

Формирование образной компоненты знаний когнитивного агента со знаковой картиной мира*

А.И. Панов^{1,2}

¹Федеральное государственное учреждение «Федеральный исследовательский центр «Информатика и управление» Российской академии наук», г. Москва, Россия

²Московский физико-технический институт (государственный университет), г. Москва, Россия

Аннотация. В теории знаковой картины мира элементарной единицей информации при моделировании произвольных когнитивных процессов планирования, целеполагания и рефлексии является знак, понимаемый как четырехкомпонентная структура. Отдельные компоненты знака отвечают за реализацию более простых произвольных процессов, которые играют роль автоматических поддерживающих функций. Для описания поддерживающих функций картины мира используются понятия каузальной матрицы и каузальной сети, определения которых уточняются в данной работе. Вводятся процедуры распространения активности по каузальной сети. На примере образной компоненты знака предложен алгоритм формирования каузальной матрицы и фрагмента каузальной сети. В качестве тестовой задачи рассмотрена задача идентификации аномалий в локомоторных движениях человека.

Ключевые слова: знак, знаковая картина мира, когнитивная функция, обучение с подкреплением, каузальная матрица, каузальная сеть, распространение активности.

DOI 10.14357/20718632180409

Введение

Одной из основных проблем при разработке информационных систем, в особенности интеллектуальных систем управления виртуальными агентами или реальными физическими роботами, является проблема выбора такого способа представления, интеграции и проявления активности знаний, который бы обеспечил выполнение сложных, не реализуемых классическими методами искусственного интеллекта интеллектуальных функций. К таким функциям, прежде всего, относятся функции целеполагания, интроспекции и коллективного планирования. Перспективным подходом к решению этой проблемы является подход, развиваемый

в рамках теории знаковой картины мира [1]. Эта теория представляет собой психологически и биологически правдоподобную формализацию элементов индивидуального знания и когнитивных функций.

При моделировании знаковой картины мира выделяют три уровня описания: синтаксический, семантический и структурный [2]. На синтаксическом уровне вводится понятие знака как элементарной единицы произвольного индивидуального знания, состоящей из трех основных компонент (образа, значения и личностного смысла) и имени, который объединяет эти три компоненты в единую согласованную структуру (аналогичные модели можно найти в [3-5]). Каждый компонент знака представляет

* Работа выполнена при финансовой поддержке РФФИ, гранты №16-37-60055 и №17-29-07079.

свой тип информации о представляемой знаком сущности или явлении, которыми могут быть как объекты, ситуации или действия внешнего мира, так и внутренние состояния носителя картины мира или его «внутренние» действия, меняющие только эти состояния. На том же синтаксическом уровне вводится понятие функции связывания компонент в единую структуру – знак [6]. На семантическом уровне каждая компонента знака представляется в виде набора предикатов языка исчисления предикатов первого порядка и набора правил, как их понимают в искусственном интеллекте [7]. Это позволяет ввести семантические определения и описания ряда отношений на множестве компонентов знака: сходства и различия образов, сценарного отношения на значениях и ситуационного на личностных смыслах [2, 6]. На семантическом уровне удастся описать ряд когнитивных функций, таких как планирование [8, 9] и целеполагание [10], которые являются основными составляющими процесса синтеза произвольного поведения агента. Такие когнитивные функции будем называть *произвольными*. Наконец, на структурном уровне описания модели знаковой картины мира вводятся понятия каузальной сети и каузальной матрицы. Уточняя структуру компонент знака, эти понятия позволяют построить описания ситуации и предсказать результаты действия, а также простроить модели ряда вспомогательных когнитивных функций, таких как распознавание и категоризация [10, 11]. Подобные *обеспечивающие функции* описываются с помощью понятий распространения активности на каузальных сетях.

Понятие знаковой картины мира как особого способа представления знаний о себе и о внешней среде не было бы столь полезным при моделировании когнитивных функций человека, если бы не было снабжено алгоритмом его пополнения, т.е. некоторым методом машинного обучения, направленного на формирование новых знаков и определенных структур на их множестве. Ряд вопросов на эту тему, в частности, вопрос итерационного связывания двух компонент, был рассмотрен ранее [8]. Настоящая работа направлена на разработку одного из базовых алгоритмов, а именно, формирования образной компоненты знака в режиме обучения без учителя, т.е.

при автоматическом выделении паттернов в потоке внешних данных, поступающих, например, от сенсорных систем интеллектуального агента. В работе уточняются понятия каузальной матрицы и каузальной сети, вводится более точное определение активности и правил ее распространения. На этой основе описан алгоритм формирования фрагмента каузальной сети и приведены результаты экспериментального исследования работы предложенного алгоритма в задаче идентификации аномалий в записях движений (локомоций) человека.

1. Основные определения структурного уровня

Вначале уточним основные определения, которые будут использоваться в данной работе.

Определение 1. Каузальным тензором $T(n) = T[n, \bar{n}, \bar{t}_c, \bar{\tau}]$ будем называть трехмерный массив действительных чисел размерности $r \times q \times h$, который снабжен идентификатором n и тремя ссылочными векторами:

1) *признаковым вектором* $\bar{n} = (n_1, n_2, \dots, n_q)$ длины q , определяющим список идентификаторов каузальных тензоров, являющихся *признаками* для данного тензора $T(n)$;

2) *временным вектором* $\bar{t}_c = (t_1, t_2, \dots, t_{h_c})$ длины $h_c \leq h$, задающим индексы элементов тензора по третьей оси, которые относятся к *индексам условий тензора*, соответственно остальные $h_e = h - h_c$ индексов относятся к *индексам эффектов* \bar{t}_e тензора;

3) *прецедентным вектором* $\bar{\tau} = (\tau_1, \tau_2, \dots, \tau_r)$ длины r , содержащим типы τ_i прецедентов размерности $q \times h$ в каузальном тензоре.

Каузальный тензор $T(n)$, представляющий в модели картины мира некоторую часть информации о внешнем или внутреннем для носителя картины мира явлении, интерпретируется как r прецедентов кодирования этой информации в виде каузальной матрицы Z размерности $q \times h$. В общем случае прецеденты могут быть нескольких типов, что определяются алгоритмом формирования тензора. Столбцы, или события,

$e_i, i \in [1, 2, \dots, h]$, каузальной матрицы представляют собой множество признаков, совместно проявляющихся при работе с этой частью информации в дискретные моменты времени $1, 2, \dots, h$, абсолютная длина θ^f которых определяется тем, какому уровню иерархии принадлежит каузальный тензор $T(n)$ (см. далее). Признаковый вектор \bar{n} задает множество ссылок на другие тензоры, которые являются признаками для данного тензора, организуя, таким образом, иерархию на множестве тензоров. Событие e_i в каузальном тензоре соответствует множеству идентификаторов тензоров-признаков:

$$e_i = (f_1^i, f_2^i, \dots, f_q^i) \rightarrow \{T(n_j) : n_j \in \bar{n} \wedge f_j^i > \theta^f\},$$

где θ^f - некоторый порог проявления признаков. Множество всех событий каузальной матрицы делится на два непересекающихся подмножества, элементы которых определяются временным вектором \bar{t}_c : подмножество событий-условий $E_c = \{e_i : 1 \leq i \leq h \wedge i \in \bar{t}_c\}$ тензора и подмножество событий-эффектов $E_e = \{e_i : 1 \leq i \leq h \wedge i \in \bar{t}_e\}$ (схема каузального тензора на Рис. 1).

