

¹ Финансовый университет при Правительстве Российской Федерации, г. Москва, Россия² Московский технологический университет (МИРЭА), г. Москва, Россия³ Московский авиационный институт (национальный исследовательский университет), г. Москва, Россия⁴ Институт проблем управления имени В.А. Трапезникова РАН, г. Москва, Россия**МОДЕЛИ И АЛГОРИТМЫ ПРОГНОЗИРОВАНИЯ ТЕХНИЧЕСКОГО СОСТОЯНИЯ КОСМИЧЕСКОГО АППАРАТА НА ОСНОВЕ ИНФОРМАЦИОННЫХ ТЕХНОЛОГИЙ*****Аннотация**

Показана актуальность решения задачи разработки новых моделей и алгоритмов прогноза технического состояния космических аппаратов в интересах автономного оперативного восстановления работоспособности их бортовой аппаратуры. Обоснована возможность использования информационных технологий для прогнозирования технического состояния космического аппарата в реальном времени. Предложена прогнозная модель, основанная на методе пространственной экстраполяции при условии, что накоплено множество экспериментальных данных, которые характеризуют причины и следствия ситуаций, подобных той, в которой необходимо осуществить прогноз. На основе анализа существующих нейронных сетей и типов нейронов предложена новая модель подсистемы прогнозирования, структура которой базируется на комплексной модульной нейросети, состоящей из сетей двух типов – Кохонена и двухслойного перцептрона с сигмоидными функциями активации. Разработаны алгоритмы, которые позволяют реализовать нейросетевое построение вектора прогнозов на основе априорной информации протокола испытаний и выработки протокола ситуаций в пространстве параметров космического аппарата в реальном времени. Представленные результаты экспериментальных исследований подтверждают эффективность разработанных моделей и алгоритмов.

Ключевые слова

Космический аппарат, прогноз технического состояния, модель, алгоритм, искусственная нейронная сеть, информационные технологии.

Volkov A.G.¹, Nechaev V.V.², Goncharenko V.I.^{3,4}, Lobanov I.A.⁴¹ Financial University under the Government of the Russian Federation, Moscow, Russia² Moscow Technological University (MIREA), Moscow, Russia³ Moscow Aviation Institute (National Research University), Moscow, Russia⁴ Trapeznikov Institute of Control Sciences of RAS, Moscow, Russia**MODELS AND ALGORITHMS FOR A SPACECRAFTS TECHNICAL STATE PREDICTION BASED ON INFORMATION TECHNOLOGIES****Abstract**

The tasks of developing new models and algorithms for a spacecraft technical state prediction in the interests of an autonomous rapid recovery of spacecraft on-board equipment operational capability are topical. This results make it possible to significantly influence the indicator of the overall spacecraft efficiency. The possibility of using neural network technologies for real-time prediction the technical state of a spacecraft is substantiated. The results of the analysis of existing technical state prediction methods of made it possible to propose a predictive model based on the method of spatial extrapolation. It is possible only for some objects a lot of experimental data and data from the operational and technical documentation that characterize the causes and consequences of situations similar to the forecast situation are accumulated. Based on the analysis of existing neural networks and neuron types, a new model of the prediction subsystem is proposed, the structure of which is based

* Труды II Международной научной конференции «Конвергентные когнитивно-информационные технологии» (Convergent'2017), Москва, 24-26 ноября, 2017

Proceedings of the II International scientific conference "Convergent cognitive information technologies" (Convergent'2017), Moscow, Russia, November 24-26, 2017

on a complex modular neural network. It consisting of two types – Kohonen net and two-layer perceptron with sigmoid activation functions. The use of Kohonen net made it possible to reduce the dimensionality of the space of input parameters by three times and to develop a prototype of the situation in the form of a vector of generalized parameters. As a result of the training of a two-layer perceptron, two synaptic matrices are formed, which make it possible to realize the prediction operator with the required prediction error. Algorithms have been developed that make it possible to implement the neural network output of the forecast vector based on the a priori information of the test protocol and the development of a situations protocol in the spacecraft parameters space in realtime. Algorithms are successfully used in technical state prediction of modern spacecraft. The presented results of experimental studies confirm the effectiveness of the developed models and algorithms.

Keywords

Spacecraft, technical state prediction, model, algorithm, artificial neural network, information technology.

Введение

Задачи разработки новых моделей и алгоритмов прогноза технического состояния (ТС) космического аппарата (КА) являются актуальными и результаты их решения существенно влияют на показатель эффективности его функционирования в целом. В статьях авторов [1-4] показано, что в настоящее время компьютерные и информационные технологии поддержки научно-исследовательских и опытно-конструкторских работ, связанных с созданием и применением систем управления (СУ) летательными аппаратами (ЛА), играют важную роль. Это связано с развивающимися возможностями таких технологий и с постоянно растущими требованиями к качеству управления ЛА.

Сложившаяся организация контроля, диагностирования и реконфигурации бортовых комплексов КА не обладает требуемой оперативностью решения задачи автономного оперативного восстановления работоспособности бортовой аппаратуры (БА). Для решения задачи автономного восстановления работоспособности БА необходима разработка автономного замкнутого контура структурного управления, в основу управляющей системы которого положена интеллектуальная система контроля, диагностирования и реконфигурации, использующая нейросетевой логический базис.

