

ИНФОРМАЦИОННО-ИЗМЕРИТЕЛЬНЫЕ И УПРАВЛЯЮЩИЕ СИСТЕМЫ

УДК 629.7.017

doi:10.21685/2307-5538-2021-1-1

НЕЙРОСЕТЕВОЙ ПОДХОД К КЛАСТЕРИЗАЦИИ КОНТРОЛИРУЕМЫХ ПАРАМЕТРОВ КАК ОДНОГО ИЗ ЭТАПОВ АВТОМАТИЗАЦИИ ПРОЦЕССА ИДЕНТИФИКАЦИИ СЛОЖНЫХ ТЕХНИЧЕСКИХ ОБЪЕКТОВ

А. И. Лоскутов¹, В. А. Клыков², Е. А. Ряхова³, А. В. Столяров⁴, О. Л. Шестопалова⁵

^{1,2,3,4} Военно-космическая академия имени А. Ф. Можайского, г. Санкт-Петербург, Россия

⁵ Филиал «Восход» Московского авиационного института, г. Байконур, Казахстан

^{1,2} vka@mil.ru

Аннотация. *Актуальность и цели.* Рассматриваются вопросы автоматизации процесса идентификации сложных технических объектов (СТО). Осуществлена постановка задачи автоматизации процесса идентификации сложных технических объектов на основе решения задачи кластеризации контролируемых параметров. Целью работы является применение нейросетевого метода кластеризации в автоматизации этапа процесса построения модели функционирования СТО. *Материалы и методы.* Представлен подход к кластеризации контролируемых параметров с использованием самоорганизующейся нейронной сети Кохонена. Новизна подхода заключается в применении известного нейросетевого метода кластеризации данных в новой области, а именно автоматизации процесса одного из этапов математического моделирования функционирования СТО. *Результаты.* Разработан алгоритм кластеризации контролируемых параметров по состояниям систем. Представлена обобщенная структурная схема системы автоматической идентификации с применением нейронной сети. Произведена оценка результатов моделирования на основе сопоставления полученных кластеров контролируемых параметров с данными вербальной модели СТО. *Вывод.* Анализ полученных результатов в ходе проведенного исследования показал, что применение нейронной сети при кластеризации контролируемых параметров возможно в качестве реализации одного из этапов автоматизации процесса идентификации СТО.

Ключевые слова: сложный технический объект, нейронная сеть, идентификация, кластеризация

Для цитирования: Лоскутов А. И., Клыков В. А., Ряхова Е. А., Столяров А. В., Шестопалова О. Л. Нейросетевой подход к кластеризации контролируемых параметров как одного из этапов автоматизации процесса идентификации сложных технических объектов // Измерения. Мониторинг. Управление. Контроль. 2021. № 1. С. 5–16. doi:10.21685/2307-5538-2021-1-1

NEURAL NETWORK APPROACH TO CLUSTERIZATION OF CONTROLLED PARAMETERS AS ONE OF THE STAGES OF AUTOMATION OF THE IDENTIFICATION OF DIFFICULT TECHNICAL OBJECTS

A.I. Loskutov¹, V.A. Klykov², E.A. Ryakhova³, A.V. Stolyarov⁴, O.L. Shestopalova⁵

^{1,2,3,4} Military Space Academy named after A. F. Mozhaisky, St. Petersburg, Russia

⁵ Voskhod branch Moscow Aviation Institute, Baykonur, Kazakhstan

^{1,2} vka@mil.ru

Abstract. *Background.* The article discusses the issues of automation of the process of identification of complex technical objects (STO). The problem of automating the process of identification of complex technical objects is

formulated on the basis of solving the problem of clustering of controlled parameters. The aim of the work is to use the neural network clustering method in automating the stage of the process of building a model of the STO functioning. *Materials and methods.* An approach to the clustering of controlled parameters using a self-organizing neural network (NN) of Kohonen is presented. The novelty of the approach lies in the application of the well-known neural network method of data clustering in a new area, namely, the automation of the process of one of the stages of mathematical modeling of the STO functioning. *Results.* An algorithm for clustering the controlled parameters according to the states of systems has been developed. The generalized block diagram of the automatic identification system using the NN is presented. The results of modeling were evaluated based on the comparison of the obtained clusters of controlled parameters with the data of the verbal model of STO. *Conclusion.* The analysis of the results obtained in the course of the study showed that the use of a neural network in the clustering of controlled parameters is possible as an implementation of one of the stages of automation of the STO identification process.

Keywords: complex technical object, neural network, identification, clustering

For citation: Loskutov A.I., Klykov V.A., Rjahova E.A., Stoljarov A.V., Shestopalova O.L. Neural network approach to clusterization of controlled parameters as one of the stages of automation of the identification of difficult technical objects. *Izmereniya. Monitoring. Upravlenie. Kontrol' = Measurements. Monitoring. Management. Control.* 2021;1:5–16. (In Russ.). doi:10.21685/2307-5538-2021-1-1

Введение

Известно [1], что под сложным техническим объектом понимается сложный управляемый объект, информация о функциональном состоянии которого передается в виде текущих значений измерительной информации в соответствующую систему управления. В настоящее время при проведении испытаний СТО в процессе их подготовки к применению по назначению в основном используются эвристические модели функционирования, содержащиеся в эксплуатационно-технической документации в неформализованном или слабо формализованном виде [1]. В то же время автоматизация процесса испытаний сложных технических объектов на базе ЭВМ невозможна без использования математических моделей функционирования СТО. В свою очередь, использование математических моделей позволяет широко применять возможности ЭВМ в контуре испытаний СТО. Однако построение рассматриваемого типа моделей связано с трудностями анализа всего множества состояний вследствие большого числа контролируемых параметров [2–4]. На практике это приводит к тому, что при проведении испытаний СТО возможно получить параметры (состояния), неучтенные на начальном этапе построения модели. Данный факт приводит к несоответствию модели и объекта испытаний и, как следствие, к увеличению различного рода затрат при повторном моделировании, а также ставит вопрос о целесообразности совершенствования существующего подхода в целом. Это создает предпосылки к необходимости автоматизации процесса построения модели функционирования СТО на основе использования эффективных математических инструментов.

