

УДК 681.335:004.891

*Т.Л. Мазурок*Южноукраинский национальный педагогический университет им. К.Д. Ушинского,
г. Одесса, Украина

Прогноз вектора состояний гомогенных групп обучаемых

В статье рассматривается проблема прогноза достижения цели обучения в условиях компетентностного подхода. На основе синергетической модели управления обучением, объектом которой является гомогенная группа обучаемых, предложены модели определения доверительных вероятностей вектора интеллекта и вектора состояния. Полученные значения использованы в генетическом алгоритме для формирования базы знаний для прогнозирования степени достижимости компетенций. Приведены результаты практической реализации.

Введение

Широкое внедрение информационных технологий в процесс обучения показало целесообразность первоочередного совершенствования средств системного моделирования обучения как управляемого процесса. Современные средства интеллектуального управления позволяют получить модели, основной целью создания которых является разрешение основных дидактических противоречий, характеризующих современное образование. В связи со слабой степенью формализации обобщённого процесса обучения модели управления разрабатываются на основе гибридизации математических моделей с методами интеллектуального подхода.

Особенности процесса обучения как управляемого процесса определяют необходимость существенного развития классических методов теории управления, которая изначально развивалась преимущественно для технических систем. Поэтому на смену кибернетическому подходу к управлению обучением в настоящее время находит широкое применение синергетический подход, который позволяет учесть при выработке управляющих воздействий собственные тенденции развития объекта управления.

В качестве одного из приложений разработанной автором модели синергетического управления обучением [1] используется модель группового обучения, в которой в качестве объекта управления рассматривается так называемая гомогенная группа обучаемых, определённая с дидактических позиций [2]. Развитие различных форм электронного обучения позволяет избежать целого ряда организационных трудностей, сдерживающих процесс формирования гомогенных групп обучаемых, динамически формировать так называемые виртуальные гомогенные группы [3]. Для разработки модели управления в условиях группового обучения необходимо дальнейшее развитие моделей и методов прогнозирования. Поэтому **актуальной и нерешённой** является **проблема** разработки модели прогнозирования для управляемого группового обучения.

Целью статьи является разработка модели прогноза вектора состояния в синергетической схеме управления обучением для гомогенных групп обучаемых.

Дидактическая постановка задачи управления обучением и обоснование актуальности осуществления обучения в пределах однородных групп обучаемых рас-

смотрены в работах А. Анастаси, В.П. Беспалько, М.Г. Доррера, А.Н. Печникова, Е. Шпрангера и др. Кибернетический подход к обучению – в работах Л.А. Растригина, М.Х. Эренштейна и др. Различные аспекты применения интеллектуальных средств для совершенствования систем управления обучением рассмотрены в работах В.А. Петрушина, В.Н. Сороко, О.В. Журавлёва, Ю.К. Тодорцева, А.И. Чмыря, Н.В. Шароновой.

Обзор современных методов прогнозирования [4] свидетельствует о тенденции их развития на основе гибридизации интеллектуальных подходов в соответствии со спецификой предметной области задачи. Одним из перспективных подходов при разработке систем управления сложными нелинейными динамическими объектами является синергетический, основная суть которого – максимальный учёт при выработке управляющего воздействия естественных свойств, внутреннего развития объекта управления [5]. В рамках реализации синергетической модели управления обучением нерешённой является проблема прогнозирования характеристик групповых показателей вектора состояния, что сдерживает реализацию схемы полноценного управления.

Модель группового управляемого обучения

Особенности синергетической модели управления обучением. Основу синергетической модели управления обучением [1] составляет двухклассовая модель «знаний и умений» управления обучением с вектором состояния (x, y) и вектором управления (U, h) , которая имеет следующий вид:

$$\begin{aligned} \frac{dx}{dt} &= fUy, \\ \frac{dy}{dt} &= c(1-U)xy, \\ \frac{d}{dt}(Ux + (1-U)y) &= \frac{h(t)}{1+r} + \frac{c-f}{1+r}(Ux + (1-U)y), \end{aligned} \quad (1)$$

где $h(t)$ – скорость выдачи информации,

r – коэффициент сопротивления дидактическому процессу,

f – коэффициент забывания,

c – коэффициент умозаключения,

U – доля времени, отведённая на накопление знаний,

S – нормированное количество информации ($0 < S < 1$),

x, y – нормированные объёмы накопленных знаний и умений.

