

Интеллектуальная система полного разума с интуицией

В. М. Колешко, Е. А. Воробей

Впервые изложена фундаментальная методология интеллектуальных систем полного разума с интуицией для широкого практического назначения, способных динамически и эффективно самообучаться, самоорганизовываться и быстро принимать решения. Представлены технические решения практической реализации интеллектуальной системы с полным разумом и интуицией.

Ключевые слова: интеллектуальная система, полный разум, интуиция, обучение, распознавание информационных образов.

Введение

Современный технический уровень развития связан с интеллектуальными системами — автоматическими или автоматизированными системами с внешним и внутренним «очувствлением», основанных на использовании искусственного интеллекта и обладающих следующими свойствами [1–3]:

- самообучением — способностью не только выполнять заложенные в ней и встроенные функции и программы, но также обладать способностью адаптировать их в соответствие с назначенными задачами;
- самоорганизацией — способностью изменять свою структуру и архитектуру в соответствие с назначенными задачами или с целью улучшения в процессе самообучения, самодиагностики и самосохранения;

- способностью решать проблемы, для которых не существует стандартных методов и / или алгоритмов решений или таковые не известны.

Интеллектуальные приборы, машины и системы разных размеров, форм, функционального назначения имеют преимущества в портативности, неинвазивности, низкой стоимости, быстром принятии решений для поддержки управленческих действий, обладают способностью к обучению и расширяют возможности «осенсорирования» и «омоторивания» всех систем и техпроцессов во всех областях жизнедеятельности человека.

Цель и постановка задачи

Целью работы является представление интеллектуальной системы полного разума с интуицией, отличающейся динамическим самообучением и быстрой самоорганизацией для прогнозирования количественных и качественных характеристик информационного образа исследуемого объекта. Показаны практические результаты разработки интеллектуальной системы полного разума с интуицией для динамического прогнозирования широкого спектра свойств новых состояний исследуемых твердых, жидких, газообразных и гетерогенных сред с установлением степени принадлежности данных информационных образов к ранее известным интеллектуальной системе классам.

1. Модель технонейрона

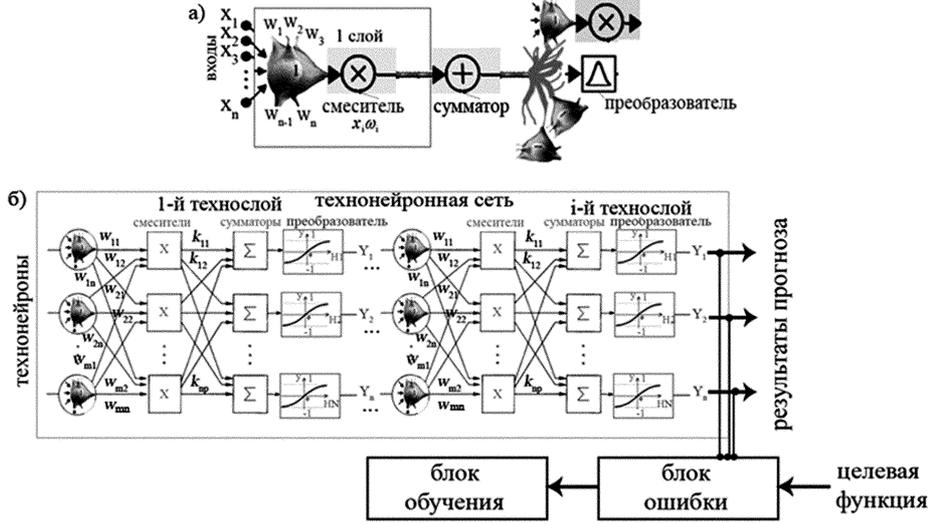
Для реализации традиционного подхода функционирования технонейрона в нейронной сети рассмотрим работу каждого его элемента управления (рис. 1) [4–6]:

- $x_1, x_2 \dots x_n$ — входы технонейрона (технодендриты), аналогами которых в бионейроне мозга служат рецепторы (сенсорные бионейроны) для восприятия сенсорной информации или потенциалы действия биосинапсов от других бионейронов с задержкой b_0 ;

- $w_1, w_2 \dots w_n$ — весовые коэффициенты технодендритов технонейрона, которые определяют свойства биодендритов, например, их электрическую проводимость или длину в бионейроне;
- $x_1 \cdot w_1; x_2 \cdot w_2; x_3 \cdot w_3 \dots x_n \cdot w_n$ — смеситель, который выполняет смешивание сигналов от технодендритов в смесителе путем попарного перемножения поступающей сенсорной информации с весовыми коэффициентами технодендритов и аналогом которого в бионейроне выступает центральное тело нейрона («мозг» нейрона);
- $H1 = x_1 \cdot w_1 + x_2 \cdot w_2 + x_3 \cdot w_3 + \dots + x_n \cdot w_n + b_0$ — сумматор, который осуществляет сложение полученных перемноженных величин и аналогом которого в бионейроне выступает спайк, распространяющийся по биоаксону;
- $\varphi(y) = 1/(1 + e^{-2 \cdot H1})$ — преобразователь в виде линейной или нелинейной функции активации получаемых значений на сумматоре, аналогом которого в бионейроне служат пузырьки в окончаниях биосинапсов с выделившимися в синаптической щели из них нейромедиаторами, а также потенциал покоя бионейрона. При этом целевая функция y может принимать, например, два состояния, которые соответствуют минус единице или плюс единице.

Полученная информация от преобразователя поступает к технодендритам других технонейронов. Если, например, у технонейрона имеется два технодендрита с потенциалом действия на каждом входе $P_1 = x_1$ и $P_2 = x_2$, а весовые коэффициенты технодендритов $w_1 = 0,89167$, $w_2 = -0,21693$, причем задержка поступления сигналов $b_0 = -0,25$, то уравнение преобразования информации технонейроном $H1$ будет представлено в виде $H1 = -0,25 + 0,89167 \cdot P_1 + (-0,21693) \cdot P_2$.