Постановка задачи автоматизации процесса идентификации сложных технических объектов на основе решения задачи кластеризации контролируемых параметров

Под идентификацией понимается процедура построения оптимальной (наилучшей) в определенном смысле математической модели (ее структуры и параметров) объекта по реализациям его наблюдаемых входных и выходных сигналов [4]. В общем случае с математической точки зрения задачей идентификации является нахождение оператора F_m , который бы в определенном смысле был близок оператору F , связывающему входные и выходные переменные объекта:

$$F_m \approx F. \quad (1)$$

Отметим, что «близость» согласно выражению (1) является весьма условной, а тождественное совпадение F и F_m вообще практически невозможно. Для количественной оценки расхождения операторов F и F_m используется скалярная функция γ , которая в общем виде может быть определена как [4]

$$\gamma = \gamma[Y, F_m(X)], \quad (2)$$

где Y – вектор наблюдаемых выходных переменных; X – вектор входных переменных.

Также известно [4], что процесс идентификации условно заключается в реализации основных этапов, а именно: определении функции выхода, решении задачи классификации над множеством контролируемых параметров и в конечном итоге определении математической структуры над базисными множествами, полученными как в результате решения задачи классификации, так и при подготовке исходных данных для проведения идентификации. Необходимо отметить, что время, затрачиваемое на реализацию данных этапов, с учетом применения эвристического подхода может изменяться в интервале от нескольких часов до нескольких дней, что при наличии ошибок в моделировании в некоторых случаях может привести к экспоненциальному росту временных затрат. Данное обстоятельство подчеркивает актуальность автоматизации этапов математического моделирования СТО. Исходя из этого задача классификации может быть переформатирована под задачу кластеризации. Результатом выполнения данной задачи является определение фактор-множества состояний объекта и множества видов его технических состояний (состояний, синтезированных в рамках создаваемой математической модели), которое находится во взаимно-однозначном отношении к первому. С формальной точки зрения реализация этапов автоматической идентификации может быть представлена в виде коммутативной диаграммы, представленной на рис. 1 [4].

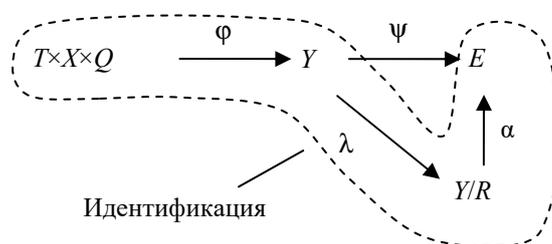


Рис. 1. Коммутативная диаграмма процесса идентификации аппаратуры сложных технических объектов: $\phi: T \times X \times Q \rightarrow Y$ – отображение множества текущих состояний объекта в множество параметров; $\lambda: Y \rightarrow Y/R$ – отображение, которое обозначает операцию факторизации, где R – бинарное отношение эквивалентности, обладающее свойствами рефлексивности, симметричности, транзитивности; $\psi: Y \rightarrow E$ – отображение отнесения наблюдаемого состояния к одному из заданных видов технического состояния (в рамках создаваемой математической модели); $\alpha: Y/R \rightarrow E$ – взаимно-однозначное отображение фактор-множества и видов технического состояния (в рамках создаваемой математической модели)

Необходимо отметить, что представленная коммутативная диаграмма не отражает процесс определения отношений над базисными множествами как конечный этап построения математической модели объекта испытаний.

Исходя из анализа коммутативной диаграммы, можно заметить, что кластеризация ψ контролируемых параметров, в свою очередь, есть реализация двух отображений, а именно: отображение λ , реализующее определение фактор-множества над полем контролируемых параметров, и отображение α , реализующее взаимно-однозначное соответствие между полученным фактор-множеством и видами технического состояния (кластерами). Также необходимо отметить, что при идентификации кластеризация является одним из наиболее важных этапов вследствие того, что правильное решение данной задачи будет характеризовать степень соответствия между операторами F_m и F с точностью или разрешающей способностью, необходимой для решения целевых задач. В настоящее время существует несколько подходов к кластеризации и все они основаны на использовании специфичной для каждой предметной области дополнительной информации [5–7]. В свою очередь, необходимо отметить, что задача кластеризации требует своего решения не только на этапе моделирования, но и на всем периоде эксплуатации объекта.

Таким образом, постановка задачи автоматизации процесса идентификации СТО с математической точки зрения может быть представлена как задача минимизации временных затрат при построении функции (2) на основе кластеризации контролируемых параметров как одного из этапов построения математической модели.