Как отмечалось в более ранних работах [2, 10], в зависимости от того, является ли нулевым вектор \bar{t}_e (или длина вектора \bar{t}_c равна h), т.е. присутствуют ли в тензоре события-эффекты ($E_e \neq \emptyset$), тензоры бывают двух типов: *объектные* (представляют в картине мира статические объекты и ситуации) и *процедурные* (представляют действия и процессы).

Далее дадим формальное определение той структуре, которая образуется на множестве тензоров, связанных друг с другом ссылками через признаковые вектора.

Определение 2. *Каузальной сетью* $W = (\mathbf{T}, \mathbf{L})$ будем называть ориентированный помеченный мультиграф, в котором множеству вершин \mathbf{T} с метками $\{n_1, n_2, \dots\}$ соответствует множество каузальных тензоров $\{T(n_1), T(n_2), \dots\}$, а множество дуг \mathbf{L} состоит из дуг $l_i = T(n_i) \rightarrow T(n_j) = (T[n_i, \bar{n}_i, \bar{t}_{ci}, \bar{t}_{ci}], T[n_j, \bar{n}_j, \bar{t}_{cj}, \bar{t}_{cj}])$ таких, что $n_i \in \bar{n}_j$, и помеченных тройкой $\{\varepsilon_1, \varepsilon_2, \varepsilon_3\}$, где

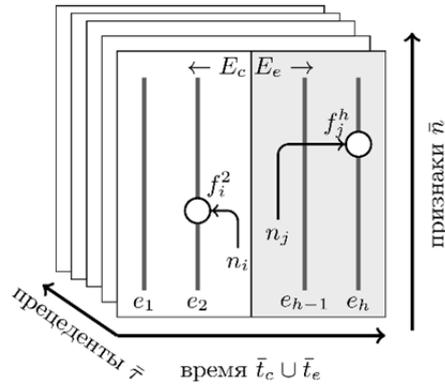


Рис. 1. Схема каузального тензора

1) $\varepsilon_1 = \tau_k$ такая, что $\tau_k \in \bar{t}_j$ и $\exists e_u = (f_1^u, f_2^u, \dots, f_q^u) \in E_c(n_j) \cup E_e(n_j)$, в котором $\exists f_v^u > \theta^f$, т.е. эта метка соответствует такому прецеденту в тензоре $T(n_j)$, для которого в каузальной матрице существует событие, в котором тензор-признак $T(n_i)$ проявляется со значением выше порога θ^f ;

2) $\varepsilon_2 = t_k$ такая, что если $t_k > 0$, то $t_k \in \bar{t}_{cj}$ и в $e_{t_k} = (f_1^{t_k}, f_2^{t_k}, \dots, f_q^{t_k}) \in E_c(n_j) \cup E_e(n_j)$ существует $f_v^{t_k} > \theta^f$, а если $t_k < 0$, то $t_k \in \bar{t}_{ej}$ и в $e_{t_k} = (f_1^{t_k}, f_2^{t_k}, \dots, f_q^{t_k}) \in E_c(n_j) \cup E_e(n_j)$ существует $f_v^{t_k} > \theta^f$, т.е. эта метка соответствует такому событию в прецеденте $\varepsilon_1 = \tau_k$ тензора $T(n_j)$, для которого в каузальной матрице существует тензор-признак $T(n_i)$, проявляющийся со значением выше порога θ^f ;

3) $\varepsilon_3 = \tau_w$ такая, что если $\tau_w > 0$, то $\tau_w \in \bar{t}_i$, т.е. определяет прецедент в тензоре $T(n_i)$, который кодирует признак для тензора $T(n_j)$, если же $\tau_w = 0$, то признак кодируется всеми прецедентами тензора $T(n_i)$.

Каузальная сеть, представляющая собой особый тип семантической сети [12], описывает как связаны друг с другом такие сложные структуры как каузальные тензоры. При этом необходимо отметить, что одна или несколько подсетей кау-

зальной сети могут не иметь циклов и представлять собой дерево, состоящее из нескольких уровней иерархии, на каждом из которых каузальные тензоры имеют некоторые общие характеристики, например, один и тот же параметр характерного времени θ_i или схожие признаковые вектора. В целом, структуру каузальной сети можно охарактеризовать как *гетерархию* [13], т.е. объединение нескольких иерархий.

Как было сказано во введении, информацию о некотором явлении, которое опосредуется в картине мира субъекта, можно разделить на три составляющие: образ, значение и личностный смысл. Каждую из этих компонент мы будем представлять каузальным тензором соответствующего типа: тензор образа, тензор значения и тензор личностного смысла. Таким образом, возможные каузальные сети также распадаются на три типа: сети на образах, значениях и личностных смыслах. При этом дуга в каузальной сети интерпретируется в зависимости от типа сети: для сети образов дуга отражает зависимость «часть-целое», «действие-поддействие» или «явление-характерный признак», для сети значений – «сценарий-роль» или «класс-подкласс», для сети личностных смыслов – «ситуация-участник ситуации». Приведем несколько примеров, поясняющие введенные определения и структуры для каждой компоненты картины мира.

На Рис. 2 изображен фрагмент каузальной сети на образах, который представляет собой описание объекта «лицо», моделируемого тензором с соответствующим идентификатором. Этот объект состоит из частей, которые одновременно являются его характерными признаками: «левый глаз», «правый глаз», «нос» и «рот». При этом, одновременно, «лицо» является составной частью и характерным признаком для объекта «тело». Т.к. все тензоры в данном примере являются объектными, то все метки на концах дуг графа больше нуля, показывая, к какому столбцу-событию условий принадлежат соответствующие признаки. В этом примере также предполагается, что для каждого тензора количество прецедентов равно 1. Если принять порог θ^f равным 1, то единственная каузальная матрица тензора $T(n)$ с идентификатором n = «лицо» будет иметь вид:

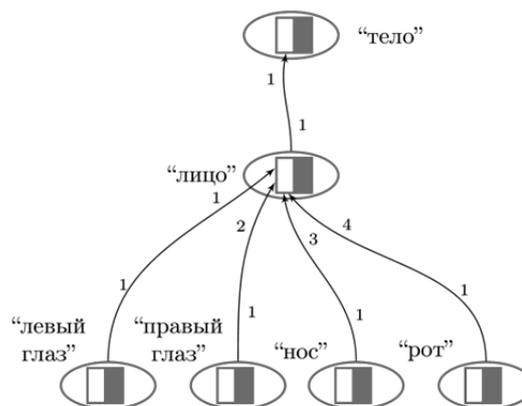


Рис. 2. Фрагмент каузальной сети на образах

Каждый тензор представлен в виде овала, в котором показаны прецеденты тензора в виде квадратов, правая, заполненная часть которых, символизирует множество событий-эффектов. Названия над овалами соответствуют идентификаторам n_i тензоров, числа рядом с началом дуги – метке ε_2 , числа рядом с концом дуги – метке ε_3 . Метке ε_1 соответствует порядковый номер матрицы внутри овала.

$$Z = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix},$$

признаковый вектор для него $\bar{n} = (\text{«левый глаз»}, \text{«правый глаз»}, \text{«нос»}, \text{«рот»})$, временной вектор $\bar{t}_c = (1, 2, 3, 4)$, прецедентный вектор $\bar{t} = (1)$.

