

СТРУКТУРНО-КЛАССИФИКАЦИОННЫЕ МЕТОДЫ АНАЛИЗА И ПРОГНОЗИРОВАНИЯ В КРУПНОМАСШТАБНЫХ СИСТЕМАХ УПРАВЛЕНИЯ¹

Ю.А. Дорофеев

Институт проблем управления им. В.А. Трапезникова РАН, г. Москва

Предложен метод решения задач анализа и прогнозирования в крупномасштабных системах управления. В качестве прогнозной модели для каждого объекта принята марковская цепь с r состояниями, где r — число структурных единиц (классов). Для эффективной реализации предложенного метода разработан комплексный алгоритм структуризации (классификации) объектов исследуемой системы.

ВВЕДЕНИЕ

Многие крупномасштабные системы управления, прежде всего, организационно-административные, функционируют в условиях большой информационной размытости и неопределенности. Именно поэтому в последнее время для исследования таких систем стали широко применяться методы структурного анализа данных, базирующиеся на алгоритмах классификационного анализа данных [1].

В настоящей статье рассматривается задача анализа и прогнозирования в крупномасштабных системах управления, причем считается, что такая система состоит из достаточно большого числа объектов, каждый из которых характеризуется многочисленным набором разнородных параметров. Основная идея предлагаемого метода решения такой задачи состоит в том, что исследуются не точные значения параметров, описывающих состояние каждого объекта (например, траектории состояний), а лишь класс, к которому принадлежит каждый объект в рамках некоторой структуры (классификации) множества объектов, входящих в исследуемую крупномасштабную систему [2]. Такое интегральное описание объектов, входящих в

крупномасштабную систему, позволяет существенно повысить эффективность анализа поведения системы, а также устойчивость и робастность процедур принятия управленческих решений и прогнозов. Для формализации задачи используется методология классификационного анализа данных [1].

1. СТРУКТУРНО-КЛАССИФИКАЦИОННЫЙ АНАЛИЗ В КРУПНОМАСШТАБНЫХ СИСТЕМАХ УПРАВЛЕНИЯ

1.1. Постановка задачи

Пусть исследуемая система состоит из n объектов, каждый из которых характеризуется набором из k параметров. Изучается поведение этого множества объектов в дискретные моменты времени. Вводится в рассмотрение k -мерное пространство параметров X , в котором j -й объект в момент времени t представляется точкой $x_j(t) = (x_j^1(t), x_j^2(t), \dots, x_j^k(t))$. Упорядоченная совокупность точек $x_j(t_1), \dots, x_j(t_m)$ представляет собой известную часть траектории, характеризующей динамику j -го объекта.

В большинстве приложений для принятия управленческого решения в момент времени t_m используется совокупная информация об известных траекториях каждого объекта и прогноз значений

¹ Работа выполнена при частичной финансовой поддержке РФФИ, проект 08-07-00349-а.



$x_j(t_m + 1), j = 1, \dots, n$. Как правило, информация по каждому объекту рассматривается независимо от остальных [3]. Однако для многих прикладных задач требуется знать не точные значения параметров-характеристик в моменты времени t_1, t_2, \dots, t_m и прогнозировать значения в момент t_{m+1} , а знать (и прогнозировать) лишь класс, к которому принадлежит (будет принадлежать) этот объект в соответствующие моменты времени в рамках некоторой структуры (классификации) множества объектов изучаемой системы. Так, например, в процессе исследования социально-экономического развития субъектов РФ (в данном случае крупномасштабная система — народное хозяйство РФ) вовсе необязательно знать (и прогнозировать) значения социально-экономических параметров для каждого региона, достаточно лишь знать, в какой класс этот регион попадает в данный и прогнозируемый моменты времени (условно, в классы «хорошо», «средне» и «плохо» развивающихся объектов).

Основу предлагаемого подхода составляет процедура выявления структуры объектов, входящих в исследуемую систему. Предполагается, что вектор значений параметров $x_j(t)$ достаточно полно характеризует состояние j -го объекта в момент времени t . А это, в свою очередь, означает, что взаиморасположение точек $x_1(t), \dots, x_n(t)$ в пространстве X отражает реальную структуру (типологию) исследуемого множества объектов. Для выявления такой структуры в работе применяется комплексный алгоритм автоматической классификации, специально разработанный для решения таких задач. Он включает в себя алгоритмы: m -локальной оптимизации заданного критерия J , выбора информативных параметров, выбора начального разбиения, выбора числа классов, заполнения пропущенных наблюдений. Рассмотрим каждый из этих алгоритмов в отдельности.