Анализ существующих методов прогноза ТС позволяет предложить прогнозную модель, основанную на методе пространственной экстраполяции [5-8] при условии, что для некоторых объектов накоплено множество экспериментальных данных (по результатам всевозможных исследований и предварительных испытаний) и данных из эксплуатационно-технической документации, которые характеризуют причины и следствия ситуаций, подобных той, в которой необходимо осуществить прогноз.

Целью исследований является разработка моделей и алгоритмов прогноза технического состояния космического аппарата на основе когнитивных и нейросетевых технологий для выработки предложений по автономному оперативному восстановлению работоспособности бортовой аппаратуры КА в реальном масштабе времени.

Постановка задачи

Под термином «*степень подобия*» будем понимать показатель, характеризующий относительное количество совпадений определенных характеристик рассматриваемых ситуаций технического состояния КА. Множество $\{I\}$ ситуаций любых подобных процессов можно представить, как объединение двух подмножеств событий, характеризующих причину $\{X\}$ и следствие $\{Y\}$:

$$\{I\} = \{X\} \cup \{Y\}. \quad (1)$$

Данные подмножества могут отличаться не только своими мощностями, содержать различные события, но отличаются, как минимум, одним элементом, характеризующим время свершения события.

В свою очередь, весь информационный массив $\{R\}$, на основании которого строится прогноз, можно представить, как объединение множеств $\{I\}$

$$\{R\} = \bigcup_{i=1}^N \{I\}_i, \quad (2)$$

где N – число наблюдаемых ранее ситуаций, подобных наблюдаемой, и следствие, которое необходимо спрогнозировать.

Совокупность наблюдаемых процессов можно представить в виде протокола наблюдений:

$$R = \langle X, Y^{t+1} \rangle = \langle Y_i^t, Z_i, K_i, Y_i^{t+1}, i = 1, \dots, N \rangle, \quad (3)$$

где: $X = [Y^t, Z, K]^T$ – вектор причин предполагаемого ТС объекта;

$Y_i^t = (y_1^t, \dots, y_n^t)$ – вектор параметров ТС объекта, либо подобной системы, принимаемых в качестве исходных в i -й зафиксированной ситуации;

$Z_i = (z_1, \dots, z_m)$ – вектор факторов прогнозного фона зафиксированной ситуации (либо интегральный показатель прогнозного фона предшествующего периода);

$K_i = (k_1, \dots, k_l)$ – вектор управляющих воздействий (УВ), подаваемых на вход объекта, либо подобного устройства, в i -й зафиксированной ситуации (либо интегральный показатель УВ предшествующего периода);

$Y_i^{t+1} = (y_1^{t+1}, \dots, y_n^{t+1})$ – вектор параметров ТС, принимаемых в качестве следствия в i -й зафиксированной ситуации.

Протокол наблюдений (2) можно представить в виде таблицы (см. табл. 1). Временная диаграмма одного прецедента, в общем виде, иллюстрируется на рис. 1.

Таблица 1. Массив наблюдений функционирования объекта

Наблюдаемая ситуация {P}	Прогнозируемая причина состояния объекта {X}			Следствие {Y}
	Y^t	Z	K	Y^{t+1}
P ₁	$Y_{t_1}^t$	Z ₁	K ₁	$Y_{t_1}^{t+1}$
P ₂	$Y_{t_2}^t$	Z ₂	K ₂	$Y_{t_2}^{t+1}$
P _i	$Y_{t_i}^t$	Z _i	K _i	$Y_{t_i}^{t+1}$
P _{i+1}	$Y_{t_{i+1}}^t$	Z _{i+1}	K _{i+1}	$Y_{t_{i+1}}^{t+1}$
P _N	$Y_{t_N}^t$	Z _N	K _N	$Y_{t_N}^{t+1}$




Рис. 1. Окно наблюдения параметров ситуации

Временной интервал $T_1 = [t_1, t_2]$ обозначен на рис. 1 как период основания прогноза. Значения компонент векторов Y^t, Z и K могут быть получены инвариантно моменту измерения (либо интегрально) в пределах T_1 . Временной интервал $T_2 = [t_2, t_3]$ обозначен как период упреждения прогноза. Получение прогнозных характеристик предполагается в момент $t_3 \in T_2$.

Длительность интервалов T_1, T_2 и другие характеристики диаграммы прецедента зависят от требований на параметры прогноза, предъявляемые органами управления (либо системой управления) и особенностей постановки задачи прогнозирования конкретного типа объекта. Множество элементов протокола R представляет собой множество прецедентов Π , описанных посредством векторов Y, Z, K, Y^{t+1} – фрагментов знаний, аккумулирующих предшествующий опыт системы прогнозирования.