Дано:

1) набор множеств $M = \{Q, T, X, Y\}$, определяющих исходные данные для построения математической структуры (модели объекта испытаний). Необходимо отметить, что исходный набор может быть изменен, учитывая то, как именно должен быть формализован СТО. Однако в самом общем случае данный набор должен включать в себя следующие множества: множество текущих состояний объекта испытаний Q , множество моментов времени T , множество управляющих воздействий X , множество контролируемых параметров Y ;

2) $H = \langle h_1, \dots, h_n, \varphi \rangle$ – набор отношений над базисными множествами M ;

3) функция выхода, реализуемая с помощью отображения φ , заданного над множеством M ;

4) функция невязки γ (показатель идентификации), характеризующая несоответствие операторов F_m и F ;

5) способ K решения задачи кластеризации ψ на основе применения соответствующего математического инструмента;

6) показатель временных затрат Z_T . Следует отметить, что данный показатель также может быть представлен в общем виде и характеризовать другие виды затрат.

Требуется: определить оператора $\tilde{F}_m \in F_m$ с минимально возможным уровнем затрат Z_T при условии достижения требуемого уровня показателя идентификации γ СТО на основе применения способа K при решении задачи кластеризации ψ ($\psi = \lambda \circ \alpha$) контролируемых параметров. Формализованная постановка задачи может быть представлена следующим образом:

$$\left. \begin{array}{l} \lambda: Y \rightarrow Y/R; \\ \alpha: Y/R \rightarrow E; \end{array} \right\} \Rightarrow \psi(K) \Rightarrow Z_T \xrightarrow{\gamma \geq \gamma_{\text{треб}}} \min \left\{ \begin{array}{l} M = \{Q, T, X, Y\}; \\ \varphi: T \times X \times Q \rightarrow Y; \\ H = \langle h_1, \dots, h_n, \varphi \rangle; \\ \gamma = \gamma[Y, F_m(X)]. \end{array} \right. \quad (3)$$

Следует отметить, что наиболее перспективным подходом к кластеризации и в то же время наиболее эффективным с точки зрения практической реализации является способ, основанный на применении нейронных сетей (НС) [5–7]. В свою очередь необходимо отметить, что в работе не рассматривается вопрос автоматического определения отношений над базисными множествами, определяющих суть построения математической модели объекта испытаний. Решение данного вопроса является сложной научной задачей и является предметом отдельных исследований.

Нейросетевой подход к кластеризации контролируемых параметров как одного из этапов автоматизации процесса идентификации сложных технических объектов

В общем случае нейросетевые методы кластеризации являются развитием классических методов кластеризации. Для решения обозначенной задачи (3) на основе анализа свойств нейронных сетей выберем сеть типа *SOM* (*Self-organizing map* – самоорганизующейся сети Кохонена). В применении к диагностированию СТО НС Кохонена применяется для:

- 1) комбинаторного поиска решений;
- 2) распознавания посредством кластеризации.

Алгоритм построения самоорганизующейся НС представляет собой синтез отображения многомерного распределения точек на N -мерную решетку с регулярным или случайным соседством между узлами. При этом близким узлам на карте отвечают близкие вектора в исходном многомерном пространстве, т.е. сохраняется не только структура разбиения точек на кластеры, но и отношения локальной топологической близости между ними [8]. В общем случае сеть Кохонена – это однослойная сеть, построенная из нейронов типа *WTA* (*Winner Takes All* – победитель получает все). Структура такой нейронной сети представлена на рис. 2 [9].

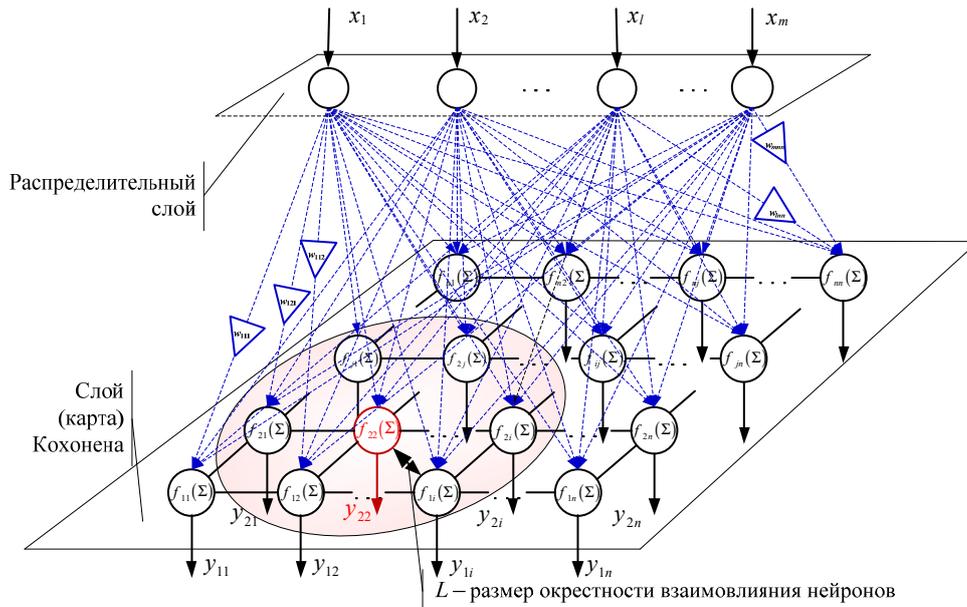


Рис. 2. Структура нейронной сети типа SOM

Алгоритм обучения заключается в выделении из всех нейронов слоя Кохонена лишь одного C -го нейрона, для которого взвешенная сумма входных сигналов максимальна:

$$C = \arg \max_i (x^T w_i). \tag{4}$$

В этом случае вследствие того, что сумма весов каждого нейрона $\sum_i w_{ij}$ слоя Кохонена одинакова и $x = 1$, условие (4) эквивалентно условию

