

УДК 629.78.018

И.Б. ТУРКИН, П.А. ЛУЧШЕВ

Национальный аэрокосмический университет им. Н.Е. Жуковского «ХАИ», Украина

НЕЙРОСЕТЕВОЕ МОДЕЛИРОВАНИЕ ПОДСИСТЕМЫ ЭЛЕКТРОСНАБЖЕНИЯ СПУТНИКА ДЛЯ ВЕРИФИКАЦИИ ПО АВТОМАТИЗАЦИИ ИСПЫТАНИЙ

Приведены результаты построения имитационной модели подсистемы электроснабжения (ПСЭС) спутника на основе математического аппарата искусственных нейронных сетей (ИНС). Определена оптимальная структура нейронной сети, которая позволяет прогнозировать процессы изменения напряжения на главной шине ПСЭС на достаточно продолжительный интервал времени, при этом накоплением статической ошибки можно пренебречь, а динамическая ошибка характеризуется допустимым для процесса моделирования значением СКО. Практическая апробация имитационной модели в ходе автономных и комплексных испытаний ПСЭС позволила сократить трудозатраты на внедрение ПО и обеспечила экономию ресурса ПСЭС, контрольно-проверочной и стендовой аппаратуры.

Ключевые слова: имитационное моделирование, нейронные сети, система электроснабжения спутника.

Введение

Верификация сценариев испытаний подсистемы электроснабжения спутника (ПСЭС) требует создания имитационной модели объекта управления, которая реализует метод структурных эквивалентов [1]. При подобном подходе модель системы строится как композиция моделей ее составных частей (рис. 1).

Среди моделей составных частей объекта управления выделим для последующего анализа модель химической батареи, так как решение задачи имитационного моделирования логики управления и информационного взаимодействия в системе известно, а аналитическое представление макрокинетики электрохимических процессов на отдельных электродах и в электролите БХ с достаточной для практики точностью отсутствует [2].

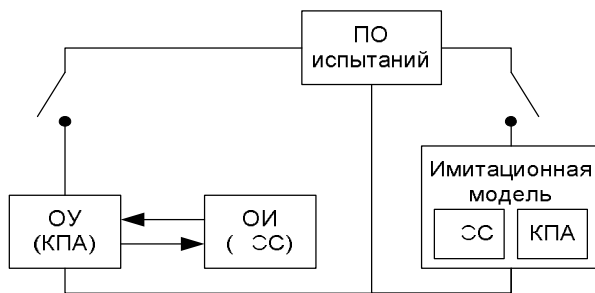


Рис. 1 Взаимодействие имитационной модели объекта управления с ПО испытаний

Использование имитационной математической модели системы электроснабжения космического аппарата позволит экономить ресурс, как объекта

испытаний, так и контрольно-проверочной и стендовой аппаратуры.

В задачах, наиболее характерных для верификации сценариев испытаний ПСЭС, математическая модель батареи химической (БХ) должна характеризовать зависимость внешних (диагностируемых) характеристик аккумулятора от внутреннего состояния и условий эксплуатации:

$$\left. \begin{aligned} \sum_{i=0}^n a_i \frac{d^i U_{ak}}{dt^i} &= \sum_{i=0}^m b_i \frac{d^i I_{ak}}{dt^i}; \\ N_{ak} = f(I_{ak}, U_{ak}, I_{cp}, \eta_i) &= I_{ak} (U_{ak} - \eta_i E) - I_{cp} E; \\ \frac{dT_{ak}}{dt} &= f(N_{ak}, T_{oc}), \end{aligned} \right\} (1)$$

где $a_i, b_i = f(T_{ak}, \theta)$; η_i – эффективность заряда, то есть величина, характеризующая отношение тока основной химической реакции к полному току, поступающему от внешнего источника; E – энтальпия основной химической реакции, выраженная в электрон-вольтах.

Для синтеза математической модели БХ предлагается использовать математический аппарат искусственных нейронных сетей (ИНС), которые предложены практически в то же время, что и обычные фон-Неймановские компьютеры [3], принципиально отличающиеся от них параллельностью выполнения вычислений, распределенным способом хранения информации, высокой надежностью, ассоциативным способом адресации.