Для n технонейронов обработка сенсорной информации происходит в технонейронной сети, причем различные технонейроны имеют свои индивидуальные смесители, сумматоры и преобразователи. Обучение многослойной технонейронной сети осуществляется в большинстве случаев по методу обратного распространения ошибки с минимизацией градиента ошибки. В этом случае на каждый технонейрон первого технослоя МГИНС подаются j -сенсорный информационный образ для обучения и определяют прогнозируемое количественное це-



а — структурная схема технейрона; б — технейронная сеть

Рис. 1. Традиционная модель обучения.

левое значение на выходе МГИНС, рассчитывают $\delta_j^{(n)}$ и Δw_{ij} для всех технослоев МГИНС, корректируют весовые коэффициенты технослоев $w_{ij}^{(l)}(q) = w_{ij}^{(l)}(q-1) + \Delta w_{ij}^{(l)}(q)$ (q — этап изменения весовых коэффициентов технейронов МГИНС) и выполняют вышеуказанные действия для всех сенсорных информационных образов [7]. Все выходы скрытых технослоев находятся в полносвязном взаимодействии с последующими технослоями МГИНС:

$$T = \frac{1}{2} \cdot \sum_{j=1}^n (c_j - s_j)^2, \quad (1)$$

$$\begin{aligned} \Delta w_{ij} &= -\varepsilon \cdot \frac{\partial T}{\partial w_{ij}} = -\varepsilon \cdot \frac{\partial T}{\partial c_j} \cdot \frac{\partial c_j}{\partial e_j} \cdot \frac{\partial e_j}{\partial w_{ij}} = \\ &= -\varepsilon \cdot \frac{\partial T}{\partial c_j} \cdot \frac{\partial c_j}{\partial e_j} \cdot k_i^l = -\varepsilon \cdot \delta_j^{(l)} \cdot k_i^l, \end{aligned} \quad (2)$$

$$\begin{aligned} \delta_j^{(l)} &= \frac{\partial T}{\partial c_j} \cdot \frac{dc_j}{de_j} = \left[\sum_h \delta_j^{(l+1)} \cdot w_{jh}^{(l+1)} \right] \cdot \frac{dc_j}{de_j} = \\ &= (c_i^l - s_i) \cdot \frac{dc_i}{de_i} = (c_i^l - s_i) \cdot c'_i(e_i), \quad (3) \end{aligned}$$

где T — ошибка обучения на сенсорных информационных образах, c_j — количественное значение j -го выхода МГИНС (полученное выходное значение для j -го сенсорного информационного образа), s_j — количественное целевое значение j -го выхода МГИНС (известное целевое значение для j -го сенсорного информационного образа), j — номер технонейрона в выходном слое МГИНС (сенсорного информационного образа для обучения), n — общее количество технонейронов в выходном слое МГИНС (сенсорных информационных образов для обучения), ε — параметр, характеризующий скорость обучения ($\varepsilon = 0,5$), e_j — взвешенная сумма входных сигналов (сумма количественных значений главных компонент для сенсорного информационного образа), k_i — количественное значение i -го выхода технонейрона МГИНС, $\delta_j^{(l)}$ — вспомогательная переменная, n — номер технослоя МГИНС, i — номер выхода технонейрона МГИНС, $w_{ij}^{(z)}$ — весовой коэффициент технонейрона в z -технослое МГИНС, l — количество технослоев МГИНС, $c'_i(e_i)$ для выходного слоя — производная функции активации технонейрона, h — количество технонейронов в технослое МГИНС.

Полученная на выходе величина сравнивается, например, с задаваемым порогом 0,5 для определения принадлежности входного образа к одному из двух известных классов.

2. Полный разум с интуицией

Известны способы распознавания данных, включающие анализы главных и независимых компонент, метод экспертных оценок, эвристическое, корреляционное и регрессивное прогнозирование, экстраполяционный и морфологический подходы, методы структурной аналогии, построение графов принятия решений и фазовых портретов, факторный, имитационный, нейросетевой, стохастический и интеллектуальный анализы [4, 6–9]. Интеллектуальные подходы в основ-

ном основаны на регулировании активности нейроподобной сети с обратным распространением ошибки в виду ее удобной аппаратной реализации и быстрого самообучения и для поиска направления снижения градиента ошибки предполагают задание ограниченного количества эпох, минимальной ошибки обучения, случайно или равномерно определенных параметров обучения. Поэтому такие подходы приводят к некачественному принятию решения и длительному его поиску. Вероятностные сети имеют только три слоя, единственный управляемый параметр обучения (отклонение гауссовой функции) и включают последовательное суммирование откликов элементов с гауссовскими функциями.

Полный разум с интуицией сохраняет все преимущества известных разработанных интеллектуальных подходов: обработка большого количества данных и их признаков, коррекция синаптических весов, применение улучшенных нейросетевых иерархических архитектур, минимизация вероятности ошибок, ускорение вычислительных расчетов. При этом предлагаемый подход в разработке интеллектуальной системы полного разума с интуицией отличается улучшенным извлечением знаний от всех известных методов, поскольку:

- имеет низкую чувствительностью к помехам и шумам за счет предварительной обработки данных с нормированием, устранением пропусков значений, их случайного искажения, подмены или утраты;
- осуществляет эффективное обучение, самообучение, дообучение, самодиагностику и распознавание на сенсорных информационных образах с учетом сочетания признаков различной модальности в многомерном пространстве;
- обладает более высокой производительностью и высокоориентированной динамической самоорганизацией онлайн-обработки информации и качества прогнозирования для обнаружения глобального максимума точности за счет применения многоядерных методов параллельного программирования;
- имеет улучшенный встроенный интеллект с отличающимся процессом обучения для различных данных, с динамической оптимизацией своей внутренней структуры путем задания топологии нейросетевой связи, оптимального количества слоев, техно-

нейронов в каждом слое, их весовых коэффициентов, функций активации нейронов;

- выдает более достоверное решение о вероятности прогнозируемого им целевого класса при обучении и распознавании за счет того, что результат классификации не представлен строгой принадлежностью объекта к одному из классов при задании отдельных пороговых значений;
- анализирует исходные данные с любым информационным содержанием для прогнозирования в широком спектре задач;
- узнавает не только заданные для ее распознавания, но и новые целевые классы.