На Рис. 3 представлены аналогичные примеры для фрагментов каузальных сетей на значениях и личностных смыслах. Левый фрагмент представляет собой описание схемы действия «рисовать», в котором соответствующий тензор связан отношениями «сценарий-роль» с ролями или абстрактными классами объектов, которые могут быть потенциальными участниками этого сценария: «субъект» (активный исполнитель действия), «объект» (что получается в результате действия), «инструмент» (с помощью чего выполняется действие). Данный состав характеризует процедурный тензор (одна из дуг имеет $\varepsilon_2 = -1$). Здесь же представлен пример и объектного тензора с идентификатором «геометрическая фигура», которая является экземпляром класса «объект» и, одновременно, классом для экземпляров «квадрат», «треугольник», «трапеция».

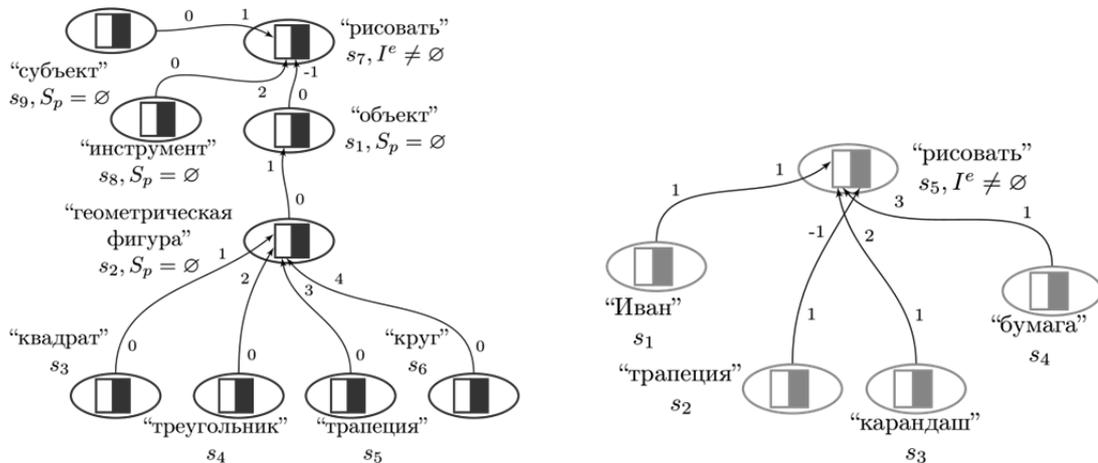


Рис. 3. Пример фрагмента каузальной сети на значениях (слева) и личностных смыслах (справа)
 Обозначения те же, что и на Рис. 2

Справа на Рис. 3 представлена конкретная ситуация «рисования», в которой процедурный тензор «рисовать» связан отношениями «ситуация-участник» с тензорами, представляющими объекты «Иван» (человек, субъект действия), «трапеция» (объект действия), «карандаш» (инструмент, с помощью которого выполняют действие) и «бумага» (одно из условий совершения действия).

В ряде работ было показано, что такой формализации представления знаний достаточно для описания внешней и внутренней для носителя картины мира информации в таких задачах, как планирование коллективного поведения, перемещение и рассуждения в пространстве [14, 15]. Более подробное описание возможных вариантов формирования отношений на множестве вершин каузальных сетей (семейства отношений R_p, R_m, R_a) можно найти в [2].

1.1. Знак и семиотическая сеть

На основе введенных структур каузального тензора и каузальной сети мы можем уточнить определения основных понятий в модели картины мира. Пусть функция связывания $\Psi_x^y(T^x(n_i)) = T^y(n_j)$ устанавливает соответствие между тензором типа x и тензором типа y , где типом может являться p (тензоры каузальной сети на образах), m (тензоры каузальной сети на значениях), a (тензоры каузальной сети на личностных смыслах). Функция связывания, таким образом, объединяет тензоры раз-

ных типов, позволяя переходить от тензора одной сети к тензору другой.

Определение 3. Знаком $s(n)$ с именем n будем называть четверку $\langle n, T^p(n), T^m(n), T^a(n) \rangle$

такую, что выполняются все три соотношения: $\Psi_a^p \Psi_m^a \Psi_p^m(T^p(n)) = T^p(n)$,

$\Psi_p^a \Psi_a^p \Psi_m^a(T^m(n)) = T^m(n)$ и

$\Psi_m^a \Psi_p^m \Psi_a^p(T^a(n)) = T^a(n)$, т.е. для любой композиции функций связывания тройка тензоров $(T^p(n), T^m(n), T^a(n))$ является неподвижной точкой.

Для определенного вида функций связывания для выполнения всех трех соотношений достаточно продемонстрировать выполнение только одного из них, например, $\Psi_a^p \Psi_m^a \Psi_p^m(T^p(n)) = T^p(n)$, остальные будут формальным следствием. Далее будем считать, что используются функции связывания именно такого вида.

Необходимо отметить, что при включении в знак все три тензора получают один и тот же идентификатор n , который совпадает с именем знака. В то же время допускается существование в каузальных сетях таких тензоров, которые не принадлежат ни одной неподвижной точке, т.е. означенной может быть только часть информации, которая имеется в картине мира. При этом предполагается, что функции Ψ_x^y связывания могут доопределяться в процессе обучения, меняя, соответственно, и множество

знаков: часть из тензоров перестают быть связаны и знак удаляется, другие тензоры образуют новую неподвижную точку, формируя новый знак. Ряд таких процедур по формированию новых знаков описан в [2, 6].

Определение 4. Семиотической сетью будем называть тройку $\langle W_n, \mathbf{W}, \Psi, \Phi \rangle$, где $\mathbf{W} = \{W_p, W_m, W_a\}$ - семейство каузальных сетей на образах, значениях и личностных смыслах, $\Psi = \{\Psi_p^m, \Psi_m^a, \Psi_a^p\}$ - семейство функций связывания, Φ - семейство правил распространения активности по каузальным сетям, $W_n = (N, R_n)$ - семантическая сеть на именах, в которой множество вершин N является множеством имен знаков $N = \{n : \Psi_a^p \Psi_m^a \Psi_p^m (T^p(n)) = T^p(n)\}$, а семейство отношений R_n задает лингвистические связи на множестве имен знаков и является трансляцией отношений на множестве компонент знака (семейств R_p, R_m, R_a).