1.2. Алгоритм m -локальной оптимизации

Вначале опишем работу алгоритма 1-локальной оптимизации. Для простоты изложения рассматривается случай двух классов $r = 2$. Пусть задано начальное разбиение R_0 всех точек классифицируемой выборки x_1, \dots, x_n . Обозначим через $x_j \in A_1$ точки, относящиеся к первому классу, а через $x_j \in A_2$ — ко второму. Алгоритм итерационный — на каждом шаге рассматривается одна точка из последовательности $x_1, \dots, x_n, x_1, \dots, x_n, x_1, \dots$ («зацикленная» исходная последовательность). Отнесение точки к одному из двух классов обозначается с помощью индекса

$$\rho(x_j) = \begin{cases} 1, & \text{если } x_j \in A_1, \\ -1, & \text{если } x_j \in A_2. \end{cases}$$

Тогда алгоритм 1-локальной оптимизации определяется следующим образом: $\rho(x_j) = \text{sign}[J(x_j \in A_1) - J(x_j \in A_2)]$.

В итоге точка x_j относится к тому классу, при отнесении к которому значение критерия J будет больше (если эти значения равны, то для определенности точка относится к классу с меньшим номером). Алгоритм заканчивается, если на некотором цикле среди точек x_1, \dots, x_n не будет сделано ни одной «переброски» точки из класса в класс.

Алгоритм m -локальной оптимизации — это поэтапное применение к выборке алгоритмов s -локальной оптимизации, $s = 1 \dots m$. На s -м этапе алгоритм работает по той же схеме, только на каждом его шаге происходит пробная «переброска» из класса в класс не одной, а s точек. Подсчитывается значение критерия J до и после «переброски», Принадлежность каждой из s точек к классу либо остается неизменной (значение J до «переброски» больше, чем после), либо меняется на другой класс — в противном случае. В данном случае цикл — это число шагов, равное числу различных s точек в выборке. Доказана сходимость алгоритма за конечное число шагов к локальному максимуму критерия J . Разработан эвристический алгоритм сокращенного перебора, в котором на каждом шаге для пробной «переброски» используются s точек, в определенном смысле ближайших к границе между классами.

При моделировании и в приложениях в качестве критерия J принимался функционал J_1 средней близости точек в классах, определяемый через потенциальную функцию близости точек x и y :

$$K(x, y) = 1/\{1 + \alpha R^p(x, y)\}, \quad (1)$$

где $R(x, y)$ — расстояние между точками x и y , α и p — настраиваемые параметры алгоритма. Средняя близость точек в классе определяется как

$$K(A_i, A_j) = \frac{2}{n_i(n_i - 1)} \sum_{i=1}^{n_i} \sum_{j>i} K(x_i, x_j),$$

где $K(x_i, x_j)$ определяется формулой (1), n_i — число точек в классе A_i . Тогда критерий J_1 определяется как

$$J_1 = \sum_{i=1}^r \frac{n_i}{n} K(A_i, A_i). \quad (2)$$

Специально отметим частный случай алгоритма m -локальной оптимизации для $k = 1$ (одномерный случай). Дело в том, что одномерный случай имеет уникальное свойство, существенно упрощающее процедуры целенаправленного перебора, применяемые для автоматической классифика-

ции, а именно: ввиду одномерной упорядоченности классов границей между двумя классами (в детерминированном случае) служит только одна точка, и таких границ может быть не более двух (для крайне правого и крайне левого классов — только одна). Работа детерминированного (в отличие от общего — размытого) варианта модификации этого алгоритма для одномерного случая описана в работе [4].

1.3. Алгоритм выбора информативных параметров

Этот алгоритм базируется на одном из алгоритмов экстремальной группировки параметров, а именно, на алгоритме «квадрат» [5]. В результате его применения получают разбиение исходных k параметров на небольшое (заданное) число групп, а также значения факторов для этих групп. В приложениях используются либо новые интегральные параметры — факторы групп, либо набор параметров, каждый из которых является ближайшим к фактору в соответствующей группе.

В большинстве приложений исходные или выделенные информативные параметры имеют неравнозначную важность для определения структуры объектов. Для выявления таких показателей важности в работе предлагается применять процедуры экспертного оценивания. Наиболее хорошие результаты дает процедура многовариантной экспертизы [6], когда к получению параметра важности для каждого оцениваемого параметра привлекаются несколько групп экспертов — специалистов в различных аспектах исследуемой проблемы. В результате процедуры экспертизы каждый параметр получает определенный вес (показатель его «важности») для формирования структуры объектов.