В общем случае объект управления может подвергаться следующим воздействиям: случайным внешним возмущениям, целенаправленным управляющим воздействиям (обучающим и контролирующим), формируемым модулем управления, самоорганизации информации [6]. В случае управления на основе синергетической модели выработка управляющего воздействия осуществляется на основе треугольника управления (рис. 1), где γ – коэффициент гипотезы забывания, т.е. параметр, характеризующий вероятность сохранения изученного материала, λ – параметр, определяемый на основе календарного плана учебных занятий, зависящий от скорости подачи учебного материала.

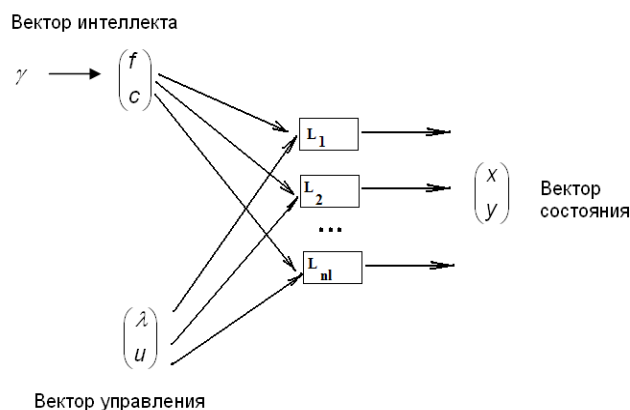


Рисунок 1 – Треугольник управления групповым обучением

Существует множество подходов к заданию отношений между обучаемыми. Однако, с точки зрения управления, на наш взгляд, наиболее эффективным является разбиение множества L на однородные (однородные) группы в соответствии с индивидуальными характеристиками обучаемых. Различные формы автоматизированного обучения, в частности, дистанционное обучение, позволяет формировать виртуальные коллективы обучаемых по критериям познавательных способностей [7]. При данном разбиении можно уменьшить размерность множества формируемых управляющих воздействий с сохранением учёта индивидуальных характеристик обучаемых. Таким образом, множество обучаемых L состоит из подмножеств L_1, L_2, \dots, L_{nl} , причём:

$$L_1 \cup L_2 \cup \dots \cup L_{nl} = L. \quad (2)$$

Каждая из групп L_i характеризуется набором атрибутов ИК= $\langle \text{УУ}, \text{СА} \rangle$, где УУ – уровень усвоения, СА – степень абстракции. Согласно одному из известных методов матричного сопоставления личностных свойств и видов общественно-производственной деятельности, определено восемь основных компонентов в структуре интеллекта, формирование которых способствует наилучшей реализации генетических задатков индивида. Таким образом,

$$L_i = \left\{ \langle \text{УУ}, \text{СА} \rangle_j \right\}, j = \overline{1,8}, \quad (3)$$

где j – основные компоненты в структуре интеллекта (например, логико-математический, пространственный и т.д.).

Модель прогноза вектора интеллекта. Схема на рис. 1 показывает, что оптимизация управления обучением достигается при условии учёта параметров вектора интеллекта. Поэтому для своевременного формирования управляющих воздействий необходимо располагать моделью прогнозирования значений его параметров. Параметры, характеризующие память и мышление, ввиду стохастичности их природы для конкретного обучаемого или группы обучаемых, могут рассматриваться как случайные величины. Следовательно, модель прогноза вектора интеллекта построим на основе исследования плотности распределения вероятностей двумерной случайной величины [8]. В табл. 1 обобщены аналогии основных параметров, характеризующих интеллектуальные способности различного характера.

Известно, что смысловые значения каждой пары координат имеют взаимосвязь. Для решения задачи прогнозирования в рамках цикла управления обучением необходимо

количественно выразить эту взаимосвязь с помощью коэффициента корреляции, так как в общем случае в задаче прогнозирования α и β – случайные величины.

Таблица 1 – Смысловые интерпретации вектора интеллекта

Система координат	Координаты	
	α	β
Технологическая	Память	Мышление
Сигнальная	Первая сигнальная система	Вторая сигнальная система
Информационная	Память	Быстродействие
Сенсорная	Вербальная	Пространственная
Диалектическая	Содержание	Форма

Тогда матрица ковариаций K определяется следующим образом:

$$K = \begin{pmatrix} \sigma_{\alpha}^2 & k_{\alpha\beta} \\ k_{\alpha\beta} & \sigma_{\beta}^2 \end{pmatrix}, \quad (4)$$

где σ_{α}^2 – дисперсия разброса случайных значений параметра памяти α ;

σ_{β}^2 – дисперсия разброса случайных значений параметра β ;

$k_{\alpha\beta}$ – ковариация между α и β .