$$C = \arg \max_i \|x - w_i\|. \tag{5}$$

Таким образом, будет активирован только тот нейрон, вектор весов которого w наиболее близок к входному вектору x . Поскольку перед началом обучения неизвестно, какой именно нейрон будет активироваться при предъявлении сети конкретного входного вектора, сеть обучается без учителя, т.е. самообучается. Число нейронов в слое Кохонена должно соответствовать числу классов входных сигналов. Вводя потенциальную функцию – функцию расстояния f_{ij} («соседства») между i -м и j -м нейронами с местоположениями на решетке r_i и r_j соответственно, монотонно убывающую с увеличением расстояния между этими нейронами, в обобщенном виде можно записать следующий алгоритм коррекции весов:

$$w_{ij}(k+1) = w_{ij}(k) + \alpha(k) f_{ij}(k) (x(k) - w_{ij}(k)), \tag{6}$$

где $\alpha(k) \in (0,1]$ – изменяющийся во времени коэффициент усиления ($\alpha = 1$ на первой итерации, постепенно уменьшая в процессе обучения до нуля); $f_{ij}(k)$ – монотонно убывающая функция расстояния:

$$f_{ij}(k) = f(\|r_i - r_j\|, k) = f(d, k) = f(d, L), \tag{7}$$

где r_i и r_j – векторы, определяющие положение нейронов i и j в решетке.

Параметр усиления α и радиус взаимодействия L изменяются с каждой k -й итерацией в соответствии с выражениями

$$\alpha(k) = \alpha(0) \left[\frac{\alpha_{\min}}{\alpha(0)} \right]^{k/k_{\max}}, \quad L(k) = L(0) \left[\frac{L_{\min}}{L(0)} \right]^{k/k_{\max}}, \tag{8}$$

где $\alpha(0) \approx 0,8$; $\alpha_{\max} \ll 1$; $\sigma(0) \approx 0,2$; $\alpha_{\min} = 0,5$ – параметры крутизны функции f_{ij} ; k_{\max} – максимально задаваемое число итераций обучения НС.

Х. Ритгером и К. Шультемом в работе [10] доказано, что обучение НС в соответствии с выражением (6) эквивалентно градиентному методу обучения, основанному на минимизации целевой функции

$$E(w) = \frac{1}{2} \sum_{i,j,k} f_{ij}(k) (x_j(k) - w_{ij}(k))^2. \quad (9)$$

В принятой метрике $d = \|r_i - r_j\|$ функция $f_{ij}(k)$ с ростом числа итераций k стремится к нулю. Вместо отсчетов k можно использовать параметр расстояния L , задающий величину области «соседства» и уменьшающийся с каждой итерацией k до нуля. Выбор функции $f_{ij}(L)$ влияет на величины весов всех нейронов в слое Кохонена, и для нейрона-победителя C

$$f_c(\|r_i - r_j\|) = f_c(0) = 1. \quad (10)$$

В случае евклидовой метрики:

$$d = \sum_k (r_{ik} - r_{jk})^2, \quad (11)$$

где r_{ik} и r_{jk} – координаты i -го и j -го нейронов двумерной регулярной решетки. Наиболее часто используемые функции соседства представлены в работе [10].

Применительно к рассматриваемому в работе подходу размерность пространства входного вектора будет определяться размерностью телеметрического образа $Y_{ij} = [y_{i1}, y_{i2}, \dots, y_{im}]^T$ ($j = 1, \dots, m$), полученного в результате определения функции выхода ϕ . Таким образом, отклик сети на входной вектор понимается как «нейрон-победитель», расстояние до которого от Y_{ij} минимально:

$$d(Y, W_j) = \min_{1 \leq i \leq n} d(Y, W_i), \quad (12)$$

где j – номер «нейрона-победителя» НС.

При обучении НС входные значения необходимо нормировать (нормирование входных данных положительным образом сказывается на скорости обучения сети), например, согласно работе [9].

В общем случае обучение самоорганизующейся сети Кохонена происходит до момента, когда выполняется любое из следующих условий [9]:

- 1) достигается максимальное число эпох;
- 2) достигается малая величина функционала ошибки, вычисляемая по формуле [9]

$$E = \frac{1}{Q} \sum_{i=1}^Q \|Y_i - W_{Y_i}\|^2, \quad (13)$$

где W_{Y_i} – вектор весов нейрона-победителя при предъявлении входного вектора Y_i ; Q – размер обучающей выборки;

- 3) превышено максимальное время обучения.

Процесс обучения самоорганизующейся сети Кохонена состоит из циклического повторения ряда шагов:

- 1) подача исходных данных на вход НС;
- 2) нахождение выхода каждого нейрона;
- 3) определение «нейрона-победителя»;
- 4) корректировка весов «выигравшего» нейрона по правилу Кохонена [9, 10]:

$$w_i^{k+1} = w_i^k + \eta_i^k [y - w_i^k], \quad (14)$$

где y – входной вектор НС; k – номер цикла обучения НС; η_i^k – коэффициент скорости обучения i -го нейрона в k -м цикле обучения.

Таким образом, обобщенная схема автоматизации процесса идентификации СТО на основе решения задачи кластеризации может быть представлена следующим образом (рис. 3).