1.4. Алгоритм построения начального разбиения

На первом шаге из всех точек выборки x_1, \dots, x_n находится пара наиболее удаленных друг от друга точек, x_l и x_p , одна из которых x_l относится к первому классу, а другая x_p — ко второму. Если n достаточно велико, то используется усеченный вариант первого шага, а именно: x_l выбирается случайно, а x_p ищется как точка, наиболее от нее удаленная.

На втором шаге ищутся точки x_{l+1} и x_{p+1} — ближайšie, соответственно, к точкам x_l и x_p ; точка x_{l+1} относится к первому классу, а x_{p+1} — ко второму.

На $(s+1)$ -ом шаге ищутся точки x_{l+s} и x_{p+s} , ближайšie в среднем к уже найденным точкам,

соответственно, первого и второго классов. Точка x_{l+s} определяется следующим образом:

$$x_{l+s} = x_j / \min_{x_j} \frac{1}{s} \sum_{m=0}^s K(x_j, x_{l+m}). \quad (3)$$

Точка x_{p+s} определяется аналогично. Если возникает «конфликт», т. е. одна и та же точка является ближайшей к первому и ко второму классам одновременно, то она относится к первому классу. Процедура (3) повторяется до тех пор, пока не будут исчерпаны все точки выборки. Полученное разбиение принимается в качестве начального разбиения R_0 .

1.5. Алгоритм выбора числа классов

Для выбора числа классов применяется специальная экспертно-компьютерная процедура, которая заключается в следующем. Сначала эксперт-пользователь оценивает диапазон (r_{\min}, r_{\max}) , в пределах которого заведомо находится искомое число классов. Далее, с помощью любого алгоритма автоматической классификации (в настоящей работе применялся алгоритм m -локальной оптимизации), анализируемое множество объектов разбивается на $r_{\min}, r_{\min} + 1, \dots, r_{\max}$ классов. Качество каждой из полученных классификаций оценивалось с помощью критерия $J_3 = J_1 - qJ_2$, где критерий J_1 вычисляется по формуле (2), величина J_2 , а также некоторые вспомогательные величины вычисляются по формулам:

$$J_2 = \frac{1}{r-1} \sum_{i=1}^r \sum_{j>i}^r \frac{n_i + n_j}{n} (A_i, A_j);$$

$$K(A_i, A_j) = \frac{1}{n_i n_j} \sum_{x_l \in A_i} \sum_{x_p \in A_j} K(x_l, x_p) — \text{мера близости}$$

классов A_i и A_j , где потенциальная функция $K(x_i, x_j)$ определяется формулой (1); q , α и p из формулы (1) — настраиваемые параметры алгоритма. Фактически, параметр q является масштабирующим параметром, приводящим к соизмеримым средним значениям функционалов J_1 и J_2 ; на практике значение q примерно 2...7 (обычно во столько раз отличается средняя близость внутри классов от средней близости между самими классами).

Формально, в качестве «оптимального» можно выбрать такое число классов r_{opt} , которое соответствует максимальному значению $J_3(r_j)$, т. е. $r_{\text{opt}} = r_j$, для которого $\max J_3(r_j)$, $r_j = r_{\min}, \dots, r_{\max}$. Однако наличие существенной, но неиспользованной при классификации информации, например, ввиду отсутствия данных, может привести к тому, что по-



лученное таким способом r_{opt} не будет «истинно оптимальным».

Для компенсации этого недостатка предлагается следующая экспертная процедура. Экспертам-специалистам в соответствующей предметной области представляются значения $J_3(r_j)$, $r_j = r_{\text{min}}, \dots, r_{\text{max}}$, представленные для удобства в виде графика, на котором отмечается значение r_{opt} (оно соответствует максимальной точке на графике $J_3(r_j)$). Используя эту информацию, эксперты могут корректировать выбираемое число классов. В подавляющем большинстве случаев экспертное число классов либо совпадает со значением r_{opt} , либо незначительно (± 1) отличается от него.