Значения дисперсии определяются как математическое ожидание квадрата отклонения от математического ожидания параметров интеллекта:

$$\sigma_{\alpha}^2 = \frac{1}{N} \sum_{i=1}^N (\alpha_i - \alpha_0)^2; \sigma_{\beta}^2 = \frac{1}{N} \sum_{i=1}^N (\beta_i - \beta_0)^2, \quad (5)$$

где математические ожидания случайных величин α_0 и β_0 определяются как среднее их случайных значений:

$$\alpha_0 = \frac{1}{N} \sum_{i=1}^N \alpha_i; \beta_0 = \frac{1}{N} \sum_{i=1}^N \beta_i, \quad (6)$$

где N – количество испытаний, определяемое по закону Стьюдента [8].

В связи с необходимостью учёта различных форм обучения (индивидуальной и групповой), вектор интеллекта соответственно может быть индивидуальным и групповым. Исчерпывающей характеристикой непрерывной двумерной случайной величины является плотность вероятности. Основываясь на предположении нормального закона распределения случайной величины двумерного вектора интеллекта, можно записать выражение для нахождения его совместной плотности вероятности:

$$\varphi(\alpha, \beta) = \frac{1}{2\pi\sqrt{|K|}} \exp\left[-\frac{(Z - Z_0)' K^{-1} (Z - Z_0)}{2}\right], \quad (7)$$

где $Z = \begin{pmatrix} \alpha \\ \beta \end{pmatrix}$ – вектор интеллекта, $Z_0 = \begin{pmatrix} \alpha_0 \\ \beta_0 \end{pmatrix}$ – центр рассеивания.

После подстановки значений элементов матрицы в уравнение (8) получим следующее выражение:

$$\varphi(\alpha, \beta) = \frac{1}{2\pi\sigma_\alpha\sigma_\beta\sqrt{1-\rho^2}} \exp\left(\frac{1}{2(1-\rho^2)}\left(\left(\frac{\alpha-\alpha_0}{\sigma_\alpha}\right)^2 - 2\rho\left(\frac{\alpha-\alpha_0}{\sigma_\alpha}\right)\left(\frac{\beta-\beta_0}{\sigma_\beta}\right) + \left(\frac{\beta-\beta_0}{\sigma_\beta}\right)^2\right)\right) \quad (8)$$

Заметим, что

$$\left(\frac{\alpha-\alpha_0}{\sigma_\alpha}\right)^2 - 2\rho\left(\frac{\alpha-\alpha_0}{\sigma_\alpha}\right)\left(\frac{\beta-\beta_0}{\sigma_\beta}\right) + \left(\frac{\beta-\beta_0}{\sigma_\beta}\right)^2 = K^2, \quad (9)$$

где $\varphi_{\alpha,\beta}$ – плотность распределения вектора интеллекта, ρ – коэффициент корреляции, определяемый следующим образом: $\rho = \frac{k_{\alpha,\beta}}{\sigma_\alpha\sigma_\beta}$.

Для характеристики регрессии площадей сечения поверхности эллипсами рассеяния введём коэффициент подобия k (рис. 2):




Рисунок 2 – Эллипс рассеяния корреляции между параметрами вектора интеллекта

На основе геометрических соображений (рис. 2) можно определить следующие соотношения:

$$b = k\sigma_\beta; \quad a = k\sigma_\alpha,$$

где a, b – большая и малая полуоси эллипса соответственно.

Вероятность $p(\alpha, \beta)$ попадания случайной точки с координатами (α, β) в область D определим путём двойного интегрирования от плотности:

$$p(\alpha, \beta \in D) = \iint_{\alpha, \beta \in D} \varphi(\alpha, \beta) d\alpha d\beta \quad (10)$$

где D – внутренняя область эллипса рассеивания.