Полный разум — это гипер-метаэвристическая многокомпонентная гиперсферная интеллектуальная нейронная сеть (МГИНС) с логическим и интуитивным ускоренным распознаванием сенсорных информационных образов, беспроводных сенсорных систем и сетей при классической метрологии. *Сенсорный информационный образ* — описание любого объекта в многомерном пространстве, включающем информацию от всех описывающих его сенсорных признаков. *Метаэвристика* — метод улучшенной оптимизации при принятии суб-и оптимальных решений отдельным алгоритмом эвристического поиска. *Гиперэвристика* — метод универсальной оптимизации при выборе оптимальных решений из нескольких различных алгоритмов метаэвристического поиска. *Эвристика* — знания, приобретаемые в процессе интуитивного принятия решений. *Интуиция* — способность интеллектуальной системы чувствовать уже имеющиеся логические цепочки связанной информации и моментально находить ответ на поставленный ей вопрос.

Уникальностью подхода полного разума и интуиции является использование сенсорных информационных образов и метаэвристической многокомпонентной гиперсферной интеллектуальной нейронной сети. Полный разум разработанной системы основан на работе головного мозга человека с левым и правым его полушариями, поэтому интеллектуальная система способна мыслить интуитивно и логически. Ряд электронных блоков выполняют функции левого полушария, то есть самоорганизующегося гипер-метаэвристического распознавания

информационных образов, и правого полушария, то есть интуитивно-прогнозирования на основе ранее полученных знаний. Чтобы придать сенсорам разум, на основе самоорганизующейся МГИНС проводится обучение на количественных данных информационных сенсорных образов. Обучившись, интеллектуальная система способна для неизвестного образа объекта быстро определить сходство с известными ей состояниями исследуемого объекта, а это и есть ее интуиция. Чем она выше, тем более идентичны сенсорные информационные образы и исследуемые объекты, а значит и не требуется дополнительное проведение дорогостоящих и длительных измерений для количественного определения состава неизвестной среды объекта (рис. 2).

МГИНС с интуицией выполняет следующие задачи [8]:

Задача 1. Формирование функционального информационного образа (*блок 1*) по результатам измерений сенсорами, нормирования полученных данных для обеспечения равноценности вкладов сенсорных признаков, последующего проведения сингулярного разложения для получения собственных векторов с наибольшими собственными значениями, соответствующих максимальной дисперсии исходной выборки (главные компоненты) и отображение информационных образов в виде карт-знаний в многокомпонентном пространстве для визуального отслеживания их функциональности и динамики поведения (*блок 10*).

При исследовании любой среды выходные сигналы сенсоров в совокупности или отдельно для каждого сенсора математически можно представить одной количественной величиной — сенсорным информационным образом. Сенсорные информационные сигналы удобно обрабатывать и распознавать микропроцессорами подобно тому, как это делает мозг человека. Для получения количественных значений сенсорных информационных образов автоматически осуществляют линейные ортогональные преобразования нормированных входных сенсорных данных с расчетом собственных векторов с наибольшими собственными значениями [9]:

$$\Gamma K_{s=\overline{1,j}} = \sum_{i=1}^j w_{is} \cdot t_i, \quad (4)$$

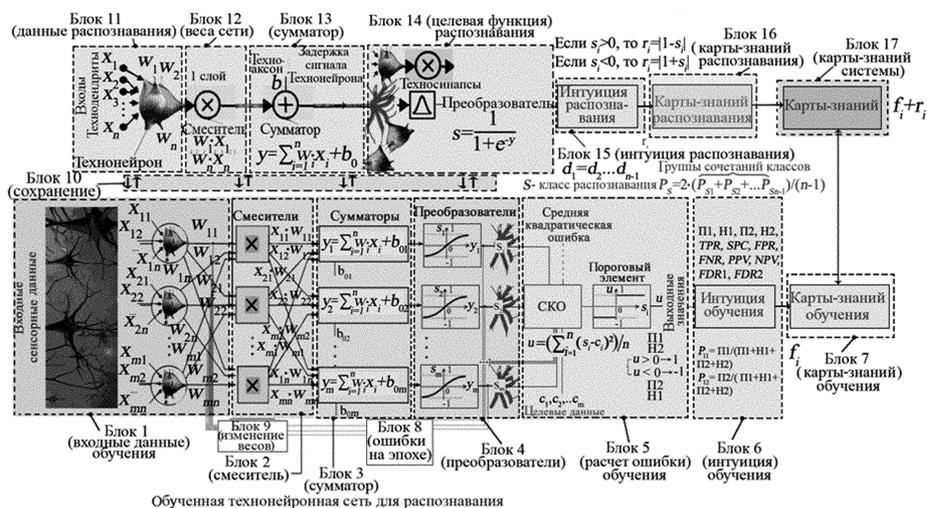


Рис. 2. Модель обучения с интуицией. Блок 1 — входные сенсорные данные; блок 2 — смеситель $\{x_1w_1, x_2w_2, x_3w_3, \dots, x_nw_n\}$; блок 3 — сумматор $x_1w_1 + x_2w_2 + x_3w_3 + \dots + x_nw_n + b_0$ с учетом общей величины задержки b_0 ; блок 4 — нелинейный преобразователь; блок 5 — расчет ошибки на этапе обучения; блок 6 — расчет интуиции обучения; блок 7 — построение карт-знаний информационных образов; блок 8 — расчет ошибки самообучения; блок 9 — изменение весовых коэффициентов; блок 10 — сохранение информации; блок 11 — поступление новых данных; блоки 12, 13, 14 — распознавание информационных образов (умножитель, сумматор, нелинейный преобразователь), блок 15 — интуиция распознавания образов с вероятностной принадлежностью к одному из известных классов; блок 16 — построение карты-знаний распознавания; блок 17 — построение карты-знаний МГИНС; блок 18 — расчет оптимального размещения центроидов в многомерном пространстве признаков; блок 19 — построение уравнений гиперсфер; блок 20 — построение уравнений гиперплоскостей.

где $\{ГК_v\}$ — новая система координат, полученная ортонормированными линейными комбинациями исходного пространства $\{t_j\}$ сенсорных признаков $j (j > 1)$, t_i — значение признака i после предобработки, $w_{i=1,v}$ — собственные векторы ковариационной матрицы $K = T' \cdot T$

с входными нормированными сенсорными данными T , где T' — транспонированная матрица.

При последовательном выделении главных компонент формируются факторы с уменьшающейся объясненной дисперсией. Общая дисперсия главных компонент равна числу сенсорных признаков v , если первоначально каждая переменная имела дисперсию равную 1, и ограничена порогом 98,9% для объяснения большей части общей дисперсии исходных сенсорных признаков.

Расчет собственных векторов и собственных значений матрицы K осуществляется путем ее сингулярного разложения на множители в виде:

$$K = N \cdot D \cdot N', \quad (5)$$

$$Y = T \cdot N, \quad (6)$$

где D — диагональная матрица с упорядоченными по диагонали по убыванию собственными числами — значения дисперсий главных компонент, N — ортогональная матрица собственных векторов матрицы K , которая позволяет перейти к главным компонентам, Y — образы исходных данных в пространстве новых компонент $\{ГК_v\}$.

Электронный разум МГИНС проводит расчет оптимального количества кластеров обучения в следующем виде:

$$F_0 = \sum_{i=1}^n \left(\sum_{j=1}^{k_n} \sqrt{\frac{\sum_{t=1}^s (x_{tji} - c_{ti})^2}{s}} \right) / k_n / n \rightarrow \text{минимум}, \quad (7)$$

$$F_1 = 2 \cdot \left(\sum_{i=1}^n \sum_{j=i+1}^n \sqrt{\frac{\sum_{t=1}^s (c_{ti} - c_{tj})^2}{s}} \right) / (n^2 - n) \rightarrow \text{максимум}, \quad (8)$$

$$F = \frac{F_1}{F_0} \rightarrow \text{максимум}, \quad (9)$$

где F_0 — средняя величина внутрикластерного расстояния между образцами, рассчитанная для всех центров кластеров n и с принадлежностью к каждому центру кластера c_i информационных образов k_n в s -многомерном сенсорном пространстве, F_1 — среднее межкластерное

расстояние между всеми n кластерами, F — функционал кластеризации, который при $F > 1$ приводит к размытию информационных образов в многомерном пространстве и длительному самообучению.

Этапы выполнения первой задачи наглядно представлены на рис. 3.

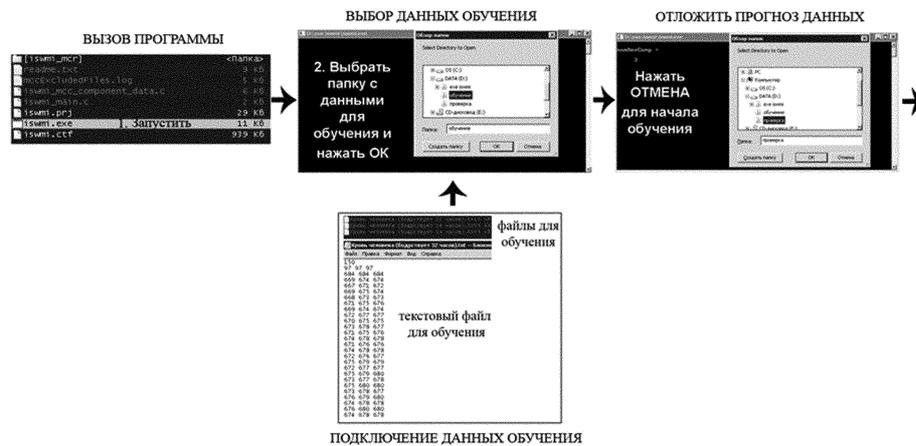


Рис. 3. Реализация задачи 1.

Предлагаемый способ расчета количества кластеров посредством функции (7) минимизирует недостатки иерархической и неиерархической кластеризации и имеет следующие преимущества по сравнению с известными подходами [10] (метод k -средних, агломеративные и дивизимные алгоритмы, кластеризация Гюстафсона-Кесселя, метод корреляционных плеяд, FOREL и др.):

- формирование компактных и вытянутых кластеров минимального количества, снижение чувствительности к шуму, случайным искажениям и пропускам данным, повышение робастности, эффективности полученных решений и скорости сходимости метода, возможность описания пересекающихся кластеров сенсорных информационных образов любого нетипичного представления с высокой внутренней однородностью и внешней изолированностью, универсальность использования для различных метрик, малая вычислительная сложность, высокая производительность обучения на большом наборе данных;

- максимизация точности обучения и распознавания, исключение локального минимума ошибки классификации, повышение самоорганизации МГИНС за счет динамического управления ее архитектурой: при обучении «без учителя» генерируются новые обучающиеся слои, а обучение «с учителем» задает технонейронам весовые коэффициенты.