При классификации многомерных объектов во время такой экспертизы анализируется также классификация каждого объекта. Для этой цели экспертам сообщается информация о мере близости $K(x_i, c_j)$ каждой точки x_i до центров классов c_j , $j = 1, \dots, r_{\text{opt}}$ в оптимальной классификации, т. е. матрица близости $\|K(x_i, c_j)\|$, $i = 1, \dots, n, j = 1, \dots, r_{\text{opt}}$. Перенесение точки (объекта) x_i из j -го класса в l -й считается допустимым, если величины $K(x_i, c_j)$ и $K(x_i, c_l)$ отличаются незначительно. Другими словами, содержательно обоснованное перенесение допустимо для точек, расположенных вблизи границы между соответствующими классами.

1.6. Алгоритм заполнения пропущенных наблюдений

Во многих приложениях имеются пропуски в данных. В этой ситуации нужно либо применять специальные процедуры подсчета расстояний между объектами, в параметрах которых имеются пропуски, либо разрабатывать специальные процедуры заполнения таких пропусков. В подавляющем большинстве случаев пропуски по каждому параметру заполняются средним известных значений соответствующего параметра (для исходной выборки). В настоящей работе была разработана специальная процедура заполнения пропусков в исходных данных с помощью алгоритмов автоматической классификации. Ее основная идея состоит в следующем. Если множество изучаемых объектов структурировано (т. е. их можно разделить на классы, достаточно компактно расположенные в пространстве параметров X), то дисперсия (диапазон) изменения каждого параметра в пределах каждой группы, как правило, будет существенно меньше, чем этот показатель для значения этого параметра по всей выборке. Таким образом, если по данным с пропусками удастся определить реальную структуру взаиморасположения точек (т. е. провести классификацию, адекватную этой струк-

туре), то заполнять пропущенное значение l -го параметра для объекта из i -го класса можно средним этого параметра по его известным значениям для всех объектов, попавших в i -й класс. Исходя из сделанного предположения, отклонение полученного значения от «истинного» должно быть существенно меньше (в среднем), чем обычная схема заполнения по общему среднему.

2. МЕТОДИКА СТРУКТУРНО-КЛАССИФИКАЦИОННОГО ПРОГНОЗИРОВАНИЯ В КРУПНОМАСШТАБНЫХ СИСТЕМАХ УПРАВЛЕНИЯ

2.1. Динамическая структуризация исследуемых объектов

Вначале (в момент времени t_1) с помощью комплексного алгоритма автоматической классификации, описанного в § 1, производится структуризация n точек в пространстве X на r классов, каждый из которых и характеризует определенный тип объекта. Число классов r выбирается с помощью человеко-машинной процедуры, входящей в комплексный алгоритм автоматической классификации. Вводится понятие модели (эталона) класса $a_i(t)$, $i = 1, \dots, r$ (чаще всего — это центр класса) [1]. Для каждого объекта, кроме принадлежности к классу, вычисляются расстояния до эталонов всех классов $R_{ij}(t)$, $i = 1, \dots, r; j = 1, \dots, n$.

Заметим, что на практике структуризация объектов чрезвычайно редко проводится в пространстве исходных признаков, обычно сначала выделяется набор информативных параметров. В настоящей работе для этой цели применялась специальная процедура, также входящая в комплексный алгоритм, она описана в п. 1.3.

В момент времени t_2 каждая точка $x_j(t_2)$ с помощью одного из алгоритмов распознавания образов с учителем относится к тому или иному классу в рамках классификации, полученной на первом шаге. Для этого применяется алгоритм метода потенциальных функций, который в спрямляющем пространстве эквивалентен алгоритму ближайшего среднего [7]. А именно, каждая точка $x_j(t_2)$ относится к классу A_p для которого заданная мера близости $K(x_j(t_2), A_p)$ точки $x_j(t_2)$ к этому классу максимальна, т. е. $K(x_j(t_2), A_p) = \max_i K(x_j(t_2), A_i)$, $i = 1, \dots, r, i = 1, \dots, n$. В качестве такой меры близости служит величина $K(x_j, A_p) = \frac{1}{n_l} \sum_{x_i \in A_l} K(x_j, x_i)$, где n_l — число точек в классе A_p , $K(x, y)$ — потенциальная функция (1).