Выполним замену переменных для перехода к полярной системе координат:

$$\alpha = \alpha_0 + \sigma_\alpha r \cos \psi; \quad \beta = \beta_0 + \sigma_\beta r \sin \psi. \quad (11)$$

Откуда получим:

$$\frac{\alpha - \alpha_0}{\sigma_\alpha} = r \cos \psi; \quad \frac{\beta - \beta_0}{\sigma_\beta} = r \sin \psi. \quad (12)$$

Тогда выражение (10) примет вид:

$$p = \iint \varphi(\alpha(r, \psi), \beta(r, \psi)) \frac{\partial(\alpha, \beta)}{\partial(r, \psi)} dr d\psi = \iint \varphi \sigma_\alpha \sigma_\beta r dr d\psi \quad (13)$$

Подставляя (8) в (13), получим:

$$p(\alpha, \beta \in D) = \frac{\sqrt{1-\rho^2}}{2\pi} \int_0^{2\pi} \left(e^{-\frac{k^2 \sigma_\beta^2}{2(1-\rho^2)}(1-\rho \sin 2\psi)} - e^{-\frac{k^2 \sigma_\alpha^2}{2(1-\rho^2)}(1-\rho \sin 2\psi)} \right) \frac{1}{1-\rho \sin 2\psi} d\psi.$$

Выполняя якобиан-преобразование для перехода к полярным координатам, получаем формулу для нахождения вероятности принадлежности параметров вектора интеллекта области эллипса рассеяния D :

$$p(\alpha, \beta \in D) = \frac{\sqrt{1-\rho^2}}{2\pi} \int_0^{2\pi} \left(e^{-k_\beta(1-\rho \sin 2\psi)} - e^{-k_\alpha(1-\rho \sin 2\psi)} \right) \frac{1}{1-\rho \sin 2\psi} d\psi \quad (14)$$

Модель прогноза группового вектора интеллекта. Плотность вероятности группового вектора интеллекта определим на основе нормального закона распределения двумерной случайной величины:

$$\varphi(U, V) = \frac{1}{2\pi \sqrt{|G|}} \exp \left[-\frac{(W - W_0)G^{-1}(W - W_0)}{2} \right] \quad (15)$$

где W – групповой вектор интеллекта,
 W_0 – центр рассеивания.

Математические ожидания групповых показателей интеллекта определяются как средние значения случайных величин:

$$U = \frac{1}{N} \sum_{i=1}^N \alpha_i; \quad V = \frac{1}{N} \sum_{i=1}^N \beta_i, \quad (16)$$

где N – количество обучаемых в группе;

i – числовой идентификатор конкретного обучаемого (номер в списке группы, номер зачётки и т.д.);

G – матрица ковариаций;

G^{-1} – обратная матрица ковариаций.

Определение матрицы ковариаций производится по формуле (4), плотность распределения группового вектора интеллекта по формуле (7), доверительная вероятность прогноза вероятности определяется выражением (14).

Таким образом, получены математические модели, с помощью которых можно определить доверительные интервалы и доверительные вероятности индивидуального и группового векторов интеллекта. Однако в реализации схемы управления (рис. 1) существенное значение имеет также возможность прогноза вектора состояния. Для определения вектора состояний необходимо рассмотреть модель графа обучения, так как прогноз вектора состояния основывается на определении вершин (учебных элементов – УЭ) и взаимосвязей между ними (внутри- и межпредметных связей).

Модель прогноза вектора состояния. Для реализации схемы управления (рис. 1) существенное значение имеет возможность прогноза вектора состояния. Для определения

вектора состояний необходимо рассмотреть модель графа обучения, т.к. прогноз вектора состояния основывается на определении вершин (учебных элементов – УЭ) и взаимосвязей между ними (внутри- и межпредметных связей).

Граф обучения (ГО) представляет собой ориентированный граф, изображающий множество точек-вершин, соответствующих УЭ дисциплины, которые соединены между собой дугами-стрелками. Для прогнозирования значений вектора состояния обучаемого после изучения учебного материала за время t применим теорему умножения, рассматривая вероятности сохранения в памяти соответствующих вершин графа как вероятности совместных событий, определяющих вероятности сохранения в памяти взаимосвязи между УЭ.

Для прогнозирования значений вектора состояния обучаемого после изучения учебного материала за время t определим на основе матрицы инцидентий, описывающей взаимосвязи между УЭ, с помощью теоремы умножения. При этом рассмотрим вероятности сохранения в памяти соответствующих вершин графа как вероятности совместных событий для определения вероятности сохранения в памяти взаимосвязи между УЭ:

$$p_{ij}(t) = p_i(t)p_j(t) \quad (17)$$

где $p_i(t), p_j(t)$ – вероятности сохранения соответственно i -х и j -х вершин в момент времени t ;

$p_{ij}(t)$ – вероятность сохранения дуги (i, j) в момент t .