Спецификой рассматриваемой предметной области – испытаний ПСЭС КА является необходимость совместного анализа в реальном масштабе времени результатов измерения, представленных в различных шкалах: отношений и бинарной.

1. Постановка задачі

Нейросетевое моделирование в чистом виде базируется лишь на данных, не привлекая никаких априорных соображений. Обычно, это его преимущество, но вместе с тем, возможна ситуация, когда имеющихся данных не достаточно для обучения, а размерность потенциальных входов может оказаться слишком велика. Для преодоления этих трудностей желателен выполнить предварительную обработку данных и их анализ традиционными методами.

Рассмотрим формулировку задачи синтеза модели по экспериментальным данным, получаемым в результате циклирования системы в режиме имитации функционирования при нормальных условиях.

Исходные данные – массив из векторов телеметрии, полученный в результате имитации суточной работы ПСЭС в условиях переменного детерминированного графика энергоприхода и стохастического графика энергопотребления, т.е. графика в котором были фиксированы мощности и величины энергопотребления различных бортовых приборов, а времена их включения-выключения подчинялись пуассоновскому распределению. В состав вектора телеметрии входят 6 аналоговых и 10 дискретных параметров (срабатывания дискретных датчиков и статические индикаторы режимов работы ПСЭС).

Анализируемый массив векторов отражает эволюцию системы после того, как она вышла на стационарный режим, а уровень заряженности БХ близок к максимальному.

Требуется построить зависимость:

$$\frac{dU_{\text{БХ}}}{dt} = f(\mathbf{V}), \quad (2)$$

где \mathbf{V} – некоторый вектор, компоненты которого либо входят в вектор телеметрии, либо вычисляются определенным образом из его составляющих

2. Моделирование

2.1. Этапы предварительной обработки

На основе анализа априорной информации о свойствах системы предварительный выбор множества входных сигналов предполагает:

- исключение сигналов, заведомо не влияющих на искомую характеристику или не изменявшихся в процессе работы;

- преобразование дискретной информации о фактах срабатывания дискретных датчиков в аналоговую – время после срабатывания датчика;

- добавление расчетного параметра – скорости изменения тока.

Тогда искомая зависимость выглядит так:

$$\frac{dU_{\text{БХ}}}{dt} = f \left(\begin{matrix} I_{\text{БХ}}, U_{\text{БХ}}, Q_{\text{САЧ}}, \\ k_{\text{инт}}, \frac{dI_{\text{БХ}}}{dt}, \Gamma_{\text{РОЗ}}, \\ \tau_{\text{ДПН}}, \tau_{\text{ДСН}}, \tau_{\text{СО}}, \tau_{\text{С1}} \end{matrix} \right), \quad (3)$$

где символами $\tau_{\text{ДПН}} \div \tau_{\text{С1}}$ обозначены интервалы времени после срабатывания дискретных датчиков, $\Gamma_{\text{РОЗ}}$ – признак работы в режиме ограничения заряда.

2.2. Устранение избыточности входов методом главных компонент

Для данных, имеющих общую физическую природу и измеренных в одних и тех же единицах интервальной или разностной шкал [4], следует сразу выполнить анализ их взаимозависимости с целью последующего снижения их размерности. К числу таких данных относятся, прежде всего, времена после срабатывания дискретных датчиков.

Метод главных компонент [5], учитывая лишь наиболее значимые линейные комбинации входных величин, решает задачу построения пространства меньшей размерности, обеспечивающей минимальное среднее квадратичное отклонение имеющихся точек от этого пространства:

$$F = \frac{\sum_{\alpha} (V^{\alpha} - V_0^{\alpha})^2}{\sum_{\alpha} (V^{\alpha} - \bar{V}^{\alpha})^2} = \min \quad (4)$$

В основу вычисления главных компонент положен принцип определения ортогональной матрицы \mathbf{L} путем решения характеристического уравнения:

$$|\Sigma - \lambda \mathbf{I}| = 0 \quad (5)$$

где Σ – ковариационная матрица, \mathbf{I} – единичная матрица, λ – собственные значения матрицы Σ .