Сеть на именах в данном определении семиотической сети играет второстепенную роль, выполняя функцию генерации лингвистического описания содержимого картины мира. Однако есть свидетельства, что сеть на именах может выполнять и более активную, управляющую функцию [16]. Перейдем к описанию правил распространения активности, составляющих семейство Φ .

1.2. Понятие активности и модели когнитивных функций

В теории знаковой картины мира предполагается введение и описание различных операций $\Xi(T) = T'$ над каузальным тензором, к которым можно отнести две основные:

1) Ξ^{len} - операция обновления в процессе обучения, в результате которой меняются как элементы самого тензора, так и его временных и прецедентных векторов (см. алгоритм формирования тензора);

2) Ξ^{comp} - операция внутреннего обобщения, когда ряд схожих прецедентов тензора объединяется в один обобщенный прецедент, в этом слу-

чае также меняются и элементы тензора, и прецедентный вектор.

Для определения модели когнитивной функции в знаковой картине мира определим понятие активности и семейство функций ее распространения Φ . С каждым каузальным тензором $T(n_i)$ сопоставим действительное число $0 \leq \lambda_i \leq 1$. Множество активных тензоров $T^* = \{T(n_i) | \lambda_i > \theta_a\}$ определяется некоторым параметром порога активности θ_a . То же самое понятие определим и для элементов тензора: каждому ненулевому элементу тензора (n_k, t, τ_i) поставим в соответствие действительное число $0 \leq \lambda_{kit} \leq 1$. Изменения значений активности тензоров и его компонент подчиняются двум наборам правил: *локальные правила* и *глобальные правила*. Рассмотрим их формулировки в допущении, что мы используем только три возможных значения активности, т.е. $\lambda \in \{0, 0.5, 1\}$, $\theta_a = 1$ (неактивное, полуактивное и активное состояния).

Локальные правила распространения активности (схематически изображены на Рис. 4) для тензора $T(n_i) = T[n_i, \bar{n}, \bar{t}_c, \bar{\tau}]$:

1) *Восходящее правило*: если в момент времени t тензор $T(n_j)$ такой, что $n_j \in \bar{n}$ и $\lambda_j = 1$, то все ненулевые элементы (j, t, τ_i) тензора $T(n_i)$ в каждом прецеденте τ_i становятся активными, т.е. $\lambda_{jit} = 1$.

2) *Предсказывающее правило*: если в момент времени t событие e_t прецедента τ_i в тензоре $T(n_i)$ активно (т.е. $\forall f_k^t \in e_t : f_k^t > 0 \wedge \lambda_{kit} = 1$) и $t < \bar{t}_c$, то все ненулевые элементы $(k, t+1, \tau_i)$ события e_{t+1} становятся полуактивными, т.е. $\lambda_{kit+1} = 0.5$.

3) *Нисходящее правило*: если в момент времени t в каждом активном прецеденте (т.е. $\forall u > 0 : u \leq t$ e_u - активно) тензора $T(n_i)$, событие e_t - активно (т.е. $\forall f_k^t \in e_t : f_k^t > 0 \wedge \lambda_{kit} = 1$), то все тензоры $T(n_j)$, соответствующие ненулевым

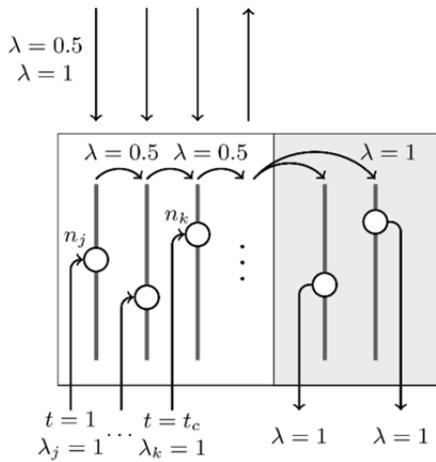


Рис. 4. Схематическое изображение локальных правил распространения активности

Восходящее правило (все стрелки снизу вверх), предсказывающее правило (дуговые стрелки в левой части каузальной матрицы), нисходящее правило (все стрелки сверху вниз в левой части матрицы), каузальное правило (дуговые стрелки и стрелки сверху вниз в правой части матрицы)

элементам $(j, t+1, \tau_i)$ события e_{t+1} в каждом прецеденте τ_i становятся полуактивными.

4) *Каузальное правило*: если в момент времени $t = t_c$ событие e_{t_c} активно, то для всех событий-эффектов последовательно применяется предсказывающее правило и нисходящее правило с поправкой на то, что распространяется полная активность, т.е. $\lambda_{jil} = 1$.

К глобальным правилам распространения активности для знака $s = \langle n, T^p(n), T^m(n), T^a(n) \rangle$, по сути, относится только одно правило: если тензор $T^x(n)$ типа x активен и $\Psi_x^y(T(n)) = T(n)$, то тензор $T^y(n)$ типа y становится полуактивным, т.е. $\lambda_j = 0.5$. Глобальное правило позволяет переводит процесс распространения активности с одного типа сети на другой за счет работы функций связывания.

Для того, чтобы с течением времени все тензоры сети не стали активными, вводится время затухания. Например, для рассмотренного выше случая $\lambda \in \{0, 0.5, 1\}$, $\theta_a = 1$ такой период может равняться характерному времени тензора, т.е. весь тензор и все его элементы перестают быть активными по истечении характерного

времени. Источником активности для сети на образах служат поступающие сигналы, а для сети личностных смыслов – внутренние потребности, которым также можно поставить в соответствие некоторые «внутренние» сенсоры.

Определение 5. Назовем *моделью когнитивной функции* последовательность знаков (s_1, s_2, \dots) таких, что $\forall s_i(n_i)$ тензоры каждой компоненты $T^p(n_i), T^m(n_i), T^a(n_i)$ являются одновременно активными, т.е. распространение активности приводит к активации таких каузальных тензоров, которые формируют знак на каждом этапе распространения активности.

2. Алгоритм формирования каузального тензора

Перейдем к одному из важнейших алгоритмов, обеспечивающих функционирование картины мира, – к алгоритму обучения или формирования нового каузального тензора и, в частности, каузальной матрицы. Мы будем рассматривать случай независимого формирования образного тензора. Ряд случаев образования новых компонент в итерационном взаимозависимом случае был рассмотрен в [8]. Предлагаемый алгоритм обучения основывается на принципе иерархической временной памяти (НТМ) [17, 18] и состоит из следующих основных шагов:

Шаг 1. Формирование пространственного представления.

Шаг 2. Поиск временных последовательностей.

Шаг 3. Выявленной причинно-следственной зависимости.