Известно, что вероятность сохранения в памяти УЭ определяется по экспоненциальному закону:

$$p_i(t) = p(q_i) = e^{-\lambda(t-t_i)} \frac{q_i}{\sum_{i=1}^n q_i}, \quad (18)$$

где t_i – момент изучения i -й вершины, причём $t > t_i$;

q_i – вес i -й вершины, характеризующий количество входящих дуг;

n – общее число вершин;

λ – параметр интеллекта, характеризующий забывание.

Тогда, после подстановки (18) в (17), получим:

$$p_{ij}(t) = \frac{e^{-\lambda(2t-t_i-t_j)} q_i q_j}{\left(\sum_{i=1}^n q_i\right)^2}. \quad (19)$$

Уравнение (17) позволяет на основе данных матрицы инцидентий и построенного на её данных графа обучения вычислять прогнозируемое значение вероятности сохранения в памяти взаимосвязи между двумя УЭ.

В процессе планирования обучения происходит группирование УЭ, изучаемых на одном занятии. Поэтому введём понятие конфигурации, под которым будем понимать в дальнейшем группу вершин, изучаемых на k -м занятии. Определим для каждой конфигурации прогнозируемые значения вероятностей сохранения в памяти УЭ, взаимосвязей между ними. Для этого сначала определим общие веса вершин и дуг, составляющих конфигурацию:

$$Q_{1k} = \sum_{i=i_k}^{i_k+l_k-1} q_i; \quad Q_{2k} = \sum_{i=i_k}^{i_k+l_k-1} \sum_{j>i}^{i_k+l_k-1} q_{ij}, \quad (20)$$

где Q_{1k} – вес всех вершин k -й конфигурации;
 Q_{2k} – вес всех дуг k -й конфигурации;
 k – номер конфигурации;
 i_k – номер первой вершины k -й конфигурации;
 l_k – количество вершин k -й конфигурации;
 q_{ij} – вес дуги, соединяющей вершины i, j , причём $q_{ij} = q_i + q_j$.

Тогда для определения соответствующих вероятностей получаем:

$$p_{1k} = e^{-\lambda(t-t_k)}; p_{2k} = e^{-2\lambda(t-t_k)}, \quad (21)$$

где $p_{1k}(t)$ – вероятность сохранения всех вершин k -й конфигурации за время $t - t_k$;
 $p_{2k}(t)$ – вероятность сохранения всех дуг k -й конфигурации за время $t - t_k$;
 t_k – время проведения занятий с k -й конфигурацией;
 t – время проведения контроля.

Таким образом, формулы (20), (21) позволяют прогнозировать вероятностные показатели вектора состояния обучаемого, соответствующие запоминанию УЭ (вершин графа обучения) и взаимосвязей между ними (дугами графа).

В соответствии со структурой общей схемы управления обучением, конфигурации могут быть объединены в различного рода блоки (темы, разделы, модули, учебные дисциплины). Поэтому представляет интерес также прогнозирование параметров вектора состояния для блоков конфигураций. Для этого выразим соответствующие вероятности сохранения информации о вершинах и дугах, объединённых в блоке конфигурации:

$$x_i(m, n) = \frac{\sum_{k=m}^{m+n-1} e^{-\lambda(t-t_k)} Q_{1k}}{\sum_{k=m}^{m+n-1} Q_{1k}}; \quad y_i(m, n) = \frac{\sum_{k=m}^{m+n-1} e^{-\lambda(t-t_k)} Q_{2k}}{\sum_{k=m}^{m+n-1} Q_{2k}}, \quad (22)$$

где m – номер первой конфигурации в k -м блоке;
 n – количество конфигураций в k -м блоке.

Тогда можно выразить совместную плотность вероятности сохранения вершин и дуг ГО следующим образом:

$$p = \frac{1}{2\pi\sqrt{|H|}} \int_D \int \exp\left(-\frac{1}{2}(B - B_0)^T H^{-1}(B - B_0)\right) dx dy, \quad (23)$$

где B – вектор состояния после изучения блока конфигураций;
 B_0 – вектор состояния, соответствующий его центру рассеивания;
 H – матрица ковариаций между компонентами x, y ;
 σ_x^2, σ_y^2 – дисперсии случайных величин x, y ;
 k_{xy} – ковариация.