После определения принадлежности всех точек к тому или иному классу, производится пересчет эталонов $a_i(t_2)$, $i = 1, \dots, r$. Для каждой точки с

предыдущего шага пересчитываются, а для каждой новой точки вычисляются расстояния до новых эталонов $R(x_j(t_2), a_i(t_2))$, $i = 1, \dots, r, j = 1, \dots, n$. Такая процедура выполняется для всех m моментов времени. В итоге для каждого объекта получается последовательность (траектория) из m позиций. В каждой позиции находится $r + 1$ число, первое из которых — это номер класса, к которому относился этот объект в соответствующий момент времени, а последующие числа — это значения расстояний до центров классов в тот же момент времени. Требуется спрогнозировать номер класса (тип объекта), к которому будет относиться каждый объект в момент времени t_{m+1} .

2.2. Алгоритм прогнозирования

В качестве прогнозной модели для каждого объекта используется марковская цепь с r состояниями, т. е. на каждом шаге рассчитываются элементы матрицы переходных вероятностей $P = \|p_{ij}\|$, $j = 1, \dots, n; i = 1, \dots, r$. Разработан специальный алгоритм пересчета на каждом шаге соответствующих переходных вероятностей p_{ij} с использованием информации о значениях расстояний до центров классов и условий нормировки $\sum_{i=1}^r p_{ij} = 1$ для всех $j = 1, \dots, n$.

Алгоритм работает следующим образом. Пусть после первого шага, для точек $x_j(t_1)$ подсчитаны расстояния до эталонов $R_{ji}^{(1)} = R(x_j(t_1), a_i(t_1))$, $i = 1, \dots, r, j = 1, \dots, n$. Тогда элементы матрицы переходных вероятностей $p_{ji}^{(1)} = p_{ji}(t_1)$ рассчитываются следующим образом:

$$p_{ji}^{(1)} = \alpha_j^{(1)} / R_{ji}^{(1)}, \quad (4)$$

где $\alpha_j^{(1)} = \frac{\prod_{i=1}^r R_{ji}^{(1)}}{\sum_{l=1}^r \frac{1}{R_{jl}^{(1)}} \prod_{i=1}^r R_{ji}^{(1)}}$ — нормирующий множитель.

На s -м шаге элементы матрицы переходных вероятностей (4) модифицируются с помощью следующей процедуры. Введем обозначения $\Delta R_{ji}^{(s)} = R_{ji}^{(s-1)} - R_{ji}^{(s)}$, $\Delta \hat{R}_{ji}^{(s)} = \frac{R_{ji}^{(s-1)} - R_{ji}^{(s)}}{R_{ji}^{(s-1)} + R_{ji}^{(s)}}$. Если j -я точка

совпадает с эталоном i_0 -го класса ($x_j(t_s) = a_{i_0}(t_s)$), т. е. $R_{ji_0}^{(s)} = 0$, то

$$p_{ji}^{(s)} = \begin{cases} 1, & \text{если } i = i_0, \\ 0, & i = 1, \dots, r, i \neq i_0. \end{cases}$$

Другими словами, если точка совпадает с эталоном некоторого класса, то вероятность для этой точки остается в этом классе равна 1, а вероятность перехода в другой класс равна 0.

Для случая, когда $R_{ji_0}^{(s)} \neq 0$, все переходные вероятности модифицируются по следующей схеме:

$$p_{ji}^{(s)} = \gamma \left[p_{ji}^{(s-1)} + \left(\frac{1 + \text{sign}(\Delta R_{ji}^{(s)})}{2} - p_{ji}^{(s-1)} \text{sign}(\Delta R_{ji}^{(s)}) \right) \Delta \hat{R}_{ji}^{(s)} \right], \quad (5)$$

где, как обычно, $\text{sign}(z) = \begin{cases} 1, & \text{если } z \geq 0, \\ -1, & \text{если } z < 0, \end{cases}$ а γ — нормирующий множитель, определяемый условием нормировки переходных вероятностей $\sum_{i=1}^r p_{ji}^{(s)} = 1$:

$$\gamma = \frac{1}{1 + ((1 + \text{sign}(\Delta R_{ji}^{(s)}))/2 - p_{ji}^{(s-1)} \text{sign}(\Delta R_{ji}^{(s)})) \Delta \hat{R}_{ji}^{(s)}}.$$

Введение в формулу (5) величины $\text{sign}(\Delta R_{ji}^{(s)})$ вызвано необходимостью модификации различными способами переходных вероятностей для случаев увеличения и уменьшения расстояния от точки $x_j(t_s)$ до эталонов классов $a_i(t_s)$ на s -м шаге. А именно, в случае уменьшения величины $R_{ji}^{(s)}$ по отношению к $R_{ji}^{(s-1)}$ (т. е. $\Delta R_{ji}^{(s)} < 0$), соответствующая переходная вероятность изменяется путем ее увеличения на некоторую долю от $(1 - p_{ji}^{(s-1)})$; а в случае увеличения величины $R_{ji}^{(s)}$ по отношению к $R_{ji}^{(s-1)}$ (т. е. $\Delta R_{ji}^{(s)} > 0$), соответствующая переходная вероятность изменяется путем ее уменьшения на некоторую долю от $p_{ji}^{(s-1)}$. Это необходимо для выполнения условий нормировки для переходных вероятностей $0 < p_{ji}^{(s)} < 1, i = 1, \dots, r$.