Под прогнозированием технического состояния КА будем понимать оценку вектора ТС Y^{t+1} по данным векторов Y^t, Z, K ; причем основой принятия решения является множество ситуаций – прецедентов $\{\Pi\}$ протокола наблюдений R . Таким образом, задачу синтеза прогнозной модели сформулируем следующим образом:

Дано:

- 1) Множество прецедентов $\{\Pi_i\}$, упорядоченных протоколом наблюдений R и содержащих множество X причин $\{x_i^t\}$ и следствий $Y^{t+1} = \{y_i\}, i = 1 \dots N$;

- 2) Множество допустимых структур прогнозной модели $S = \{s_l\}, l = 1 \dots L;$
 3) Множество допустимых значений параметров прогнозной модели $P = \{p_k\}, k = 1 \dots K.$

Ограничения:

- 1) Максимально допустимая погрешность прогноза $\Delta_{\text{тр}}$;
 2) Ограничение снизу $\varepsilon_{\text{тр}}$ на достоверность прогноза $D.$

Найти:

Прогнозную модель F , характеризуемую структурой S и множеством параметров P , осуществляющую отображение множества причин $X^t = \{x_i^t\}$ в множество следствий $Y^{t+1} = \{Y^{t+1}\}$, с погрешностью Δ на этапе обучения модели.

$$\sum_{i=1}^{N1} (Y_i^{t+1} - Y_{M_i}^{t+1})^2 \leq \Delta, \tag{4}$$

где $Y_{M_i}^{t+1} = F(x_i^t), i = 1 \dots N1$

и удовлетворяющую требованию на этапе верификации модели:

$$D = \frac{m}{M} \geq \varepsilon, \tag{5}$$

где m – число совпадений вектора прогноза $Y_{M_i}^{t+1}$ с истинным значением Y_i^{t+1} , причем вектор причин

$\emptyset_2^t : X_1^t \cap X_2^t = \dots, X_1^t \cup X_2^t = X^t$, к общему числу M прогнозов.

Модели прогноза

Результаты проведенного анализа существующих нейронных сетей и типов нейронов позволили предложить новую модель системы прогнозирования, структура которой базируется на совмещенной модульной нейросети, состоящей из сетей двух типов – Кохонена (рис. 2) и двухслойного персептрона с сигмоидными функциями активации.

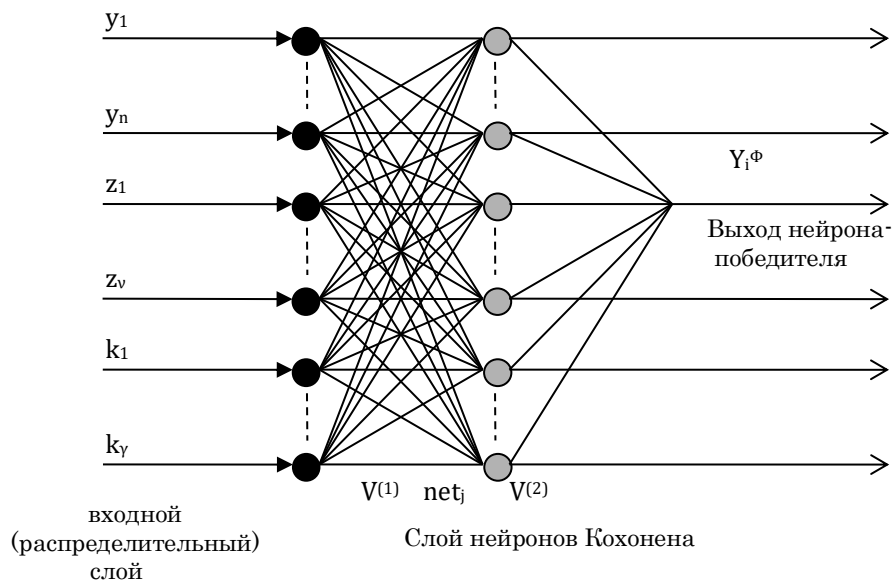


Рис. 2. Структура нейросети Кохонена

НС Кохонена относится к классу самоорганизующихся нейросетей [5-8], при этом самоорганизация происходит в результате топологического упорядочения входных образов по различным множествам фактов.

НС Кохонена представляет собой двухслойную сеть с прямыми связями (рис. 2). Первый слой – распределительный. Каждый нейрон этого слоя связан со всеми нейронами выходного слоя. Второй слой осуществляет конкуренцию между нейронными элементами, в результате которого определяется нейрон победитель. Выход нейрона-победителя будем трактовать как требуемое значение обобщенного

параметра. Очевидно, что для разных образов ТС значения обобщенных параметров (фактов), характеризующие данный образ, различны. Фактом для образа технического состояния является выход нейрона, который в результате подачи на вход НС определенного образа ТС (вектора наблюдаемых параметров) имеет максимальную взвешенную активность.

Определим взвешенную активность в виде суммы:

$$S_j = \sum_i V_{ij} y_i = V_j^{(I)} [X^t]^T, \quad (6)$$

где $X = \{y_1, \dots, y_n, z_1, \dots, z_v, k_1, \dots, k_\gamma\}$ – вектор наблюдаемых параметров (входной образ ТС);

$V_j = \{v_{1j}, \dots, v_{nj}\}$ – вектор столбец весовых коэффициентов j – го входного нейрона;

t – текущий момент времени;

T – знак транспонирования вектора X .