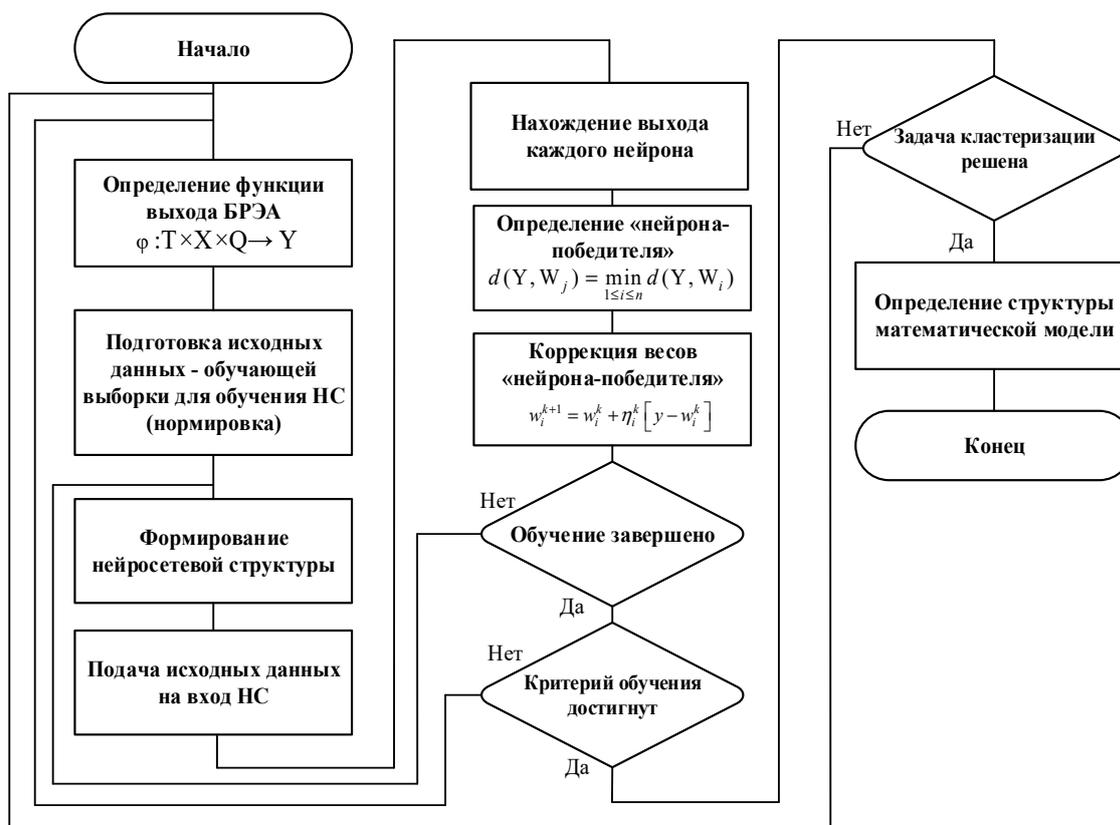


Рис. 3. Обобщенная блок-схема алгоритма обучения нейронной сети при решении задачи кластеризации

Очевидно, что представленный подход позволяет минимизировать временные затраты, а также с требуемой точностью решить задачу кластеризации как одного из этапов автоматизации процесса идентификации СТО. Рассмотрим возможность реализации нейросетевого подхода при кластеризации контролируемых параметров на этапе процесса идентификации СТО.

Пример нейросетевого подхода при кластеризации контролируемых параметров бортовой аппаратуры сложных технических объектов

В качестве исходных данных рассмотрим параметры СТО, в роли которого выступает радиопередающее устройство (РПУ) РПТ111. Данное устройство предназначено для формирования частотно-манипулированного сигнала дециметрового диапазона волн с переключающимися информативностями и переключаемой выходной мощностью. Прибор РПТ111 может эксплуатироваться в составе аппаратуры герметизированных и негерметизированных приборных отсеков космических аппаратов (КА), разгонных блоков (РБ). Данное РПУ разработано и эксплуатируется в составе РБ «Бриз-М», «Фрегат», КА «Фобос-Грунт» и др.

Передачик имеет выходные цепи контрольных сигналов: ТМА – мощность падающей волны, ТМОТР – мощность отраженной волны. Также при проведении испытаний РБ «Фрегат» параметром передатчика, подлежащим контролю, является ТМИ – контроль источника питания передатчика. Таким образом, размерность телеметрического образа РПУ РПТ111 равна трем. На основе рассмотренного выше алгоритма обучения представим пример реализации нейросетевого подхода к кластеризации контролируемых параметров как одного из этапов автоматизации процесса идентификации СТО. Необходимо отметить, что для простоты реализации нейросетевого подхода будут рассмотрены параметры только исправно функционирующей аппаратуры:

1. Определим функцию выхода φ радиопередающего устройства РПТ111. Данный этап связан с проведением большого числа экспериментов в лабораторных и натуральных условиях.

В число таких экспериментов входят также наблюдение за реально функционирующим объектом. В результате анализа литературы были получены значения функции выхода РПУ РПТ111 на 1500 элементов (векторов параметров).

2. На основании значений функции выхода φ радиопередающего устройства РПТ111 синтезируем обучающую выборку на 1500 элементов для обучения самоорганизующейся сети Кохонена. С целью обучения используем линейную нормировку при подготовке исходных данных. Фрагмент обучающей выборки представлен в табл. 2.