Матрица \mathbf{L} линейного перехода из исходного пространства в пространство главных компонент $\mathbf{Z} = \mathbf{LX}$ состоит из строк, являющихся собственными векторами матрицы Σ .

2.3. Индивидуальная нормировка и преобработка данных

Обычно, индивидуальная нормировка осуществляется путем линейного преобразования к выборке с $\text{МО} = 0$ и $\text{СКО} = 1$:

$$\tilde{x}_i = \frac{x_i - \bar{x}_i}{\sigma_i}, \quad \bar{x}_i = \frac{\sum_{i=1}^P x_i}{P}, \quad \sigma_i^2 = \frac{\sum_{i=1}^P (x_i - \bar{x}_i)^2}{P-1} \quad (6)$$

ИНС эффективны в задачах, где отсутствуют априорные гипотезы о характере функциональных взаимосвязей между входами и выходами, поэтому

приведенного выше линейного преобразования недостаточно для данных, в которых присутствуют редкие выбросы, существенно отличающиеся по амплитуде от основной массы.

Для данных такого рода необходимо нелинейное преобразование, которое реализует динамическое сжатие данных, в большей степени усиливая центральную область данных, чем периферию.

Количественно эффективность нелинейного преобразования можно оценить через изменение энтропии:

$$H(x) = -\sum_{\alpha} P(x) \log(P(x)), \quad (7)$$

которая, как известно, принимает максимальное значение, если данные имеют равномерное распределение плотности вероятности.

На следующем этапе необходимо максимально снизить размерность входного вектора данных, не потеряв при этом точность аппроксимации с их помощью выходных величин, то есть отобрать наиболее информативные или значимые нормализованные переменные, входящие в уравнение:

$$\text{th}\left(\frac{dU_{\text{BX}}}{d\tau}\right) = f\left(\begin{array}{c} \tilde{I}_{\text{BX}}, \tilde{U}_{\text{BX}}, \tilde{Q}_{\text{CA4}}, \tilde{k}_{\text{инт}}, \\ \text{th}\left(\frac{dI_{\text{BX}}}{d\tau}\right), \tilde{\tau}_{\text{ДПН}}, \tilde{\tau}_{\text{РОЗ}}, \tilde{\tau}_{\text{С1}} \end{array}\right) \quad (8)$$

В отличие от традиционно применяемого корреляционного анализа, который позволяет выявить только линейные зависимости, box-counting алгоритмы оценивают существенность нелинейных зависимостей. Поэтому они могут быть использованы для решения двух задач:

– определения значимости входов, которое базируется на оценке предсказуемости выхода при данном наборе входных переменных;

– анализа взаимозависимости входных переменных для снижения их избыточности.

Box-counting алгоритмы исходят из общих положений теории информации, согласно которым мерой предсказуемости случайной величины X является ее энтропия – $H(X)$. Их работа основана на оценке скорости возрастания числа ячеек (boxes), содержащих все точки множества при уменьшении размера ячеек.

Предсказуемость случайной величины Y , обеспечиваемая знанием другой случайной величины X , оценивается кросс-энтропией:

$$I(Y, X) = H(Y) + H(X) - H(X, Y) = H(Y) - H(Y|X) \quad (9)$$

2.4. Синтез нейросетевой модели

Искусственная нейронная сеть (ИНС) является вычислительной системой с большим числом параллельно функционирующих простых процессоров с множеством связей. Модели ИНС в некоторой

степени воспроизводят "организационные" принципы, свойственные мозгу человека. Их ценность в практических задачах в том, что они эффективно решают проблему организации параллельных вычислений и обработки весьма сложных функций с неизвестной заранее плотностью распределения.

Практическая полезность также определяется тем, что разработан обширный методический аппарат по их применению, что позволяет решать задачи идентификации реальных сложных объектов, оценки их параметров, синтеза моделей.