Задача 2. Обучение на информационных сенсорных образах путем построения уравнений гиперплоскостей и гиперсфер (блок 2) с расчетом псевдообратных матриц и использования метода обратного распространения ошибки (блоки 3, 4, 5, 8, 9) для каждой пары сочетаний выходных классов информационных образов.

Сущность обучения, например, первого слоя интеллектуальной нейронной сети заключается в построении разделяющей гиперплоскости $\Gamma\Pi_{n,k}$ в ограниченном многокомпонентном пространстве ГК N (N — количество отобранных главных компонент, k и n — номера распознаваемых выходных классов), эффективно разделяющей n -й и k -й классы информационных образов среды. Проекция данной гиперплоскости в пространстве компонент ГК1 и ГК2 имеет вид $\Gamma\Pi_{k,n}$: $b_0 + \text{ГК1} \cdot w_1 + \text{ГК2} \cdot w_2 = 0$. Весовые коэффициенты w_i ($i = 0, 1, 2$) для всех $N \cdot (N - 1) / 2$ сочетаний главных компонент задаются в первом слое интеллектуальной нейронной сети. Для сочетания главных компонент ГК1 и ГК2 набор весовых коэффициентов будет представлен в виде $[b_0 w_1 w_2]$ и рассчитывается как:

$$W = X^n \cdot Y, \quad (10)$$

где Y — вектор решений целевой функции $[-11]$, $W = [b_0; w_1; w_2]$ — весовые коэффициенты для расчета, причем для вычисления b_0 необходимо, чтобы первый столбец матрицы X состоял из единиц, X^n — псевдообратная матрица для двух признаков сенсорных данных.

Среднее время обучения МГИНС на 100 информационных сенсорных образах с использованием двухъядерной вычислительной системы (процессор Intel Core 2 Duo T8300 2,4 ГГц, 4 Гб ОЗУ, Windows 7, 15,17 Гфлопс, 32-хразрядная операционная система) составляет 1 с. Этапы выполнения второй задачи наглядно представлены на рис. 4.

МГИНС параллельно проводит обучение на представленных ей информационных образах, результаты которого сохраняются в от-

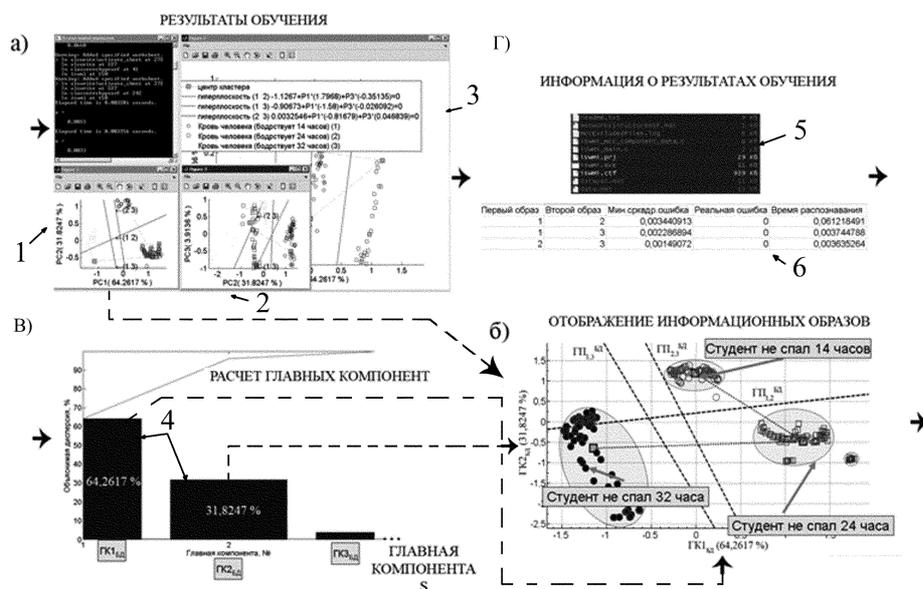


Рис. 4. Реализация задачи 2.

дельный файл программы с расширением .xls, а затем выполняется отображение информационных образов в пространстве отобранных главных компонент, полученных по формуле (4). На рис. 4а наглядно отображены результаты обучения МГИНС, причем обозначения 1, 2 и 3 описывают проекции всех информационных образов на главные компоненты ГК1 и ГК2, ГК2 и ГК3, ГК1 и ГК3. Например, на рис. 4б представлены проекции информационных образов крови для трех бодрствующих состояний студента в экзаменационную сессию (распознаваемые классы) в пространстве главных компонент ГК1 и ГК2 с разделяющими проекциями гиперплоскостей, весовые коэффициенты которых получены по формуле (10). Для каждой главной компоненты рассчитана объясненная дисперсия (рис. 4в) в процентном соотношении от общей дисперсии главных компонент. Например, для главной компоненты ГК1 она равна 64,2617%, а для главной компоненты ГК2 — 31,8247% (обозначение 4). После обучения МГИНС автоматически открывает файл, показанный на рис. 4г через обозначение 5, который содержит информацию о времени и ошибках обучения (обозначение 6) для каждого сочетания распознаваемых классов.

Задача 3. Самоорганизация и интуиция обучения для каждого исследуемого объекта с автоматическим определением оптимальной динамической технотруктуры нейронной сети (блоки 18, 19, 20) с эффективным подбором количества скрытых технослоев и технонейронов (т-нейроны) в каждом технослое, техносинаптических связей, функции активации т-нейронов, расчетом весовых коэффициентов индивидуальной значимости т-нейронов за счет минимизации внутрикластерной суммы расстояний объектов кластера до его образа центроида с максимизацией отношения среднего межкластерного расстояния к среднему внутрикластерному расстоянию информационных образов, запоминанием новых информационных сенсорных образов при обучении и расчетом интуиции обучения (блок 6).