Для адекватного определения нейрона-победителя нормализуем весовые и входные векторы, то есть

$$|X| = \sqrt{\sum_i x_i^2} = 1, \quad (7)$$

$$|V_j^{(I)}| = \sqrt{\sum_i v_{ij}^2} = 1. \quad (8)$$

Тогда взвешенная активность j – го нейрона, представленная в виде скалярного произведения, будет определяться значением косинуса угла α между векторами весов и входных (наблюдаемых) параметров.

$$S_j = |V_j| |X| \cos \alpha = \cos \alpha. \quad (9)$$

Приведенная интерпретация НС означает, что максимальную активность будет иметь тот нейрон, весовой вектор которого коллинеарен входному вектору наблюдаемых параметров.

Выражение (9) эквивалентно коэффициенту взаимной корреляции между входным и весовым векторами, который будет равен 1 при $\alpha = 0$.

Наличие латеральных связей между нейронами слоя Кохонена $V^{(2)}$ позволяет повысить «контрастность» входного вектора наблюдаемых параметров [4], то есть формализовать обобщенную ситуацию-прототип.

Используем характерный для теории распознавания образов принцип введения метрики в пространстве параметров. Для этого определим область притяжения G , оцениваемую функцией притяжения $h(j, k, t)$. Выберем шаг квантования в данной метрике равным $\gamma(t)$. Область притяжения G , в радиусе действия которой нейроны активно изменяют свои весовые векторы в сторону входного вектора наблюдаемых параметров, определим для каждого нейрона-победителя. Тогда в область G нейрона k войдут все нейроны, находящиеся на определенном расстоянии от нейрона-победителя.

Отметим, что в аксиоматической теории множеств фактор-множество $X^{\hat{o}}$ определяется как множество окрестностей единичного радиуса, взятых для всех элементов исходного множества X при задании в нем какого-либо отношения (в нашем случае отношение частичного порядка). Область притяжения G можно рассматривать как своеобразную окрестность нейронного радиуса, отвечающего подмножеству фактор-множества, наиболее близкому к вектору наблюдаемого параметра.

Поскольку

$$S_k = \max_j S_j, \quad (10)$$

тогда элемент фактор-множества в дискретном виде принимает вид:

$$X_j^{\phi} = h(S_j) = \begin{cases} 1, & \text{если } j \in G, \\ 0, & \text{если } j \notin G, \end{cases} \quad (11)$$

где $j = 1 \dots m$.

В непрерывном варианте в качестве метрики можно использовать значение функции Гаусса (12) (так как называемой функции «мексиканская шляпа») (рис. 3).

$$h(j,k,t) = e^{-\frac{|u_k - u_j|^2}{2\sigma^2(t)}}, \quad (12)$$

где $(u_k - u_j)$ – расстояние между нейронами, $\sigma(t)$ – среднеквадратичное отклонение (радиус области притяжения).

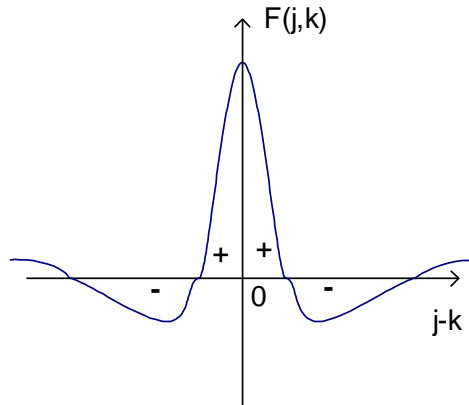


Рис. 3. Вид функции притяжения

В процессе самоорганизации НС Кохонена изменяются весовые коэффициенты не только нейрона победителя, но и всех нейронов внутри области притяжения. Следовательно, для j – го нейрона весовой вектор изменяется по правилу

$$V_j^{(1)}(t+1) = V_j^{(1)}(t) + \gamma(t)h(j,k,t)(X(t) - V_j^{(1)}(t)), \quad (13)$$

второе слагаемое выражения (13) с учетом невязки $(X(t) - V_j^{(1)}(t))$ определяется формулой (12).

С увеличением времени обучения радиус области притяжения уменьшается, и нейронные элементы сжимаются около нейрона-победителя до тех пор, пока он не останется один. В результате происходит выделение обобщенного признака ситуации, т.е. формирование прототипа.

Таким образом, первая компонента гибридной НС, используемой в системе прогнозирования на основе НС Кохонена осуществляет редукцию пространства наблюдаемых параметров X , реализуя процедуру факторизации пространства параметров КА. При этом таблица обучения (обучающая выборка) для НС Кохонена формируется на основе протокола наблюдений R . В результате предложенного упорядочивания пространства признаков (параметров) синтезируется оператор преобразования входного вектора наблюдаемых параметров в вектор обобщенных параметров (фактов) – прототип. Полученные элементы фактор-множества X^ϕ используются в качестве входного вектора для второй компоненты нейросетевой модели.