Доверительная вероятность прогноза для блока конфигураций определяется с помощью двойного интеграла:

$$p_D = \frac{1}{2\pi\sigma_x\sigma_y\sqrt{1-\rho_{xy}^2}} \int_a^b dx \int_{y_1(x)}^{y_2(x)} \exp\left(-\frac{G(x, y)}{1-\rho_{xy}^2}\right) dy, \quad (24)$$

где D – область интегрирования внутренних точек эллипса рассеивания.

Определение пределов интегрирования плотности доверительной вероятности на основе метода вычисления двойного интеграла производим по формулам:

$$a = x_0 - \frac{c\sigma_x}{\sqrt{1-\rho_{xy}^2}}; \quad b = x_0 + \frac{c\sigma_x}{\sqrt{1-\rho_{xy}^2}} \quad (25)$$

Границы доверительных интервалов эллипса рассеивания определим по формулам:

$$y_1(x) = y_0 + \sigma_y \left(\frac{\rho_{xy}(x-x_0)}{\sigma_x} - \sqrt{c^2 - \frac{3(x-x_0)^2}{4\sigma_x^2}} \right);$$

$$y_2(x) = y_0 + \sigma_y \left(\frac{\rho_{xy}(x-x_0)}{\sigma_x} + \sqrt{c^2 - \frac{3(x-x_0)^2}{4\sigma_x^2}} \right). \quad (26)$$

Плотности доверительной вероятности прогноза вектора состояния после изучения блока конфигураций по формуле двойного интегрирования:

$$p = \frac{1}{2\pi\sigma_x\sigma_y\sqrt{1-\rho_{xy}^2}} \int_a^b dx \int_{y_1(x)}^{y_2(x)} \exp\left(-\frac{G(x,y)}{1-\rho_{xy}^2}\right) dy. \quad (27)$$

Таким образом, получены зависимости, с помощью которых можно определить вероятностные характеристики двумерного вектора (x, y) на основе входных данных алгоритма прогнозирования обученности.

Однако, в условиях компетентностного обучения больший интерес представляет определение не только вероятностных характеристик вектора состояния, но и прогнозируемой степени достижения компетенции для каждой группы учащихся. Для этого воспользуемся эволюционным подходом.

Эволюционная модель прогнозирования степени достижения компетенции. Для реализации схемы управления процессом формирования компетенций наиболее целесообразным является подход, основанный на применении генетического алгоритма в качестве средства формирования нечёткой базы знаний (БЗ) на основе статистических данных, накапливаемых в процессе обучения [9]. В этом случае прогнозированию предшествует этап формирования нечёткой БЗ. В качестве основных влияющих факторов рассмотрим значения плотности распределения вектора интеллекта и вектора состояния гомогенной группы, а также управляющее воздействие u , определяющее долю времени на усвоение знаний. Необходимая обучающая выборка для формирования матрицы знаний имеет вид, представленный в табл. 2.

Таблица 2 – Структура обучающей выборки

Номер блока конфигурации k	Входы				Выход
	Плотность распределения группового вектора интеллекта $p(f, c)$	Плотность распределения группового вектора состояния $p(x, y)$	Доля времени, отведённого на накопление знаний u	Степень интеграции $k_{инт}$	Степень формирования компетенции C
1	$p_1(f, c)$	$p_1(x, y)$	u_1	$k_{инт}^1$	C_1
...
N	$p_N(f, c)$	$p_N(x, y)$	u_N	$k_{инт}^N$	C_N

Определим области определения входных переменных:

для $p_i(f, c)$, $p_i(x, y)$, $i = \overline{1, N} - [0, 1]$;

для u_i , $k_{инт}^i$, $i = \overline{1, N} - [0, 1]$.

Выходная переменная описывается с помощью терм-множества $T = \{\text{компетенции не развиты, недостаточно развиты, объём достаточен, развитие компетенций, высшее развитие компетенций}\}$ [10], фазсификация которых выполнена на основе принятой шкалы оценивания.

Применение генетического алгоритма для извлечения матрицы знаний предполагает выполнение следующих основных шагов [9]:

ШАГ 1. Инициализация начальной популяции хромосом-решений с помощью операции определения случайного числа $RANDOM([0, 1])$, равномерно распределённого на интервале области определения каждой из входной переменной.