Обучение проходит для некоторого фрагмента каузальной сети без циклов, который можно представить в виде дерева тензоров. Предполагается, что предварительно имеется «схема» такого фрагмента, т.е. определено количество тензоров и их признаковые вектора. Вопрос получения схемы, или обучения виду иерархии, очень важен и требует отдельного рассмотрения, однако ряд подходов к решению этой проблемы можно найти в [19]. Рассмотрим каждый шаг формирования одного прецедента (одной каузальной матрицы) подробнее.

Входом для алгоритма обучения является последовательность векторов действительных чисел

x_1, x_2, \dots длины q , которые характеризуют наличие соответствующих признаков во входных данных. В каждый дискретный момент времени t , определяемый характерным временем θ'_i для данного тензора $T(n_i)$, поступает вектор x_i . Для тензора нижнего уровня иерархии это может быть вероятность срабатывания того или иного сенсора или яркость пикселя изображения в момент времени t . На первом шаге алгоритма проходит кластеризация поступающих векторов, что соответствует пространственной группировке в оригинальном алгоритме НТМ. В качестве метода кластеризации могут быть использованы как простейшие алгоритмы (например, динамический вариант k -средних) в случае небольшой размерности и слабой зашумленности данных, так и продемонстрировавшие свою эффективность алгоритмы формирования разреженных представлений (SDR), кодирующих описание кластеров для зашумленных данных очень большой размерности.

Для формирования SDR представления в нашей реализации использовался биологически-правдоподобный алгоритм, использующий расширенную модель нейрона с дендритными сегментами (НТМ-нейрон), синапсы которого обучаются по модифицированным правилам Хебба. Каждый НТМ-нейрон имеет свое «рецептивное поле», т.е. некоторое фиксированное множество индексов элементов входного вектора. Активность нейрона определяется тем, какова сила синапса, какому дендритному сегменту он принадлежит и каково значение элемента вектора, соответствующего этому синапсу в рецептивном поле. Обучение происходит за счет изменения силы синапса по правилу Хебба для каждого дендритного сегмента: при одновременной активности нейрона и входа сила синапса увеличивается, при разномоментной активности – сила синапса уменьшается.

НТМ-нейроны организованы в так называемые мини-колонок, активность которых определяется активностью входящих в них нейронов. Активная мини-колонка подавляет активность соседних: по принципу «победитель получает все». Каждый признак (кластер входных векторов) характеризуется набором мини-колонок, которые активируются в ответ на определенный

входной вектор x_i . Количество мини-колонок на нижних уровнях иерархии значительно превышает количество активных колонок в каждый момент времени, поэтому получаемое представление является разреженным. Мини-колонки в свою очередь организованы в колонки (узлы), связанные с другими колонками иерархическими связями. Мы будем сопоставлять одну колонку K_i одному каузальному тензору $T(n_i)$.

На втором шаге алгоритма формируются так называемые временные группы из последовательности признаков (кластеров), которые последовательно идентифицируются на основе пространственного группировщика на первом шаге. Временная группа представляет собой марковскую цепь, узлами которой являются разреженные представления признаков (кластеров). Такие марковские цепи также кодируются на основе разреженного представления и являются подмножеством активных НТМ-нейронов из множества выходных нейронов. Формирование цепей также происходит за счет правил Хебба (с учетом наличия дендритных сегментов). Выходом алгоритма обучения на данном этапе является получаемое разреженное представление, т.е. вектор активных нейронов y_i , однозначно кодирующий временную группу.

Выход временного группировщика колонки (узла) K_i объединяется с выходами других колонок этого же уровня иерархии и формирует входной вектор x_1 для колонки следующего уровня иерархии. Для соответствующего высокоуровневого каузального тензора $T(n_j)$ характерное время $\theta'_j = h * \theta'_i$, т.е. на новом уровне иерархии сети на образах рассматриваются более протяженные во времени и пространстве общие признаки и процессы.

По окончании процесса обучения в колонке K_i нейронов формируется следующий каузальный тензор $T[n_i, \bar{n}, \bar{\tau}_c, \bar{\tau}]$:

1) $\bar{\tau} = (\tau_1, \tau_2, \dots, \tau_r)$ - тензор состоит из r прецедентов (каузальных матриц), которые соответствуют разным путям в полученных на этапе работы временного группировщика марковских цепях, при этом будем полагать,

что $\tau_k = \tau_u$, если пути принадлежат одной и той же марковской цепи;

2) $\bar{n} = (n_1, n_2, \dots, n_q)$ - вектор идентификаторов признаков (кластеров), каждому идентификатору n_i соответствует свой набор мини-колонок колонки K_i ;

3) на данном шаге $\bar{t}_c = (1, 2, \dots, h)$, т.е. события-эффекты в тензоре не выделены;

4) элемент тензора с координатами (τ_k, t, n_v) равен значению вероятности присутствия признака n_v на t шаге k -го пути на множестве марковских путей, полученных временным группировщиком.

На заключительном 3-м шаге алгоритма решается задача разбиения множества событий прецедентов (каузальных матриц) тензора на два подмножества: события-условия и события-эффекты. Иными словами, решается задача поиска такого разбиения множества последовательностей $(e_1^k, e_2^k, \dots, e_h^k)$ событий одной и той же длины h , при котором подмножество событий $E_c = \{e_u^k \mid 0 < u \leq h_c \wedge \exists v \neq k : e_w^v \in E_c \wedge e_w^v \sim e_u^k\}$ не пересекается с множеством $E_e = \{e_u^k \mid h_c < u \leq h \wedge \exists v \neq k : e_w^v \in E_e \wedge e_w^v \sim e_u^k\}$, где знак \sim означает схожесть событий, т.е. расстояние между векторами e_w^v, e_u^k по некоторой метрике меньше порога θ_c . В простейшем случае, при небольших значениях h можно использовать перебор различных вариантов формирования множества E_c (соответственно и множества E_e). В более сложных случаях предполагается использовать произвольные операции логического вывода (поиска причинно-следственных связей) [20].

Отметим, что рассмотренный алгоритм работает в том случае, когда изначально задана иерархия колонок (узлов) системы обучения, т.е. заранее определены дуги в формируемом фрагменте каузальной сети, но не известны заранее метки \mathcal{E} для этих дуг.

3. Экспериментальное исследование

Рассмотренный алгоритм формирования фрагмента каузальной сети был исследован для

задачи обнаружения аномалий в данных записи движений человека, в которой представленная модель формировала образы различных типов движений, а затем применялась для идентификации отклонений относительно сформированных образов в подаваемых данных. Необходимо отметить, что задача поиска аномалий в записях локомоций человека решалась и ранее, так в [21] анализировались траектории, которым следовали испытуемые, а аномалии находились как сильные отклонения от траектории. В [22, 23] поиск аномалий проводился в видеозаписях с большим количеством участников. Авторы ставили задачу выявления аномалий в действиях отдельных людей в толпе. В [24] было проведено сравнение классификаторов аномалий, полученных с помощью скрытой марковской модели, линейных динамических систем и других подходов. В [25, 26] авторы помимо классификации движений проводили генерацию последовательностей движений. В настоящей работе не ставилась цель улучшить качество выявления аномалий по сравнению с имеющимися подходами. Данная задача выступала в качестве модельного примера, на которой была продемонстрирована работоспособность предложенного алгоритма.