Таблица 2

Пример реализации обучающей выборки

Номер	ТМОТР	ТМА	ТМИ
1	0,768444	0,538603	0,637808
2	0,879992	0,517149	0,25121
3	0,776979	0,477883	0,383741
4	0,756759	0,294193	0,754547
5	0,847415	0,300105	0,721999
6	0,715172	0,212177	0,460506
7	0,699155	0,441099	0,396254
8	0,714076	0,422326	0,618255
9	0,82615	0,417174	0,700565
10	0,820944	0,49787	0,835965
...
1498	0,639071	0,244369	0,485797
1499	0,642749	0,313239	0,523842
1500	0,791009	0,380537	0,845319

3. Сформируем нейросетевую структуру для решения задачи кластеризации в пакете расширения Neural Network Toolbox системы MATLAB R2017a. Стандартная сеть, которая используется по умолчанию для кластеризации данных, является самоорганизующейся сетью Кохонена размером десять на десять ячеек. Размерность входного вектора равна размерности телеметрического образа. На рис. 4 приведена топология сформированной нейронной сети.

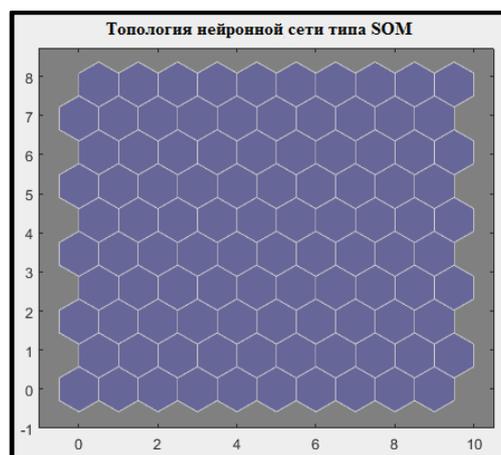


Рис. 4. Топология нейронной сети типа SOM

Из анализа рис. 4 видно, что топология карты является гексагональной, каждый из шестиугольников представляет собой нейрон. Карта имеет размеры 10 на 10 (содержит 100 нейронов). Каждый входной вектор содержит три элемента, поэтому входное пространство трехмерное. Карта отображает трехмерное пространство в двухмерное.

4. Произведем обучение нейросетевой структуры на основе сформированной в пункте 2 обучающей выборки. Оценим результаты в виде графика весов, называемого компонентной плоскостью – *Component Planes* и графика положения весов – *SOM Weight Positions*. На графике компонентной плоскости более темные цвета представляют большие веса. Одинаковыми

цветами отмечаются близкие веса. На рис. 5 видно, что состояния резко отличаются по первому и второму входам (параметры ТМИ и ТМА) и близки по третьему входу (параметр ТМОТР).

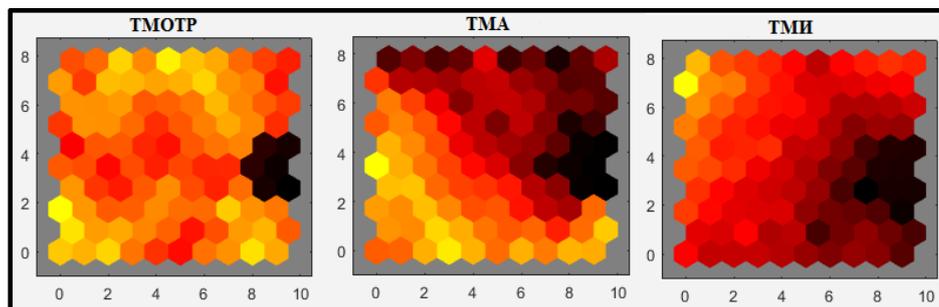


Рис. 5. Компонентные плоскости телеметрического образа РПУ РПТ111

График положения весов (рис. 6) показывает зелеными точками координаты входных векторов, определяемые по первым двум компонентам. Аналогично синими точками отображаются координаты векторов первых двух весов нейронов. Соседние нейроны соединяются красными линиями.

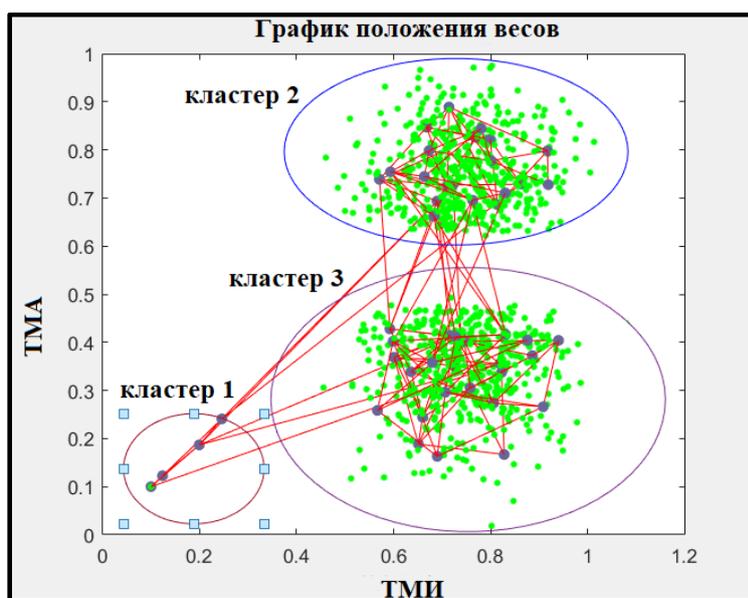


Рис. 6. График положения весов

Необходимо отметить, что для удобства восприятия полученных результатов график представлен в двухмерном пространстве. Удаленность объектов каждого из кластера соответствует требуемому значению качества кластеризации, обеспечив $\gamma_{\text{треб}}$ при $\tilde{F}_m \in F_m$. В свою очередь, анализ данных показал, что нейронная сеть сгруппировала телеметрический образ РПУ РПТ111 на три кластера. В табл. 3 представлены сформированные кластеры по диапазонам параметров передатчика.