ШАГ 2. Расчёт функций соответствия (fitness function) каждой хромосомы на основе соотношения:

$$FF(S_{ch}) = -\sum_{i=1}^N [C_i - C_i^{эм}]^2, \quad (28)$$

где ch – номер хромосомы S ;

$i = \overline{1, N}$ – номер элемента обучающей выборки;

$C_i^{эм}$ – зафиксированное значение лингвистической переменной для изученного блока конфигурации.

ШАГ 3. Если получена хромосома с функцией соответствия $FF(S_{ch}) = 0$, то окончание алгоритма, иначе – переход к шагу 4.

ШАГ 4. Определить вероятности отбора каждой хромосомы-родителя для операции скрещивания.

ШАГ 5. Синтезировать хромосомы-отпрыски путём одноточечного скрещивания хромосом-родителей.

ШАГ 6. Определить значение функции соответствия для хромосом-отпрысков по формуле (28).

ШАГ 7. Если получена хромосома с функцией соответствия $FF(S_{ch}) = 0$, то принять её искомым решением, окончание алгоритма, иначе – переход к шагу 8.

ШАГ 8. Если количество итераций исчерпано (например, $M=1000$), то считать искомым решением хромосому с наибольшим значением FF , окончание алгоритма, иначе – переход на шаг 4.

КОНЕЦ АЛГОРИТМА.

Полученная модель даёт возможность получить прогнозируемые значения степени достижения компетенции на основании значений параметров синергетической модели управления.

Практическая реализация. Осуществление компьютерных экспериментов проводилось в два этапа. Первый этап связан со статистической обработкой данных, накопленных в результате использования системы управления обучением Moodle для студентов института физики и математики. Обработка результатов и построение поверхностей распределения двумерных случайных величин для каждой гомогенной группы выполнен на основе использования функций Statistics Toolbox пакета MATLAB. Передача подготовленных исходных данных из файлов с расширениями *.xlsx в MATLAB осуществлялась с использованием подключения через надстройки ExcelLink,

которая позволяет вести совместную работу с двумя пакетами. Графическая визуализация эллипсов рассеяния и поверхностей плотности вероятности реализована с использованием графических команд визуализации в виде каркасной (команда mesh) и сплошной (команда surface) поверхностей [11]. Команда meshgrid используется для преобразования области определения векторов в матрицы узлов поверхности.

Второй этап состоит в реализации генетического алгоритма для формирования нечёткой БЗ по прогнозированию достижения соответствующих компетенций, проверке адекватности прогноза. Диаграммы сравнения для различных гомогенных групп обучаемых (рис. 3) показали, что среднеквадратичные отклонения реальных оценок достижения компетентности от прогнозируемых не превышают допустимого предела отклонения $\delta = 0.001$.




Рисунок 3 – Диаграмма сравнения для гомогенной группы обучаемых

Выводы

Предложенный подход позволяет получить прогнозируемые значения степени достижения компетенции при реализации синергетического управления обучением. Основу прогноза составляет гибридизация методов статистического анализа двумерных случайных величин – вектора интеллекта и вектора состояния с эволюционным методом формирования нечёткой БЗ на основе применения генетического алгоритма. К особенностям полученного подхода можно отнести учёт накопленных статистических данных о тенденциях развития группы обучаемых совместно с лингвистически заданными параметрами управления. **Научная новизна** состоит в разработке модели прогноза диагностично заданной цели обучения на основе обработки накопленных статистических данных совместно с интеллектуальными средствами нечёткого вывода по правилам, сгенерированным в результате применения генетического алгоритма. **Практическое значение** определяется экспериментальным подтверждением эффективности предложенного подхода.

К перспективным направлениям данного исследования, на наш взгляд, следует отнести декомпозицию схемы управления обучением, разработку механизма учёта глубины уровня декомпозиции при формировании правил БЗ.

Литература

1. Мазурок Т.Л. Синергетическая модель индивидуализированного управления обучением / Т.Л. Мазурок // Математические машины и системы. – 2010. – № 3. – С. 124-134.
2. Беспалько В.П. Образование и обучение с участием компьютеров (педагогика третьего тысячелетия) / Беспалько В.П. – М. : МПСИ, 2002. – 352 с.