Элементарный нейрон осуществляет преобразование входного вектора X размерностью N в выходной сигнал:

$$S = \omega_0 + \sum_{i=1}^N x_i \omega_i, \quad y = F(S) \quad (10)$$

В качестве активационной функции чаще всего используются:

– линейная – $y = S$;

– пороговая – $y = \begin{cases} -1, & S < 0, \\ 0, & S = 0, \\ 1, & S > 0; \end{cases}$

– гиперболический тангенс и т.д.

Для решения задачи подбираем искусственную нейронную сеть прямого распространения, которая состоит из нескольких слоев нейронов (табл. 1). Первый слой является входным, последний – выходным, а промежуточные – скрытыми, так как входы-выходы нейронов, принадлежащих ему, недоступны для контроля. Настройка сети реализуется путем адаптации весовых коэффициентов. Наибольшее распространение получил алгоритм обучения ИНС, известный как «процедура обратного распространения» (back propagation of errors). В его основе – минимизация целевой функцией ошибки:

$$E(w) = \frac{1}{2} \sum_{j,p} \left(y_{j,p}^{(N)} - d_{j,p} \right)^2 \quad (11)$$

где $y_{j,p}^{(N)}$ – реальное выходное состояние j -го нейрона N -того выходного слоя нейронной сети при подаче на ее входы p -го образа; $d_{j,p}$ – идеальное (желаемое) выходное состояние этого нейрона.

Суммирование ведется по всем нейронам выходного слоя и по всем обрабатываемым сетью образам. Минимизация ведется методом градиентного спуска, что означает подстройку весовых коэффициентов в направлении, противоположном градиенту:

$$\Delta w_{ij}^{(n)} = -\eta \cdot \frac{dE}{dw_{ij}} \quad (12)$$

Здесь w_{ij} – весовой коэффициент синаптической связи, соединяющей i -ый нейрон слоя $n-1$ с

j -ым нейроном слоя n , $0 < \eta < 1$ – коэффициент скорости обучения.

Результат работы алгоритма обратного распространения ошибки характеризуется двумя ошибками, которые фактически характеризуют способность ИНС запоминать информацию и прогнозировать выход на новых данных:

– ошибка обучения оценивается путем вычисления невязки выхода ИНС и желаемых значений

на множестве примеров, используемых в обучении;
– ошибка обобщения вычисляется на множестве примеров, неиспользуемых в обучении ИНС.

Для того чтобы оценить эти ошибки, исходное множество примеров, как и в традиционном регрессионном анализе [6], разбивается на три части: обучающую, тестовую и контрольную: первая используется в обучении, вторая при подборе архитектуры, третья для контроля точности.

Таблица 1

Ошибки обучения при различных архитектурах ИНС

№	Архитектура ИНС	СКО обученной ИНС	
		Входы $\tilde{I}_{БХ}, \tilde{U}_{БХ}, th\left(\frac{dI_{БХ}}{d\tau}\right)$	Входы $\tilde{I}_{БХ}, \tilde{U}_{БХ}, \tilde{Q}_{САЧ}, th\left(\frac{dI_{БХ}}{d\tau}\right)$
1		0.041	0.016
2		0.041	0.024
3		0.012	0.0125
4		0.0115	0.013
5		0.0135	0.012

2.5. Представление нейросетевой модели в явном виде

Несмотря на то, что нейрокомпьютеры в настоящее время выпускаются и в виде самостоятельных нейрокомпьютеров, и в виде периферийных устройств, расширяющих возможности обычных компьютеров фон-Неймановской архитектуры [7], рассмотрим возможность представления знаний, накопленных ИНС, в более традиционном и явном виде, для чего необходимо восстановить функциональную зависимость выходной переменной от входных, что реализуется следующими этапами.