Таблица 3

Сформированные кластеры в результате анализа НС телеметрического образа РПУ РПТ111

Кластер	ТМА	ТМОТР	ТМИ
1 (e_1)	0В	0В	0В
2 (e_2)	$4 \pm 1В$	Не более 0,5В	$3,8 \pm 0,8В$
3 (e_3)	$2 \pm 0,8В$	Не более 0,5В	$3,8 \pm 0,8В$

Как видно из табл. 3, сформированным кластерам соответствуют состояния по режимам работы передатчика и состоянию, когда РПТ111 выключен. В свою очередь время, затраченное на получение результата, находилось в пределах 30–40 мин, необходимо отметить, что основное время было потрачено на подготовку исходных данных ($T_{\text{исх дан}}$), а не кластеризацию ($T_{\text{кл}}$), т.е. $T_{\text{рез}} = T_{\text{исх дан}} + T_{\text{кл}}$, $T_{\text{исх дан}} \gg T_{\text{кл}}$. На рис. 7 представлено соотношение временных затрат на решение задачи классификации при эвристическом подходе (с учетом наличия полной вербальной модели процесса функционирования) и решение задачи кластеризации на основе применения НС, обеспечив минимальное значение Z_T .

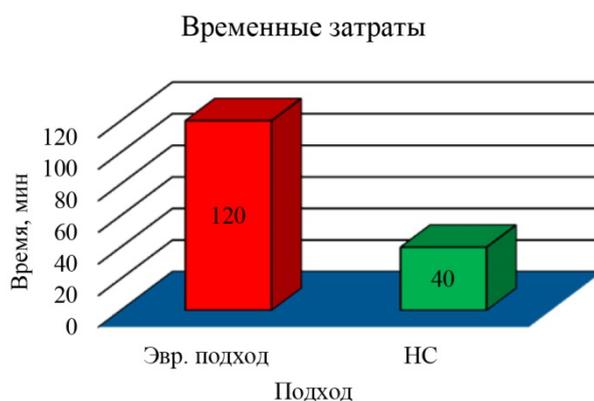


Рис. 7. Соотношение временных затрат при решении задачи классификации (эвристический подход) и кластеризации (НС)

Приведенный в работе пример кластеризации контролируемых параметров является наиболее простым примером реализации одного из этапов автоматизации процесса идентификации СТО на основе применения нейросетевого подхода ввиду небольшой размерности входного вектора. Проведенная кластеризация может быть без труда осуществлена и без применения НС. Однако на практике может возникнуть ситуация, когда количество контролируемых параметров (размерность входного вектора) будет на один или два порядка выше, тогда представленный в работе подход может быть реализован для кластеризации контролируемых параметров как одного из этапов автоматизации процесса идентификации СТО.

Заключение

Использование математических моделей позволяет широко использовать возможности ЭВМ в контуре испытаний СТО. Однако построение рассматриваемого типа моделей связано с определенными трудностями, одной из которых является так называемое «проклятие размерности» вследствие большого числа контролируемых параметров. В свою очередь ошибки, допущенные при проведении математического моделирования, могут иметь катастрофические последствия в дальнейшем. Для предотвращения негативных последствий «ручного» математического моделирования возникает необходимость автоматизации данного процесса. В свою очередь идентификация (процесс построения математической модели) СТО заключается в последовательном решении нескольких задач, одной из которых является задача классификации. Применительно к автоматизации процесса идентификации задача классификации должна быть переформатирована под задачу кластеризации. Анализ полученных результатов в ходе проведенного исследования показал, что применение нейронной сети при кластеризации контролируемых параметров возможно в качестве реализации одного из этапов автоматизации процесса идентификации СТО.

Список литературы

1. Охтилев М. Ю., Соколов Б. В., Юсупов Р. М. Интеллектуальные технологии мониторинга и управления структурной динамикой сложных технических объектов : монография. М. : Наука, 2006. 408 с. ISBN 5-02-033789-7.

2. Takahashi M., Kosaka R., Nanba R. A Study of Fault Tree Analysis for Control Program in Space System // 2015 IEEE/SICE International Symposium on System Integration : proc. 2015. P. 301–306.
3. Талалаев, А. А., Фраленко В. П., Хачумов В. М. Обзор стандартов и концепция построения средств мониторинга, контроля и диагностики космического аппарата // Программные системы: теория и приложения. 2015. № 3. С. 21–43.
4. Дмитриев А. К. Модели и методы анализа технического состояния бортовых систем. СПб. : ВИКУ им А. Ф. Можайского, 1999. 174 с.
5. Сидоревич А. Н. Алгоритмы кластеризации данных с использованием нейронных сетей // Статьи факультета радиофизики и компьютерных технологий. 2005. URL: <http://elib.bsu.by/handle/123456789/7648> (дата обращения: 18.09.2020).
6. Сырямкин В. И., Горбачев С. В., Сунцов С. Б. Адаптивные нейросетевые алгоритмы диагностики материалов, оборудования и радиоэлектронной аппаратуры. Saarbrücken : LAMBERT Academic Publishing, 2013. 269 с.
7. Zohrer M., Pernkopf F. General stochastic networks for classification. In NIPS'2014. 2014.
8. Хайкин С. Нейронные сети. Полный курс. 2-е изд., испр. М. : Вильямс, 2006. 1104 с.
9. Горбаченко В. И. Нейроинформатика : конспект лекций. – Пенза : Пенз. гос. пед. ун-т им. В. Г. Беллинского, 2011. 81 с.
10. Ritter H., Schulden K. On the stationary state of the Kohonen self-organizing sensory mapping // Biological Cybernetics. 1986. Vol. 54. P. 234–249.