Оставшиеся операции, необходимые для получения прогноза, реализуются второй компонентой нейросетевой системы прогнозирования.

Известно [5-8], что выходные значения (решения о принадлежности классу ТС) для нейронной сети с одним скрытым слоем в векторном виде определяются следующим образом:

$$\xi : Y^{t+1} = F(F(X^\phi W^{(1)})W^{(2)}), \quad (14)$$

где $X^\phi = (x_1^\phi, x_2^\phi, \dots, x_m^\phi)$ – входной вектор параметров (фактов);

F – оператор нелинейного преобразования;

W – матрицы синаптических весов.

Обозначив выходные величины выходного скрытого и входного слоев через X_λ и X_p соответственно, а веса связей между λ – м элементом скрытого слоя и p – м элементом выходного слоя и m – м элементом входного слоя и λ – м элементом скрытого слоя через $W_{\lambda p}$ и $W_{m\lambda}$ (рис. 4) получим на выходном слое

$$X_p = f(\text{net}_p), \quad (15)$$

где

$$net_p = \sum_{\lambda} w_{\lambda p} x_{\lambda} - \theta_p, \quad (16)$$

а на скрытом слое

$$X_{\lambda} = f(net_{\lambda}), \quad (17)$$

где

$$net_{\lambda} = \sum_m w_{m\lambda} x_m^{\Phi} - \theta_{\lambda}, \quad (18)$$




Рис. 4. Структура нейросети прямого распространения с одним скрытым слоем

Выбранная нами в результате предварительного анализа функция активации сигмоидного типа имеет вид:

$$f(x) = \frac{1}{1 + \exp(-x)}. \quad (19)$$

Количество нейронов L в скрытом слое определяется из эмпирических выражений [2]

$$\frac{tN}{1 + \log_2 N} \leq L_w \leq t \left(\frac{N}{t} + 1 \right) (m + t + 1) + t, \quad (20)$$

$$L = \frac{L_w}{n + m}, \quad (21)$$

где m – размерность входного сигнала;

n – размерность выходного сигнала (вектора прогноза Y_n^{t+1});

N – число пар «прототип ситуации – следствие» (множество элементов обучающей выборки);

L_w – число синаптических связей (весовых коэффициентов).

Таким образом, предлагаемая нейросетевая модель контроля и прогнозирования технического состояния КА, относящаяся к классу модульных моделей, позволяет последовательно реализовать оператор «факторизации», формирующий прототип и оператор прогнозирования.

Алгоритмы прогнозирования

Процедуру функционирования системы прогноза ТС КА можно представить в виде алгоритма нейросетевого вывода относительно следствий Y^{t+1} (ТС объекта) не наблюдавшихся ранее причин x_2^t , состоящего из девяти шагов.

Шаг 1. Формирование обучающей выборки по данным предварительных исследований (испытаний) сложного объекта или его элементов в различных условиях и на различных этапах создания. Выбор объектов, информация о поведении которых включается в обучающую выборку, осуществляется исходя из заданной степени компактности расположения наблюдаемых ситуаций $\Pi_k = (Y_k^t, Z_k, K_k, Y_k^{t+1})$, $k = 1, \dots, N$ в пространстве их признаков.

Шаг 2. Формирование архитектуры модульной НС с учетом условия (20), где $N(V+1)$ – количество нейронов слоя Кохонена. Задание вида функции f_1 активации нейронов слоя Кохонена и f_2 персептрона.

Шаг 3. Обучение модульной НС (по отдельности НС прямого распространения и НС Кохонена) распознаванию ситуаций $\Pi_k = (Y_k^t, Z_k, K_k, Y_k^{t+1})$, $k = 1, \dots, N1$, зафиксированных в период предварительной обработки КА протоколом R .

Шаг 4. Верификация модели на основе вектора признаков ситуации $X_2^t = \{x_i\}, i = 1, \dots, N2$, входящих во вторую часть протокола испытаний R (не использовавшуюся в обучении модели).

Шаг 5. Проверка условия:

$$D = \frac{m}{M} \geq \varepsilon,$$

где m – число совпадений вектора прогноза $Y_{M_i}^{t+1}$ с истинным значением Y_i^{t+1} , причем вектор причин

$$\emptyset_2^t : X_1^t \cap X_2^t = \quad , \quad X_1^t \cup X_2^t = X^t, \quad \text{к общему числу } M \text{ прогнозов.}$$

Шаг 6. Предъявление на вход сети компонент вектора X признаков ситуации, не содержащегося в протоколе предварительных испытаний R .

Шаг 7. Определение усредненного образа ситуации – прототипа, путем выделения «истинного» нейрона в слое Кохонена.

Шаг 8. Предъявление прототипа Y_Φ^t на вход двухслойного персептрона.

Шаг 9. Выдача прогноза Y^{t+1} .

Разработанный алгоритм позволяет реализовать нейросетевой вывод вектора прогнозов Y^{t+1} на основе априорной информации протокола испытаний R и выработки протокола ситуаций в пространстве параметров КА в реальном времени.