Внешними явлениями, которые кодировались каузальными тензорами, служили различные типы локомоторных движений человека. Для обучения и тестирования модели были использованы данные из базы [27]. В качестве входных данных были использованы множество преобработанных видеозаписей, полученных с помощью технологии захвата движения. Видеозаписи содержат последовательные снимки актера (кадры), совершающего некоторое локомоторное действие: ходьба, бег, прыжки и т.д. Для создания видеозаписи был использован набор маркеров, расположенных на теле актера. Одновременно с записью видео движения велась запись расположения маркеров. Дополнительные каналы информации были использованы для обработки видеозаписей: удаления шумов, замены изображений человека на схематические изображения, замена цветовой палитры. Пример кадров из использованных в работе видео представлен на Рис. 5.

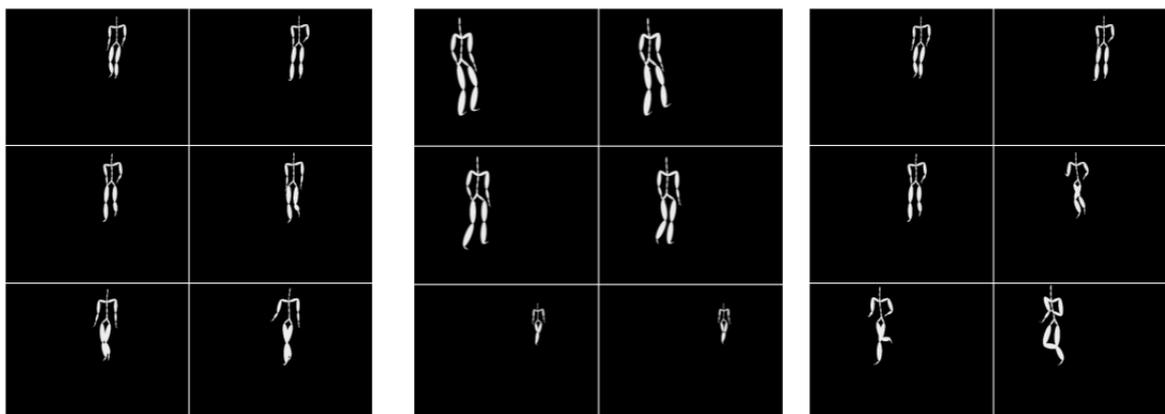


Рис. 5. Примеры кадров из экспериментальных видеозаписей (слева) и примеры аномалий (среднее и правое изображения)

Для тестирования алгоритма использовались два вида аномалий: внезапное изменение положения актера на экране и изменение выполняемого актером действия. Для создания аномалий кадры различных видеозаписей комбинировались друг с другом, либо удалялись для создания аномалии с резким перемещением актера. Примеры использованных аномалий приведены на Рис. 5.

Все эксперименты проводились на трех конфигурациях модели: с одним, двумя и тремя уровнями иерархии. Каждый эксперимент состоял из двух частей.

1. Обучение модели на исходных данных. В ходе обучения исходная последовательность кадров видео была представлена модели 5-20 раз (в зависимости от длины последовательности). В качестве остановочного критерия использовался контрольный прогон модели с обучающей видеозаписью. Для этого прогона обученная модель фиксировалась, т.е. останавливался процесс, в ходе которого происходит изменение синаптических связей. С помощью алгоритма нахождения аномалий проверялось насколько хорошо изучена обучающая последовательность. На обучающей последовательности ожидаемый выход алгоритма нахождения аномалий не должен был обнаруживать аномалий с заданной точностью.

2. Тестирование модели на данных с аномалией. Для тестирования модели, так же как для проверки в предыдущем пункте, обучение останавливалось и для каждого кадра последовательности подсчитывались вероятности аномалий. Кадры, для которых подсчитанная веро-

ятность превышала заданный порог, обозначались аномальными.

При обработке каждого кадра последовательности осуществлялся подсчет коэффициента аномалии (anomaly coefficient – AC). Значение $AC \in [0,1]$ соответствует вероятности того, что текущий кадр является аномальным. Если AC равен нулю, то модель не считает кадр аномальным, если AC близок к единице, то модель определяет кадр аномальным с высокой вероятностью. Если в видеозаписи нет аномалий, ожидается, что модель определит $AC = 0$ для всех кадров. После того как последовательность кадров пропущена через модель, получается некоторый вектор вычисленных коэффициентов AC_{real} . После этого подсчитывается следующая оценка:

$$\frac{\sum_{i=0}^n (AC_{exp}^{(i)} - AC_{real}^{(i)})^2}{n},$$

где n – количество кадров в последовательности. Эта оценка использовалась в качестве метрики для определения того, насколько хорошо модель справляется с поиском аномалий. Чем ближе оценка к 0, тем лучше работает модель.

Был проведен ряд экспериментов (более подробно [28]), которые показали, что построенная модель успешно справляется с выявлением аномалий. На аномалиях с резким перемещением актера модели всех конфигураций показали одинаково высокие результаты и всегда безошибочно определяли аномальные кадры. При обучении моделей на короткой последовательности кадров оказалось, что переход от одно-

слоистой к двухслойной конфигурации дает значимый прирост в точности обнаружения аномальных кадров. Увеличение количества слоев до трех в этом типе экспериментов не приводит к значимому улучшению качества работы моделей, что может быть связано с короткой длиной обучающей последовательности. При обучении на более длинной последовательности кадров, которая отличается от короткой сложностью представленного движения (эта последовательность представляет собой движение объекта под разными углами в разных направлениях), оказалось, что точность сетей росла с добавлением новых слоев в иерархии, хотя в целом, как и ожидалось, была ниже, чем точность в предыдущих экспериментах.

Заключение

В работе представлен один из основополагающих алгоритмов функционирования знаковой картины мира – алгоритм формирования образной компоненты знака в постановке обучения без учителя. Для этого в работы были уточнены основные понятия: каузальной матрицы, каузальной сети, знака и семиотической сети. Введены и описаны правила распространения активности на сетях. Предложенный алгоритм состоит из трех основных шагов: формирование пространственного представления, поиск временных последовательностей, выявленной причинно-следственной зависимости. Предложенная модель обучения была применена для поиска аномалий в видеозаписях локомоторных движений человека. В этой задаче модель формировала образы различных типов движений, а затем применялась для идентификации отклонений в подаваемых данных, идентифицируемых относительно сформированных образов. Была продемонстрирована работоспособность модели и зависимость качества обучения от количества уровней иерархии каузальной сети.