3. Мазурок Т.Л. Интеллектуальное формирование контента для гомогенных групп обучаемых / Т.Л. Мазурок // Образование и виртуальность-2009 : сб. науч. тр. 12-й Междунар. конф. Украинской ассоциации дистанционного образования. – Харьков-Ялта : УАДО, 2009. – С. 245-253.
4. Снитюк В.С. Прогнозування. Моделі. Методи. Алгоритми / Снитюк В.С. – К. : Маклаут, 2008. – 364 с.
5. Колесников А.А. Синергетические методы управления сложными системами: теория системного синтеза / Колесников А.А. – М. : УРСС. – 2006. – 240 с.
6. Жуков Д.О. Модель самоорганизации информации в процессе управления знаниями / Д.О. Жуков, И.В. Саойло // Качество, инновации, образование. – 2008. - №12. – С.18-36.
7. Мазурок Т.Л. Динамическое управление формированием гомогенных групп обучаемых / Т.Л. Мазурок, Ю.К. Тодорцев // Труды десятой междунар. науч.-практ. конф. : Современные информационные и электронные технологии («СИЭТ-2009»), 18-22 мая 2009 г.- Одесса. – Т. 2. – С.188.
8. Гайдышев И.А. Анализ и обработка данных / Гайдышев И.А. – СПб. : Питер, 2001. – 341 с.
9. Мітюшкін Ю.І. Soft Computing: ідентифікація закономірностей нечіткими базами знань / Ю.І. Мітюшкін, Б.І. Мокін, О.П. Ротштейн. – Вінниця : УНІВЕРСУМ-Вінниця, 2002. – 145 с.
10. Малахов Ю.А. Алгоритм формирования компетенций студентов технического вуза / Ю.А. Малахов // УСиМ. – 2010. – № 2. – С.73-79.
11. Дьяконов В. Математические пакеты расширения MATLAB : [специальный справочник] / В. Дьяконов, В. Круглов. – СПб. : Питер, 2001. – 400 с.

Literatura

1. Mazurok T.L. Matematicheskiemashiny i sistemy. № 3. 2010. S 124-134
2. Bespal'ko V.P. Obrazovanie i obuchenie s uchastiemkomp'yuterov (pedagogikatret'egotysjacheletija). M.: MPSI. 2002. 352 s.
3. Mazurok T.L. Obrazovanie i virtual'nost'-2009. Sb.nauch.tr. 12-j Mezhdunar. konf. Ukrainskojassociaciiidistancionnogooobrazovanija. Har'kov-Jalta: UADO. 2009. S 245-253
4. Snitjuk V.C. Prognozuvannja. Modeli. Metodi. Algoritmi. K.: Maklaut. 2008. 364 s.
5. KolesnikovA.A.Sinergeticheskiemetodyupravlenijaslozhnymisistemami: teorijasistemnogosinteza. M.: URSS. 2006. 240 s.
6. Zhukov D.O. Kachestvo, innovacii, obrazovanie. № 12. 2008. S18-36
7. Mazurok T.L. Trudydesjatojmezhdunar. nauch.-prakt. konf. Sovremennyeinformacionnye i jelektronnyetehnologii («SIJeT-2009»). 18-22 maja 2009 g.Odessa. Tom 2. 2009. S 188
8. Gajdyshev I.A. Analiz i obrabotkadannyh. SPb: Piter. 2001. 341 s.
9. MitjushkinJu.I.SoftComputing: identifikacijazakonomirnostejnechitkimibazamiznan'. Vinnicja: UNIVERSUM-Vinnicja. 2002. 145 s.
10. MalahovJu.A. USiM. № 2. 2010. S 73-79
11. D'jakonov V. Matematicheskiepaketyrasshirenija MATLAB. Special'nyjspravochnik. SPb.: Piter. 2001. 400 s.

T.L. Мазурок

Прогноз вектора станів гомогенних груп осіб, що навчаються

У статті розглянуто проблему прогнозування досяжності мети навчання в умовах компетентнісного підходу. На основі синергетичної моделі управління навчанням, об'єктом якої є гомогенна група осіб, що навчаються, запропоновано моделі визначення довірчих ймовірностей вектора інтелекту та вектора станів. Отримані значення використано у генетичному алгоритмі для формування бази знань в прогнозуванні ступеня досяжності компетенцій. Наведено результати практичної реалізації.

T. Mazurok

Forecast of the State Vector of Homogeneous Groups of Learners

The paper addresses to the problem of forecasting the goal of teaching in competence-based approach. On the basis of a synergetic model of control education, whose object is a homogeneous group of learners, the model for determining the confidence probability of vector of the intellect and the state vector are proposed. The values obtained are used in genetic algorithm for building knowledge base for predicting the degree of accessible expertise. The results of implementation are given.

Статья поступила в редакцию 16.06.2011.