Заключение

Проведенное экспериментальное исследование разработанных моделей и алгоритмов позволяют сделать следующие выводы:

1. Использование нейронной сети Кохонена позволило уменьшить размерность пространства входных параметров в три раза и выработать прототип ситуации в виде вектора обобщенных параметров, причем выработка прототипа была осуществлена за 1284 итерации.

2. В результате обучения двухслойного персептрона сформированы две синаптические матрицы $W^{(1)}$ и $W^{(2)}$, позволяющие реализовать оператор прогнозирования с требуемой ошибкой прогноза.

3. Оценка ошибки тестирования и финальной ошибки распознавания проводилась с помощью таблицы тестирования, включающей в себя 200 пар «вход (объект) – выход (прототип ТС)».

4. Настройка параметров сети (формирование синаптических матриц $W^{(1)}$ и $W^{(2)}$) проведена градиентным методом и за 11400 итераций выявлена ошибка (значение целевой функции), равная 0.07, при этом целевая функция два раза попадала в локальные минимумы, что потребовало выведения из них путем увеличения значения целевой функции с последующим проведением итераций до достижения такого локального минимума, который отвечает требуемому значению целевой функции.

Таким образом, разработанные модели и алгоритмы позволяют оперативно реализовать нейросетевой вывод вектора прогнозов на основе априорной информации протокола испытаний и выработки протокола ситуаций в пространстве параметров КА в реальном времени. Алгоритм применяется в задачах прогноза ТС современных КА [9-18].

Благодарности

Работа поддержана Грантом РФФИ в рамках научного проекта № 16-29-04326 офм.

Литература

1. Веремей Е.И. Когнитивная реализация оптимизационного подхода к синтезу законов управления подвижными объектами // Современные информационные технологии и ИТ-образование. – 2016. – Т. 12, № 1. – С. 98-107.
2. Veremey E. Cognitive implementation of optimization approach to the control system design for moving objects // Convergent Cognitive Information Technologies (Convergent 2016), Moscow, Russia, November 25-26, 2016. – 2016. Vol. 1763. – P. 98-107. URL: <http://ceur-ws.org/Vol-1763/> (дата обращения: 29.07.2017).
3. Нечаев В.В., Гончаренко В.И., Рожнов А.В., Лычев А.В., Лобанов И.А. Интеграция компонентов виртуальной семантической среды и обобщенной модели анализа среды функционирования // Современные информационные технологии и ИТ-образование. – 2016. – Т. 12, № 3, часть 1. – С. 187-194.
4. Nechaev V., Goncharenko V., Rozhnov A., Lytchev A., Lobanov I. Integration of virtual semantic environments components and generalized Data Envelopment Analysis (DEA) model // CEUR Workshop Proceedings (CEUR-WS.org): Selected Papers of the XI International Scientific-Practical Conference Modern Information Technologies and IT-Education (SITITO 2016), Moscow, Russia, November 25-26, 2016. – 2016. Vol. 1761. – P. 339-347. URL: <http://ceur-ws.org/Vol-1761/> (дата обращения: 29.07.2017).
5. Назаров А.В., Лоскутов А.И. Нейросетевые алгоритмы прогнозирования и оптимизации систем. СПб.: Наука и техника, 2003.
6. Амосов Н. М. и др. Нейрокомпьютеры и интеллектуальные роботы. – Киев: Наук. Думка, 1991. – 272 с.
7. Головки В. А. Нейронные сети: обучение организация и применение. Кн.4: Учеб. пособие для вузов / Общая ред. А.И. Галушкина. – М.: ИПРЖ, 2001. – 256 с.
8. Полоус А.И., А.Г. Волков Интеллектуальные методы и модели диагностирования РТС (системы искусственного интеллекта). – М.: ВА РВСН им. Петра Великого, 2005.
9. Гончаренко В.И., Легович Ю.С., Рывкин С.Е. Обработка телеметрической информации о кинематических параметрах движения летательных аппаратов на основе дискретного вейвлет-преобразования // Доклады 18-й международной конференции. Серия: "Цифровая обработка сигналов и её применение– DSPA-2016" (30 марта – 01 апреля 2016 г.). 2016. Том 1, выпуск: XVIII-1. – М.: РНТОРЭС имени А.С. Попова. С. 442-447.
10. Беневольский С.В., Гончаренко В.И., Кучерявенко Д.С. Определение кинематических параметров движения летательных аппаратов на основе фильтрации телеметрических измерений // Вестник Казанского государственного технического университета им. А.Н. Туполева, 2012. № 1. С. 10-17.
11. Оганджян С.Б., Рожнов А.В., Бурмистров П.А., Лобанов И.А., Тюрин С.А. Творческие материалы «круглого стола». Часть I. Ретроспектива и реальная конкорданция исследований в сфере интеллекта // Нейрокомпьютеры: разработка, применение. 2016. № 1. С. 17-29.
12. Рожнов А.В. Творческие материалы «круглого стола». Часть II. Системная интеграция и моделирование новых эффектов в сфере интеллекта // Нейрокомпьютеры: разработка, применение. 2016. № 3. С. 3-12.
13. Гончаренко В.И., Легович Ю.С., Рывкин С.Е. Обработка телеметрической информации о кинематических параметрах движения летательных аппаратов на основе дискретного вейвлет-преобразования // Доклады 18-й международной конференции. Серия: "Цифровая обработка сигналов и её применение– DSPA-2016" (Москва, 30 марта – 01 апреля 2016 г.). 2016. Том 1, выпуск: XVIII-1. – М.: РНТОРЭС имени А.С. Попова. С. 442-447.
14. Рожнов А.В., Лобанов И.А., Бимаков Е.В. Обоснование задач системной интеграции и информационно-аналитическое моделирование проблемно-ориентированных системы управления на предпроектном этапе жизненного цикла / Труды XII Всероссийского совещания по проблемам управления (Москва). М.: ИПУ РАН, 2014. С. 7474-7479.
15. Рожнов А.В., Губин А.Н., Михайлов Р.А., Белавкин П.А. Становление вычислительных систем и комплексов военного назначения на заре стратегических ракетных войск // Нейрокомпьютеры: разработка, применение. 2010, № 11. С. 62-68.
16. Гончаренко В.И., Кобзарь А.А., Корнеев А.А., Кучерявенко Д.С. Алгоритм оценивания характеристик баллистического объекта при неизвестных параметрах его математической модели движения и некачественной измерительной информации // Вестник Казанского государственного технического университета им. А.Н. Туполева, 2011. № 4. С. 128-135.
17. Гончаренко В.И., Кучерявенко Д.С., Гойденко В.К., Скорик Н.А. Распознавание типа аварийной ситуации при испытании беспилотного космического аппарата на основе использования вейвлет-преобразования // Нейрокомпьютеры: разработка, применение. 2016. №1. С. 39-48.
18. Полоус А.И., Волков А.Г., Бурый А.С. Устройство для допускового контроля функциональных состояний технических систем. Патент на изобретение 2222823 RU. 27.05.2002.