Литература

- Осипов Г.С. и др. Знаковая картина мира субъекта поведения. М.: Физматлит, 2018. 264 с.
- Осипов Г.С., Панов А.И. Отношения и операции в знаковой картине мира субъекта поведения // Искусственный интеллект и принятие решений. 2017. № 4. С. 5–22.
- Карпов В.Э. Об одной реализации знак - ориентированной системы управления мобильного робота // Искусственный интеллект и принятие решений. 2015. № 3. С. 53–61.
- Semiotics and Intelligent Systems Development / ed. Gudwin R., Queiroz J. IGI Global, 2007. 368 p.
- Кулинич А.А. Ситуационный, когнитивный и семиотический подходы к моделированию организаций // Инжиниринг предприятий и управление знаниями (ИП&УЗ-2016) : сборник научных трудов XIX научно-практической конференции. 26– 27 апреля 2016 г. / под ред. Ю.Ф. Тельнова. М.: ФГБОУ ВО “РЭУ им. Г. В. Плеханова”, 2016. С. 42–48.
- Осипов Г.С., Панов А.И., Чудова Н.В. Управление поведением как функция сознания. I. Картина мира и целеполагание // Известия Российской академии наук. Теория и системы управления. 2014. № 4. С. 49–62.
- Осипов Г.С., Виноградов А.Н., Жилиякова Л.Ю. Динамические интеллектуальные системы. I. Представление знаний и основные алгоритмы // Известия АН. Теория и системы управления. 2002. № 6. С. 119–127.
- Осипов Г.С., Панов А.И., Чудова Н.В. Управление поведением как функция сознания. II. Синтез плана поведения // Известия Российской академии наук. Теория и системы управления. 2015. № 6. С. 47–61.
- Киселев Г.А., Панов А.И. Знаковый подход к задаче распределения ролей в коалиции когнитивных агентов // Труды СПИИРАН. 2018. № 2. С. 161–187.
- Панов А.И. Целеполагание и синтез плана поведения когнитивным агентом // Искусственный интеллект и принятие решений. 2018. № 2. С. 21–35.
- Панов А.И. Алгебраические свойства операторов распознавания в моделях зрительного восприятия // Машинное обучение и анализ данных. 2014. Т. 1. № 7. С. 863–874.
- Осипов Г.С. Построение моделей предметных областей. Ч. I. Неоднородные семантические сети // Известия АН СССР. Техническая кибернетика. 1990. № 5. С. 32–45.
- Величковский Б.М. Гетерархия когнитивной организации: прошлое, настоящее и будущее // В книге: Седьмая международная конференция по когнитивной науке Тезисы докладов. Ответственные редакторы: Ю. И. Александров, К. В. Анохин. 2016. С. 194.
- Kiselev G., Kovalev A., Panov A.I. Spatial reasoning and planning in sign-based world model // Artificial Intelligence / ed. Kuznetsov S., Osipov G.S., Stefanuk V. Springer International Publishing, 2018. P. 1–10.
- Ermeck A., Kiselev G., Panov A.I. Task and Spatial Planning by the Cognitive Agent with Human-like Knowledge Representation // Interactive Collaborative Robotics / ed. Ronzhin A., Rigoll G., Meshcheryakov R. Springer International Publishing, 2018. (In Press).
- Кузнецова Ю.М. и др. Языковая система как регулятор планирования поведения когнитивных агентов // Восьмая международная конференция по когнитивной науке: Тезисы докладов. 2018. (В печати).
- George D., Hawkins J. Towards a mathematical theory of cortical micro-circuits // PLoS Comput. Biol. 2009. Vol. 5, № 10. P. e1000532.
- Hawkins J., Ahmad S., Cui Y. A Theory of How Columns in the Neocortex Enable Learning the Structure of the World // Front. Neural Circuits. 2017. Vol. 11. P. 1–18.
- Скрынник А.А., Панов А.И. Автоматическое построение иерархии абстрактных автоматов для задачи обу-

- чения с подкреплением // Информатика, управление и системный анализ: Труды V Всероссийской научной конференции молодых учёных с международным участием. Ростов-на-Дону: Мини-Тайп, 2018. С. 7–16.
20. Финн В.К. Об определении эмпирических закономерностей посредством ДСМ - метода автоматического порождения гипотез // Искусственный интеллект и принятие решений. 2010. № 4. С. 41–48.
 21. Suzuki N. et al. Learning motion patterns and anomaly detection by human trajectory analysis // Systems, Man and Cybernetics, 2007. ISIC. IEEE International Conference on. – IEEE, 2007. – С. 498-503.
 22. Kratz L., Nishino K. Anomaly detection in extremely crowded scenes using spatio-temporal motion pattern models // Computer Vision and Pattern Recognition, 2009. CVPR 2009. IEEE Conference on. – IEEE, 2009. – С. 1446-1453.
 23. Li W., Mahadevan V., Vasconcelos N. Anomaly detection and localization in crowded scenes // IEEE transactions on pattern analysis and machine intelligence. – 2014. – Т. 36. – №. 1. – С. 18-32.
 24. Ren L. et al. A data-driven approach to quantifying natural human motion // ACM Transactions on Graphics (TOG). – ACM, 2005. – Т. 24. – №. 3. – С. 1090-1097.
 25. Bütepage J. et al. Deep representation learning for human motion prediction and classification // IEEE Conference on Computer Vision and Pattern Recognition (CVPR). – 2017. – С. 2017.
 26. Du Y., Wang W., Wang L. Hierarchical recurrent neural network for skeleton based action recognition // Proceedings of the IEEE conference on computer vision and pattern recognition. – 2015. – С. 1110-1118.
 27. CMU Graphics Lab. Carnegie Mellon University Motion Capture Database. 2003. url: [http://http://mocap.cs.cmu.edu/](http://mocap.cs.cmu.edu/).
 28. Дайлиденко И.Д., Фроленкова А.И. Биологически правдоподобные нейронные сети для выявления аномалий во временных последовательностях // Информатика, управление и системный анализ: Труды V Всероссийской научной конференции молодых учёных с международным участием. Ростов-на-Дону: Мини-Тайп, 2018. С. 169–178.

Панов Александр Игоревич. Институт проблем искусственного интеллекта Федерального государственного учреждения Федеральный исследовательский центр «Информатика и Управление» Российской академии наук г. Москва, Россия. Лаборатория когнитивных динамических систем Московского физико-технического института (государственного университета), г. Москва, Россия. Старший научный сотрудник, кандидат физико-математических наук. Количество печатных работ: 70 (в т.ч. 1 монография). Область научных интересов: когнитивные динамические системы, семиотика, обучение с подкреплением. E-mail: pan@isa.ru

Formation of an Image Component of Knowledge of the Cognitive Agent with a Sign-based Model of Worldview

A.I. Panov^{1,II}

¹Federal Research Center "Computer Science and Control" of the Russian Academy of Sciences

^{II}Moscow Institute of Physics and Technology (State University)

In the theory of the sign-based model of worldview the elementary unit of information (at modeling of any cognitive processes, such as planning, goal-setting and reflection) is the four-component structure named sign. Sign components are responsible for implementing relatively simple involuntary processes that play the role of automatic or supporting functions. To describe the supporting functions of the sign-based world model, the concepts of the causal matrix and the causal network are used, the definitions of which are specified in this paper. The procedures of activity spreading on the causal network are introduced. With a focus on the image component of the sign, the paper proposes an algorithm for the formation of the causal matrix and a fragment of the causal network. As an example, the problem of identification of anomalies in human locomotory movements is considered.