Интуиция обучения МГИНС основана на принадлежности новых образов к ранее известным или неизвестным классам и, например, для двух классов имеет вид:

$$U1 = (П1 + П2)/(П1 + П2 + Н1 + Н2), \quad (11)$$

где $U1$ — уверенность распознавания образов, $П1$ (TP) — количество образов 1-го класса, которые отнесены к классу 1, $П2$ (TN) — количество образов 2-го класса, которые отнесены к классу 2, $Н1$ (FP) — количество образов 1-го класса, которые отнесены к классу 2, $Н2$ (FN) — количество образов 2-го класса, которые отнесены к классу 1. Интуиция МГИНС характеризуется чувствительностью $TPR = П1/(П1 + Н2)$, $SPC = П2/(П2 + Н1)$, $FPR = Н1/(П2 + Н1)$, $FNR = Н2/(П1 + Н2)$, уверенностью $PPV = П1/(П1 + Н1)$, $NPV = П2/(П2 + Н2)$ и предсказанием $FDR1 = Н1/(Н1 + П1)$, $FDR2 = Н2/(Н2 + П2)$.

Для каждого из N сочетаний, например, класса 1 интуиция обучения МГИНС:

$$P_1 = (П1_1/(П1_1+Н1_1+П2_1+Н2_1) + \dots + П1_n/(П1_n+Н1_n+П2_n+Н2_n))/N. \quad (12)$$

Таким образом, этапы выполнения третьей задачи наглядно представлены на рис. 5.

Задача 4. Интуитивное распознавание новых информационных сенсорных образов (блоки 11,12,13,14,15) с расчетом ошибок первого и второго рода при отнесении каждого нового информа-



Рис. 5. Реализация задачи 3.

ционного образа к ранее известным при обучении интеллектуальной нейронной сети выходным классам отдельно для каждой пары их сочетаний. Время интуитивного распознавания МГИНС информационного сенсорного образа составляет порядка 0,01 с.

Например, после обучения МГИНС на k -м и n -м выходных классах возможно установить, насколько близки новые и неизвестные ей информационные образы s класса к выходным классам, на которых она обучилась. Для этого входные данные новой среды, полученные по результатам измерений, например, сенсорами нормируются и преобразовываются в информационные образы, расположенные в пространстве информационных образов k -го и n -го выходных классов для обучения. При сравнении близости информационных образов s -класса к известным образам k -го и n -го классов в первом слое интеллектуальной нейронной сети определяется положение новых информационных образов относительно разделяющей гиперплоскости $\Gamma_{n,k}$ в многокомпонентном пространстве GKN . В результате рассчитывается вероятность отнесения информационных образов s -го класса среды к k -му классу (P_k) и к n -му классу (P_n). Этапы выполнения четвертой задачи наглядно представлены на рис. 6.

Например, с целью поддержки мониторинга бодрствования студента для определения его функциональных состояний бодрствования во время сессии для новых данных неинвазивного исследования

его крови электронным глазом (е-глазом) [1–3] рассчитана интуиция к известным состояниям его информационных образов крови, на которых была обучена разработанная интеллектуальная система МГИНС:

- для состояния № 1 ($F_1 = 14$ ч время бодрствования) интуиция распознавания информационных образов крови равна $P_1 = 86,95641\%$;
- для состояния № 2 ($F_2 = 24$ ч время бодрствования) интуиция распознавания информационных образов крови равна $P_2 = 68,17584\%$;
- для состояния № 3 ($F_3 = 32$ часа время бодрствования) интуиция распознавания информационных образов крови равна $P_3 = 45,49027\%$.

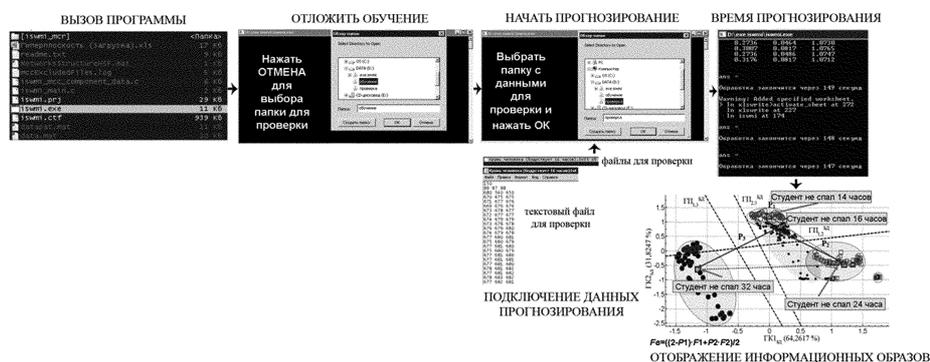


Рис. 6. Реализация задачи 4.

Задача 5. Интуитивное прогнозирование количественных значений свойств и статистических данных (блок 16) объекта неизвестного интеллектуальной системе на основании только информации, представленной для обучения с известными количественными данными, и построенных на основе статистических данных для известных классов регрессионных зависимостей свойств, измеренных с использованием существующих длительных, трудозатратных, сложных и дорогостоящих методов. Причем для высокоточного прогнозирования свойств сред необходимо, чтобы обучение проводилось на

информационных образах классов s и k , которые наиболее сильно отличаются друг от друга. Для выполнения интуитивного прогнозирования вместо F_k и F_n используются количественные величины свойств сред, которые были известны ранее по результатам их исследований и измерений известными методами. Если, например, s -й класс включает в себя свойства F_k для k -го и F_n для n -го классов в соответствие с полученными значениями вероятности P_k и P_n , тогда модель расчета свойств F_s s -го класса может быть представлена через усреднение свойств F_k и F_n в виде $F_s = (P_k \cdot F_k + P_n \cdot F_n)/2$.