References

1. Veremey E.I. Kognitivnaja realizacija optimizacionnogo podhoda k sintezu zakonov upravlenija podvizhnymi ob#ektami // Sovremennye informacionnye tehnologii i IT-obrazovanie. – 2016. – Т. 12, № 1. – S. 98-107.
2. Veremey E. Cognitive implementation of optimization approach to the control system design for moving objects // Convergent Cognitive Information Technologies (Convergent 2016), Moscow, Russia, November 25-26, 2016. – 2016. Vol. 1763. – P. 98-107. URL: <http://ceur-ws.org/Vol-1763/> (дата обращения: 29.07.2017).
3. Nechaev V.V., Goncharenko V.I., Rozhnov A.V., Lytchev A.V., Lobanov I.A. Integracija komponentov virtual'noj semanticheskoy sredy i obobshhennoj modeli analiza sredy funkcionirovanija // Sovremennye informacionnye tehnologii i IT-obrazovanie. – 2016. – Т. 12, № 3, chast' 1. – S. 187-194.
4. Nechaev V., Goncharenko V., Rozhnov A., Lytchev A., Lobanov I. Integration of virtual semantic environments components and generalized Data Envelopment Analysis (DEA) model // CEUR Workshop Proceedings (CEUR-WS.org): Selected Papers of the XI International Scientific-Practical Conference Modern Information Technologies and IT-Education (SITITO 2016), Moscow, Russia, November 25-26, 2016. – 2016. Vol. 1761. – P. 339-347. URL: <http://ceur-ws.org/Vol-1761/> (дата обращения: 29.07.2017).
5. Nazarov A.V., Loskutov A.I. Nejrossetevye algoritmy prognozirovanija i optimizacii sistem. SPb.: Nauka i tehnika, 2003.
6. Amosov N. M. i dr. Nejrokomp'jutery i intellektual'nye roboty. – Kiev: Nauk. Dumka, 1991. – 272 s.
7. Golovko V. A. Nejronnye seti: obuchenie organizacija i primenenie. Kn.4: Ucheb. posobie dlja vuzov / Obshhaja red. A.I. Galushkina. – М.: IPRZh, 2001. – 256 s.
8. Polous A.I., A.G. Volkov Intellektual'nye metody i modeli diagnostirovanija RTS (sistemy iskusstvennogo intellekta). – М.: VA RVSН im. Petra Velikogo, 2005.
9. Goncharenko V.I., Legovich Ju.S., Ryvkin S.E. Obrabotka telemetricheskoy informacii o kinematicheskikh parametroh dvizhenija letatel'nyh apparatov na osnove diskretnogo vejvlet-preobrazovanija // Doklady 18-j mezhdunarodnoj konferencii. Serija: "Cifrovaja obrabotka signalov i ejo primenenie– DSPA-2016" (30 marta – 01 aprelya 2016 g.). 2016. Tom 1, vypusk: XVIII-1. – М.: RNTORJeS imeni A.S. Popova. S. 442-447.