Keywords: sign, sign-based world model, cognitive function, HTM, causal matrix, causal network, activity spreading.

DOI 10.14357/20718632180409

References

1. Osipov G.S. et al. Znakovaya kartina mira sub"ekta povedeniya [Sign-based model of Actor's Worldview]. M.: Fizmatlit, 2018. 264 p. (In Russian).
2. Osipov G.S., Panov A.I. Relationships and operations in agent's sign-based model of the world // Sci. Tech. Inf. Process. 2018. Vol. 45, № 5. P. 1–14.
3. Karpov V.E. A sign-oriented mobile robot-control system // Sci. Tech. Inf. Process. 2018. Vol. 45, № 5-6, pp. 281-288.

4. Semiotics and Intelligent Systems Development / ed. Gudwin R., Queiroz J. IGI Global, 2007. 368 p.
5. Kulinich A.A. A model of agents (robots) command behavior: The cognitive approach // Automation and Remote Control. 2016. Vol. 77, № 3. P. 510-522.
6. Osipov G.S., Panov A.I., Chudova N. V. Behavior control as a function of consciousness. I. World model and goal setting // J. Comput. Syst. Sci. Int. 2014. Vol. 53, № 4. P. 517–529.
7. Vinogradov, A.N., Zhilyakova, L.Yu., Osipov, G.S. Dynamic intelligent systems: I. Knowledge representation and basic algorithms// Journal of Computer and Systems Sciences International. 2002. Vol. 41, № 6. P. 953–960.
8. Osipov G.S., Panov A.I., Chudova N. V. Behavior Control as a Function of Consciousness. II. Synthesis of a Behavior Plan // J. Comput. Syst. Sci. Int. 2015. Vol. 54, № 6. P. 882–896.
9. Kiselev G.A., Panov A.I. Sign-based Approach to the Task of Role Distribution in the Coalition of Cognitive Agents // SPIIRAS Proc. 2018. № 57. P. 161–187.
10. Panov A.I. Behavior Planning of Intelligent Agent with Sign World Model // Biol. Inspired Cogn. Archit. 2017. Vol. 19. P. 21–31.
11. Panov A.I. Algebraic Properties fo Recogniton Operators in Modeling Visual Perception of Dynamic Scenes // Proceedings of the International Conference IIP-10. 2014. P. 133.
12. Osipov G.S. Formulation of subject domain models: Part I. heterogeneous semantic nets// Soviet journal of computer and systems sciences. 1992. Vol. 30, № 2. P. 1–12.
13. Velichkovskij B.M. Geterarhiya kognitivnoj organizacii: proshloe, nastoyashchee i budushchee [Heterarchy of cognitive organization: past, present and future] // V knige: Sed'maya mezhdunarodnaya konferenciya po kognitivnoj nauke Tezisy dokladov. Otvetstvennye redaktory: Yu. I. Aleksandrov, K. V. Anohin. 2016. P. 194. (In Russian).
14. Kiselev G., Kovalev A., Panov A.I. Spatial reasoning and planning in sign-based world model // Artificial Intelligence / ed. Kuznetsov S., Osipov G.S., Stefanuk V. Springer International Publishing, 2018. P. 1–10.
15. Ermek A., Kiselev G., Panov A.I. Task and Spatial Planning by the Cognitive Agent with Human-like Knowledge Representation // Interactive Collaborative Robotics / ed. Ronzhin A., Rigoll G., Meshcheryakov R. Springer International Publishing, 2018. P. 1-12.
16. Kuznecova Yu.M. et al. Yazykovaya sistema kak regulyator planirovaniya povedeniya kognitivnyh agentov [Linguistic system as a regulator of behavior planning of cognitive agents] // Vos'maya mezhdunarodnaya konferenciya po kognitivnoj nauke: Tezisy dokladov. 2018. (In press) (In Russian).
17. George D., Hawkins J. Towards a mathematical theory of cortical micro-circuits // PLoS Comput. Biol. 2009. Vol. 5, № 10. P. e1000532.
18. Hawkins J., Ahmad S., Cui Y. A Theory of How Columns in the Neocortex Enable Learning the Structure of the World // Front. Neural Circuits. 2017. Vol. 11. P. 1–18.
19. Panov A.I., Skrynnik A. Automatic formation of the structure of abstract machines in hierarchical reinforcement learning with state clustering // ICML/IJCAI Work. Plan. Learn. 2018.
20. Finn V.K. On the definition of empirical regularities by the JSM method for the automatic generation of hypotheses // Sci. Tech. Inf. Process. 2012. Vol. 49, № 5. P. 261–267.
21. Suzuki N. et al. Learning motion patterns and anomaly detection by human trajectory analysis //Systems, Man and Cybernetics, 2007. ISIC. IEEE International Conference on. – IEEE, 2007. – C. 498-503.
22. Kratz L., Nishino K. Anomaly detection in extremely crowded scenes using spatio-temporal motion pattern models //Computer Vision and Pattern Recognition, 2009. CVPR 2009. IEEE Conference on. – IEEE, 2009. – C. 1446-1453.
23. Li W., Mahadevan V., Vasconcelos N. Anomaly detection and localization in crowded scenes //IEEE transactions on pattern analysis and machine intelligence. – 2014. – T. 36. – №. 1. – C. 18-32.
24. Ren L. et al. A data-driven approach to quantifying natural human motion //ACM Transactions on Graphics (TOG). – ACM, 2005. – T. 24. – №. 3. – C. 1090-1097.
25. Bütepage J. et al. Deep representation learning for human motion prediction and classification //IEEE Conference on Computer Vision and Pattern Recognition (CVPR). – 2017. – C. 2017.
26. Du Y., Wang W., Wang L. Hierarchical recurrent neural network for skeleton based action recognition //Proceedings of the IEEE conference on computer vision and pattern recognition. – 2015. – C. 1110-1118.
27. CMU Graphics Lab. Carnegie Mellon University Motion Capture Database. 2003. url: [http://http://mocap.cs.cmu.edu/](http://mocap.cs.cmu.edu/).
28. Daylidyonok I., Frolenkova A., Panov A.I. Extended Hierarchical Temporal Memory for Motion Anomaly Detection // Biologically Inspired Cognitive Architectures 2018 / ed. Samsonovich A. V. Springer International Publishing, 2018. P. 69–81.

Panov Aleksandr I. PhD in Computer Science. Senior Researcher in Federal Research Centre "Informatics and Control" of Russian Academy of Sciences (Moscow), deputy head of laboratory in Moscow Institute of Physics and Technology (State University).
E-mail: pan@isa.ru