Построенная с помощью описанного алгоритма матрица переходных вероятностей P используется для прогнозирования принадлежности объекта к тому или иному классу. На практике обычно применяется не рандомизированная, а байесовс-



кая схема, когда объект относится к тому классу i_0 , для которого $p_{ji_0} = \max_{i=1, \dots, r} p_{ji}$. В случае равенства переходных вероятностей p_{ji} для прогнозируемого объекта для двух или нескольких классов, он относится к классу с наименьшим номером.

2.3. Модификации

Разработана модификация процедуры прогнозирования, когда классификация объектов задается заранее (например, экспертным путем) и в последующем остается неизменной.

Разработан также вариант алгоритма «с памятью», когда используются данные только об s прошлых состояниях множества объектов (s — глубина памяти алгоритма).

Оказалось, что для некоторых приложений (с достаточно высоким уровнем помех при измерении параметров) существенно более эффективными оказываются алгоритмы размытой классификации, в том числе с фоновым классом [1].

ЗАКЛЮЧЕНИЕ

Разработанная методика применялась для анализа и совершенствования процедур принятия решений для нескольких больших систем управления, в основном регионального уровня, в том числе — региональная система управления здравоохранением, пассажирскими автоперевозками, система анализа, управления и прогнозирования социально-экономического развития субъектов

РФ и др. Во всех приложениях, а также при машинном моделировании была подтверждена высокая эффективность разработанного комплекса алгоритмов структурно-классификационного анализа и прогнозирования.

ЛИТЕРАТУРА

1. Бауман Е.В., Дорофеюк А.А. Классификационный анализ данных / Тр. Междунар. конф. по проблемам управления. — М.: СИНТЕГ, 1999. — Т. 1. — С. 62–67.
2. Дорофеюк А.А., Дорофеюк Ю.А. Методы структурно-классификационного прогнозирования многомерных динамических объектов // Искусственный интеллект. — 2006. — № 2. — С. 138–141.
3. Статистическое моделирование и прогнозирование / Под ред. А.Г. Гранберга. — М.: Финансы и статистика, 1990. — 382 с.
4. Процедуры классификационного анализа в задаче формирования информативных признаков при исследовании ритмической структуры биосигнала / А.А. Десова, А.А. Дорофеюк, В.В. Гучук и др. // Автоматика и телемеханика. — 2008. — № 6.
5. Браверман Э.М., Мучник И.Б. Структурные методы обработки эмпирических данных. — М.: Наука, 1983.
6. Дорофеюк А.А., Покровская И.В., Чернявский А.Л. Экспертные методы анализа и совершенствования систем управления // Автоматика и телемеханика. — 2004. — № 10. — С. 172–188.
7. Айзерман М.А., Браверман Э.М., Розоноэр Л.И. Метод потенциальных функций в теории обучения машин. — М.: Наука, 1970.

☎ (495) 334-90-70, e-mail: tigress86@bk.ru

Статья представлена к публикации членом редколлегии А.С. Манделем. □



Мультиконференция по информационным технологиям и управлению в промышленности

Институт проблем управления им. В.А. Трапезникова РАН,
3—7 июня 2009 г., г. Москва

В рамках мультиконференции пройдут следующие мероприятия:

- 13-й симпозиум «Information Control Problems in Manufacturing» (INCOM'09) — информационные технологии и управление в промышленности под эгидой Международной федерации по автоматическому управлению (International Federation of Automatic Control — IFAC)
- Международная научно-практическая конференция-выставка «Автоматизация в промышленности»
- Семинар «Информационные технологии в промышленности» для руководящего звена промышленности и бизнеса

Дополнительную информацию можно получить по тел./факсу (495) 334-89-90,
на сайтах <http://incom09.org>, <http://multi.sicpro.org>.
E-mail: incom09@ipu.ru, income@ipu.ru.