Процедура контрастирования основана на оценке значимости весов связей в сети, а ее основная цель – упростить техническую реализацию ИНС. Рассмотрим сеть, правильно решающую все примеры обучающего множества. Обозначим через $w_p, p=1, K$ веса всех связей. При обратном функционировании методу обратного распространения ошибки сеть вычисляет вектор градиента функции оценки H по весам связей – $\left\{ \frac{dH}{dw_p} \right\}_{p=1, K}$. Пусть

w^0 – текущий набор весов связей, а оценка текущего примера равна w_p^0 . Тогда в линейном приближении можно записать функцию оценки в точке w как:

$$H(w) = H^0 + \sum_{p=1}^K \frac{dH}{dw_p} (w_p - w_p^0) \quad (16)$$

Используя это приближение можно оценить изменение оценки при замене w_p^0 на w_p^* как:

$$\chi(p, q) = \left| \frac{dH}{dw_p} \right| \cdot |w_p^* - w_p^0|, \quad (13)$$

где q – номер примера обучающего множества, для которого были вычислены оценка и градиент.

Величину $\chi(p, q)$ будем называть показателем чувствительности к замене w_p^0 на w_p^* для примера q . Далее необходимо вычислить показатель чувствительности, не зависящий от номера примера. Для этого используется равномерная норма (максимум модуля): $\chi(p) = \max_q \chi(p, q)$.

В табл. 2 и на рис. 2 приведен результат расчета, который позволяет утверждать, что рассмотренная модель позволяет прогнозировать процессы изменения напряжения на главной шине ПСЭС на достаточно продолжительный интервал времени (по меньшей мере до 5-ти суток), при этом накоплением статической ошибки можно пренебречь, а динамическая ошибка характеризуется СКО, равным 0.29 В на интервале времени в 4 суток и 0.18 В на ближайшие сутки.

Таблица 2

Статистические характеристики точности прогноза изменения напряжения

	Min	Max	МО	СКО
$U_{\delta x}$ фактическое, В	27.48	33.98	30.33	1.082
$U_{\delta x}$ расчетное, В	26.82	33.11	30.36	1.092
Погрешность $\Delta U_{\delta x}$ ($\tau=100$ час)	-1.03	1.39	-0.026	0.29
Погрешность $\Delta U_{\delta x}$ ($\tau=24$ час)	-0.62	0.50	-0.158	0.18




Рис. 2. Прогноз изменения напряжения и расчетная оценка его точности

3. Программная реализация имитационной модели

Программная реализация имитационной модели была основана на применении OPC-сервера Fastwel UniOPC. Входящая в состав сервера библиотека DataServ.dll была разработана с возможностью работы как в штатном режиме работы, когда обеспечивается взаимодействие с внешними устройствами в составе КИА и КПА подсистемы электропитания, так и в режиме имитации.

В штатном режиме выполняются следующие действия:

- в момент старта считывает из базы данных конфигурационную информацию;

- после запуска с заданной периодичностью опрашивает внешние устройства и получает информацию, характеризующую текущее состояние ПСЭС, ее КИА и КПА;

- принимает команды управления, передает их на внешние, осуществляет первичный контроль корректности исполнения этих команд.

В режиме имитации модель ПСЭС используется для отладки и автономных испытаний СПО и верификации технологических процессов проведения испытаний. Программа решает следующие задачи:

- эмулирует работу ПСЭС, ее КИА и КПА и передает информацию о состоянии системы через UniOPC-сервер программам-клиентам;

- имитирует функции ПСЭС, ее КИА и КПА по отработке команд управления, поступающих из внешних программ через OPC-сервер;

- обеспечивает возможность работы в ускоренном режиме.

Таблица 3

Значения синаптических весов обученной ИНС

$\omega_{1,0}$	-4.9242
$\omega_{1,1}$	-4.7617
$\omega_{1,2}$	-0.2885
$\omega_{1,3}$	0.8161
$\omega_{2,0}$	0.0885
$\omega_{2,1}$	-0.0908
$\omega_{2,2}$	-0.0045
$\omega_{2,3}$	0.0019
$\omega_{3,0}$	-0.3436
$\omega_{3,1}$	-0.8353
$\omega_{3,2}$	-5.5670

Имитационная модель ПСЭС образуется в результате программного взаимодействия трех основных составляющих:

- модели логики работы ПСЭС, реализуемой аппаратурой управления и контроля ПСЭС;

- математической модели энергетического взаимодействия источника, накопителя и потребителя энергии;

- модели КИА и КПА агрегатов ПСЭС.