Например, с целью поддержки мониторинга бодрствования студента для определения времени, в течение которого он не спал во время сессии, поскольку $P_3 < P_2 < P_1$, то для улучшенного интуитивного прогнозирования за счет исключения зашумленных информационных сенсорных образов крови целесообразно использовать наибольшие значения интуиции распознавания P_1 и P_2 . Модель для расчета времени бодрствования F_b для нового распознаваемого класса информационных образов крови через усреднение свойств F_1, F_2 записывается в виде $F_b = (P_1 \cdot F_1 + P_2 \cdot F_2)/2$.

Как видно из рис. 4б, новые информационные образы расположены между информационными образами, соответствующих состояниям № 1 и № 2. Поскольку при изменении состояний от № 1 к № 3 время бодрствования увеличивается, то целесообразно вместо интуиции P_1 использовать значение интуиции 2 – P_1 , тогда $F_b = ((2 - P_1) \cdot F_1 + P_2 \cdot F_2)/2$. Подставив численные значения, получим $F_b = ((2 - 0,8695641) \cdot 14 + 0,6817584 \cdot 24)/2 = 16,0942$ (ч).

Сравнивая прогнозируемые результаты расчета прошедшего времени F_b с истинным результатом бодрствования студента, равном 16 часам, рассчитана высокая достоверность интуиции прогнозирования, которая для количественного определения времени бодрствования студента равна 99,4112%. Интуитивное прогнозирование возможно только при наличии экспериментальных данных измерения времени бодрствования для обучения МГИНС. Решение пятой задачи наглядно представлено на рис. 7.

Задача 6. Построение карт-знаний обучения и распознавания информационных сенсорных образов, и интеллектуаль-



Рис. 7. Реализация задачи 5.

ной системы для отображения разума (рис. 8) МГИНС с интуицией (блоки 7, 16, 17).

В общем виде уравнение любой проекции разделяющей гиперплоскости в двухмерном пространстве может быть представлено как $b_0 + w_1 \cdot x_1 + w_2 \cdot x_2 = 0$, где b_0, w_1, w_2 — весовые коэффициенты, а x_1, x_2 — признаки исследуемого пространства. Проекция разделяющей гиперплоскости, например, $ГП_{1,2}^{БД}$, представленная уравнением $0,21206 + ГК1_{БД} \cdot 0,23277 + ГК2_{БД} \cdot (-0,97102) = 0$, оптимально разграничивает два класса информационных образов крови студента, которые соответствуют бодрствованию 14 часов и сутки. Гиперплоскость $ГП_{1,2}^{БД}$ генерируется в пространстве отобранных $e = 3$ главных компонент, а одна из ее проекций на рис. 8 показана в пространстве первой и второй главной компонент $ГК1_{БД}$ и $ГК2_{БД}$. При этом весовые коэффициенты $W_{12} = [b_{12}^0 w_{12}^1 w_{12}^2]$ для данной проекции равны $W_{12} = [0,212060,23277 - 0,97102]$, сохраняются в соответствующих технослоях и предназначены для распознавания информационных образов интеллектуальной системой МГИНС. Совокупность полученных матриц W для всех рассматриваемых сочетаний по двум из трех главных компонент позволяет задать весовые коэффициенты, например, для первого слоя МГИНС. Нелинейное преобразование информаци-

онных образов после каждого нового слоя продолжается, пока не будет достигнута самоорганизация МГИНС в соответствии с формулами (7–9). Информативность каждой главной компоненты при решении задачи 2 описывается процентом от кумулятивной дисперсии факторов, которая рассчитывается как сумма их всех объяснимых дисперсий. Можно увидеть, что первая компонента $ГК1_{БД}$ объясняет 64,2617%, вторая компонента $ГК2_{НТ}$ — 31,8247% общей дисперсии информационных образов крови студента. Уравнения разделяющих гиперплоскостей (ГП), построенных в пространстве главных компонент ($ГК_{БД}$), для случая определения времени бодрствования (БД) студента на рис. 8 имеют следующее представление:

$$\begin{aligned} ГП_{1,2}^{БД} &: 0,21206 + ГК1_{БД} \cdot 0,23277 + ГК2_{БД} \cdot (-0,97102) = 0, \\ ГП_{1,3}^{БД} &: -0,58867 + ГК1_{БД} \cdot (-1,1725) + ГК2_{БД} \cdot (-0,32207) = 0, \\ ГП_{2,3}^{БД} &: -0,085808 + ГК1_{БД} \cdot (-0,81121) + ГК2_{БД} \cdot (-0,19325) = 0. \end{aligned}$$

Условные обозначения на рис. 8а, 8б определяются следующим образом: \blacksquare — центр кластера; $---$ — гиперплоскость; \circ — кровь студента, бодрствующего 14 часов; \square — кровь студента, бодрствующего сутки; \bullet — кровь студента, бодрствующего 32 часа; \bullet — кровь студента, время бодрствования которого нужно определить (априори оно равно 16 часам).

Для случая прогнозирования, в частности, времени бодрствования студента МГИНС имеет важное практическое назначение, связанное с сбалансированной поддержкой трудовой, когнитивной и творческой активности для успешного обучения студентов и лучшего усвоения ими знаний в период обучения в университете. Благодаря интуиции МГИНС путем выдачи соответствующих рекомендаций при недосыпании студент в состоянии сам предотвратить свою депрессию, раздражительность, усталость, голод и ожирение, гормональные изменения, улучшить обмен веществ, иммунитет, работоспособность, учебную работу и спортивные достижения. Для преподавателей МГИНС дает возможность оптимизировать процесс усвоения знаний студентами, контролировать здоровье студентов, обеспечить безопасность проведения лабораторных занятий и значительно повысить успеваемость студентов учебной группы. Другие практические примеры приведены в [1–3, 8].