10. Benevol'skij S.V., Goncharenko V.I., Kucherjavenko D.S. Opredelenie kinematičeskikh parametrov dvizhenija letatel'nyh apparatov na osnove fil'tracii telemetričeskikh izmerenij // Vestnik Kazanskogo gosudarstvennogo tehničeskogo universiteta im. A.N. Tupoleva, 2012. № 1. S. 10-17.
11. Ogandzhanjan S.B., Rozhnov A.V., Burmistrov P.A., Lobanov I.A., Tjurin S.A. Tvorcheskije materialy «kruglogo stola». Čast' I. Retrospektiva i real'naja konkordancija issledovanij v sfere intellekta // Nejrokomp'jutery: razrabotka, primenenie. 2016. № 1. S. 17-29.
12. Rozhnov A.V. Tvorcheskije materialy «kruglogo stola». Čast' II. Sistemnaja integracija i modelirovanie novyh jeffektov v sfere intellekta // Nejrokomp'jutery: razrabotka, primenenie. 2016. № 3. S. 3-12.
13. Goncharenko V.I., Legovich Ju.S., Ryvkin S.E. Obrabotka telemetričeskoi informacii o kinematičeskikh parametroh dvizhenija letatel'nyh apparatov na osnove diskretnogo vejjvet-preobrazovanija // Doklady 18-j mezhdunarodnoj konferencii. Serija: "Cifrovaja obrabotka signalov i ejo primenenie- DSPA-2016".(Moskva,30 marta – 01 apreļa 2016 g.). 2016. Tom 1, vypusk: XVIII-1. – M.: RNTORJeS imeni A.S. Popova. S. 442-447.
14. Rozhnov A.V., Lobanov I.A., Bimakov E.V. Obosnovanie zadach sistemnoj integracii i informacionno-analičeskoe modelirovanie problemno-orientirovannyh sistemy upravlenija na predproektnom jetape zhiznennogo cikla / Trudy XII Vserossijskogo soveshhanija po problemam upravlenija (Moskva). M.: IPU RAN, 2014. S. 7474-7479.
15. Rozhnov A.V., Gubin A.N., Mihajlov R.A., Belavkin P.A. Stanovlenie vychislitel'nyh sistem i kompleksov voennogo naznachenija na zare strategičeskikh raketnyh vojsk // Nejrokomp'jutery: razrabotka, primenenie. 2010, № 11. S. 62-68.
16. Goncharenko V.I., Kobzar' A.A., Korneev A.A., Kucherjavenko D.S. Algoritm ocenivanja harakteristik ballističeskogo ob#ekta pri neizvestnyh parametroh ego matematičeskoi modeli dvizhenija i nekachestvennoj izmeritel'noj informacii // Vestnik Kazanskogo gosudarstvennogo tehničeskogo universiteta im. A.N. Tupoleva, 2011. № 4. S. 128-135.
17. Goncharenko V.I., Kucherjavenko D.S., Gojdenko V.K., Skorik N.A. Raspoznavanie tipa avarijnoj situacii pri ispytanii bespilotnogo kosmičeskogo apparata na osnove ispol'zovanija vejjvet-preobrazovanija // Nejrokomp'jutery: razrabotka, primenenie. 2016. №1. S. 39-48.
18. Polous A.I., Volkov A.G., Buryj A.S. Ustrojstvo dlja dopuskovogo kontrolja funkcional'nyh sostojanij tehničeskikh sistem. Patent na izobrenenie 2222823 RU. 27.05.2002.

Об авторах:

Волков Андрей Геннадьевич, кандидат технических наук, доцент, Финансовый университет при Правительстве Российской Федерации, volkov-ag@mail.ru

Нечаев Валентин Викторович, доктор физико-математических наук, профессор, профессор кафедры «Интеллектуальные технологии и системы», Московский технологический университет (МИРЭА), sukhomlin@mail.ru

Гончаренко Владимир Иванович, доктор технических наук, доцент, директор Военного института, Московский авиационный институт (национальный исследовательский университет); ведущий научный сотрудник лаборатории «Системная интеграция средств управления», Институт проблем управления имени В.А. Трапезникова РАН, vladimirgonch@mail.ru

Лобанов Игорь Александрович, научный сотрудник лаборатории «Системная интеграция средств управления», Институт проблем управления имени В.А. Трапезникова РАН, a.ji@bk.ru

Note on the authors:

Volkov Andrei G., Candidate of Engineering Sciences, Associate professor, Financial University under the Government of the Russian Federation, volkov-ag@mail.ru

Nechaev Valentin V., Doctor of Engineering Sciences, Full Professor, head of the laboratory of open information technologies faculty of computational mathematics and Cybernetics, Moscow Technological University (MIREA), sukhomlin@mail.ru

Goncharenko Vladimir I., Doctor of Engineering Sciences, Research Officer, Director of the Military Institute, Moscow Aviation Institute (National Research University); Leading Researcher of the Laboratory of System Integration of the Control Means, V.A. Trapeznikov Institute of Control Sciences of Russian Academy of Sciences, vladimirgonch@mail.ru

Lobanov Igor A., Researcher, Laboratory No. 29 (Laboratory of system integration), Trapeznikov Institute of Control Sciences of Russian Academy of Sciences, a.ji@bk.ru