References

1. Okhtilev M.Yu., Sokolov B.V., Yusupov R.M. *Intellektual'nye tekhnologii monitoringa i upravleniya strukturnoy dinamiko slozhnykh tekhnicheskikh ob'ektov: monografiya = Intelligent technologies for monitoring and controlling the structural dynamics of complex technical objects: monograph*. Moscow: Nauka, 2006:408. ISBN 5-02-033789-7. (In Russ.)
2. Takahashi M., Kosaka R., Nanba R. A Study of Fault Tree Analysis for Control Program in Space System. *2015 IEEE/SICE International Symposium on System Integration: proc.* 2015:301–306.
3. Talalaev, A.A., Fralenko V.P., Khachumov V.M. Overview of standards and the concept of building spacecraft monitoring, control and diagnostics tools. *Programmnye sistemy: teoriya i prilozheniya = Software systems: Theory and applications*. 2015;3:21–43. (In Russ.)
4. Dmitriev A.K. *Modeli i metody analiza tekhnicheskogo sostoyaniya bortovykh sistem = Models and methods for analyzing the technical condition of on-board systems*. Saint-Petersburg: VIKU im A. F. Mozhayskogo, 1999:174. (In Russ.)
5. Sidorevich A.N. Data clustering algorithms using neural networks. *Stat'i fakul'teta radiofiziki i kompyuternykh tekhnologiy = Articles of the Faculty of Radiophysics and Computer Technology*. 2005. Available at: <http://elib.bsu.by/handle/123456789/7648> (accessed 18.09.2020). (In Russ.)
6. Syryamkin V.I., Gorbachev S.V., Suntsov S.B. *Adaptivnye neyrosetevye algoritmy diagnostiki materialov, oborudovaniya i radioelektronnoy apparatury = Adaptive neural network algorithms for diagnostics of materials, equipment and radio-electronic equipment*. Saarbrücken: LAMBERT Academic Publishing, 2013:269. (In Russ.)
7. Zohrer M., Pernkopf F. *General stochastic networks for classification*. In NIPS'2014. 2014.
8. Khaykin S. *Neyronnye seti. Polnyy kurs. 2-e izd., ispr. = Neural networks. Full course. 2nd ed., revised*. Moscow: Vil'yams, 2006:1104. (In Russ.)
9. Gorbachenko V.I. *Neyroinformatika: konspekt lektsiy = Neuroinformatics: lecture notes*. Penza: Penz. gos. ped. un-t im. V. G. Belinskogo, 2011:81. (In Russ.)
10. Ritter H., Schulden K. *On the stationary state of the Kohonen self-organizing sensory mapping*. *Biological Cybernetics*. 1986;54:234–249.

Информация об авторах / Information about the authors

Андрей Иванович Лоскутов

доктор технических наук, профессор,
начальник кафедры телеметрических систем,
комплексной обработки и защиты информации,
Военно-космическая академия
имени А. Ф. Можайского
(Россия, г. Санкт-Петербург, ул. Ждановская, 13)
E-mail: vka@mil.ru

Andrey I. Loskutov

Doctor of technical sciences, professor,
head of sub-department of telemetry systems,
complex processing and protection of information,
Military Space Academy
named after A. F. Mozhaisky
(13 Zhdanovskaya street, St. Petersburg, Russia)

Владимир Алексеевич Клык

кандидат технических наук, преподаватель,
кафедра телеметрических систем,
комплексной обработки и защиты информации,
Военно-космическая академия
имени А. Ф. Можайского
(Россия, г. Санкт-Петербург, ул. Ждановская, 13)
E-mail: vka@mil.ru

Екатерина Александровна Ряхова

адъюнкт,
кафедра телеметрических систем,
комплексной обработки и защиты информации,
Военно-космическая академия
имени А. Ф. Можайского
(Россия, г. Санкт-Петербург, ул. Ждановская, 13)
E-mail: vka@mil.ru

Андрей Владимирович Столяров

адъюнкт,
кафедра телеметрических систем,
комплексной обработки и защиты информации,
Военно-космическая академия
имени А. Ф. Можайского
(Россия, г. Санкт-Петербург, ул. Ждановская, 13)
E-mail: vka@mil.ru

Ольга Львовна Шестопалова

кандидат технических наук, доцент,
декан факультета «Испытание летательных
аппаратов»,
филиал «Восход»
Московского авиационного института
(Казахстан, г. Байконур, ул. Гагарина, 5)
E-mail: vka@mil.ru

Vladimir A. Klykov

Candidate of technical sciences, teacher,
sub-department of telemetry systems,
complex processing and protection of information,
Military Space Academy
named after A. F. Mozhaisky
(13 Zhdanovskaya street, St. Petersburg, Russia)

Ekaterina A. Ryakhova

Adjunct,
sub-department of telemetry systems,
complex processing and protection of information,
Military Space Academy
named after A. F. Mozhaisky
(13 Zhdanovskaya street, St. Petersburg, Russia)

Andrey V. Stolyarov

Adjunct,
sub-department of telemetry systems,
complex processing and protection of information,
Military Space Academy
named after A. F. Mozhaisky
(13 Zhdanovskaya street, St. Petersburg, Russia)

Olga L. Shestopalova

Candidate of technical sciences, associate professor,
dean of faculty "Test of aircraft",
Voskhod branch Moscow Aviation Institute
(5 Gagarina street, Baikonur, Kazakhstan)