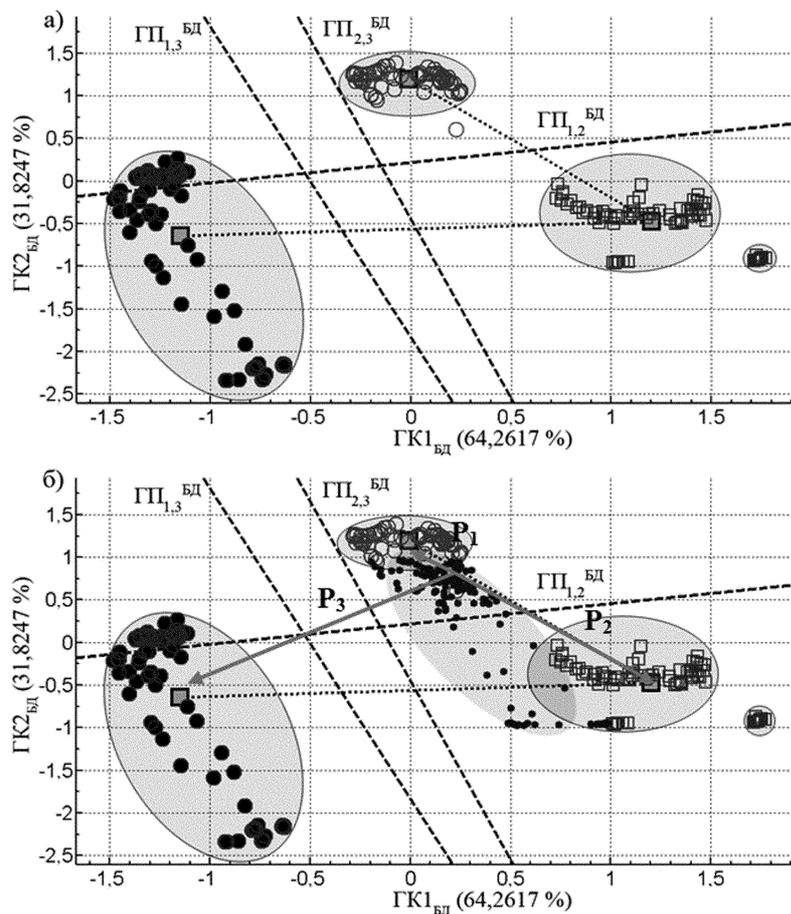


Рис. 8. Карта-знаний информационных образов крови бодрствующего студента, соответствующая решению задачи 6.

3. Вывод

Изложена фундаментальная методология и технические решения интеллектуальной системы полного разума с интуицией, позволяющая оперировать семантическими и прагматическими свойствами интеллектуальной информации и знаниями и приблизиться к пониманию естественного интеллекта. По качеству прогнозирования МГИНС в 5–10 раз и до 650 раз по производительности эффектив-

нее известных методов классификации и распознавания образов с использованием вероятностных нейронных сетей и нейронных сетей с обратным распространением ошибки. МГИНС рекомендуется использовать в портативных мобильных устройствах, в том числе в смартфонах, коммуникаторах, айподах и др.

Список литературы

- [1] Koleshko, V.M. Intelligent systems / V.M. Koleshko. — InTech, 2012. — IF=1,765 [Electronic resource]. — Mode of access: <http://www.intechopen.com/books/intelligent-systems>.
- [2] Колешко, В.М. Мобильные телефоны, смартфоны и старение организма / В.М. Колешко, Е.А. Воробей, Н.А. Хмурович; под общ. ред. В.М. Колешко. — Минск: Техническая литература, 2011. — IF=0,864 [Электронный ресурс]. — Режим доступа: <http://www.youtube.com/watch?v=AMQssY8SgNI>.
- [3] Колешко, В.М. Интеллектуальная система распознавания информационных образов наноматериалов / В.М. Колешко, Е.А. Воробей, Е.Л. Прудникова // Нано- и микросистемная техника. — М., 2013. — № 1 (150). — С. 9–14 [Электронный ресурс]. — Режим доступа: <http://elibrary.ru/item.asp?id=18442880>.
- [4] Осовский, С. Нейронные сети для обработки информации / С. Осовский. — М.: Финансы и статистика, 2002.
- [5] Котляр, Б.И. Пластичность нервной системы / Б.И. Котляр. — М.: МГУ, 1986.
- [6] Местецкий, Л.М. Математические методы распознавания образов // Курс лекций кафедры «Математические методы прогнозирования». — ВМиК, МГУ, 2002. [Электронный ресурс]. — Режим доступа: <http://www.ccas.ru/frc/papers/mestetskii04course.pdf>.
- [7] Комарцова, Л.Г., Максимов А.В. Нейрокомпьютеры / Л.Г. Комарцова, А.В. Максимов. — М.: МГТУ им. Н.Э. Баумана, 2002.
- [8] Способ и интеллектуальная система с интуицией: пат. Респ. Беларусь / В.М. Колешко, Е.А. Воробей. — № а 20120653; заявл. 25.04.2012.

- [9] Айвазян, С. А. Прикладная статистика: Классификации и снижение размерности / С. А. Айвазян. — М.: Финансы и статистика, 1989.
- [10] Шумейко, А. А. Интеллектуальный анализ данных (Введение в Data Mining) / А. А. Шумейко, С. Л. Сотник. — Днепропетровск, 2012. [Электронный ресурс]. — Режим доступа: http://sotnyk.com/Articles/iad/Intellectualnyj_analiz_dannyh_120527.pdf.