Математическая имитационная модель системы построена в результате применения разработанного метода идентификации. В табл. 3 приведены результаты обучения ИНС, архитектура которых последовательно усложнялась.

Адекватность модели проверена сравнением модельных расчетных значений и фактических. Для этого выполним расчет, задав начальное условие:

$$U_{\text{БХ}} = U_{\text{БХ факт}} (\tau = 0)$$

Выводы

Созданная имитационная модель прошла практическую апробацию в ходе автономных и комплексных испытаний систем электроснабжения космических аппаратов КС5МФ2, «EgyptSat-1»

Имитационное моделирование системы с применением ИНС позволило сократить трудозатраты, необходимые для верификации сценариев испытаний и внедрения разработанного ПО, на 2.5 человеко-месяца, обеспечить экономию 250 часов ресурса ПСЭС, КПА и стендовой аппаратуры

Литература

1. Поляк Ю.Г. Вероятностное моделирование на электронных вычислительных машинах / Ю.Г. Поляк. – М.: Сов. радио, 1971. – 400 с.
2. Токарев А.Б. Анализ требований к математическим моделям аккумуляторных батарей для решения задач проектирования автономных систем электропитания / А.Б. Токарев, Н.Б. Журнова // Техническая электродинамика. – 1990. – №2. – С. 78-82.
3. Галушкин А.И. Современные направления развития нейрокомпьютеров в России / А.И. Галушкин // Зарубежная радиоэлектроника. – 1998. – №1. – С. 3-17.
4. Пфанцагль И. Теория измерений / И. Пфанцагль. – М.: Мир, 1976. – 165 с.
5. Прикладная статистика: Классификация и снижение размерности: Справ. изд. / Под ред. С.А. Айвазяна. – М.: Финансы и статистика, 1989. – 607 с.
6. Ивахненко А.Г. Помехоустойчивость моделирования / А.Г. Ивахненко, В.С. Степашко. – К: Наук. думка, 1985. – 216 с.
7. Галушкин А. Современные направления развития нейрокомпьютерных технологий в России / А. Галушкин // Открытые системы. – 1997. – №4. – С. 25-28.

Поступила в редакцію 2.02.2009

Рецензент: д-р техн. наук, проф. В.М. Вартанян, Национальный аэрокосмический университет им. Н.Е. Жуковского «ХАИ», Харьков, Украина.

НЕЙРОМЕРЕЖЕВЕ МОДЕЛЮВАННЯ ПІДСИСТЕМИ ЕЛЕКТРОПОСТАЧАННЯ СУПУТНИКА ДЛЯ ВЕРИФІКАЦІЇ ПЗ АВТОМАТИЗАЦІЇ ВИПРОБУВАНЬ

І.Б Туркін, П.О. Лучшев

Наведено результати побудови імітаційної моделі підсистеми електрозабезпечення (ПСЕЗ) супутника на основі математичного апарата штучних нейронних мереж (ШНМ). Визначено оптимальну структуру нейронної мережі, що дозволяє прогнозувати процеси зміни напруги на головній шині ПСЕЗ на досить тривалий інтервал часу, при цьому нагромадженням статичної помилки можна зневажити, а динамічна помилка характеризується припустимим для процесу моделювання значенням СКВ. Практична апробація імітаційної моделі в ході автономних і комплексних випробувань ПСЕЗ дозволила скоротити працевитрати на впровадження ПЗ й забезпечила економію ресурсу ПСЕЗ, контрольно-перевірочної й стендової апаратури.

Ключові слова: імітаційне моделювання, нейронні мережі, система електрозабезпечення супутника.

A SIMULATION OF THE POWER SUPPLY SYSTEM OF SATELLITE BY NEURAL NETWORKS FOR VERIFICATION OF SOFTWARE FOR AUTOMATION OF TEST

I.B. Turkin, P.A. Luchshev

Results of development of the simulation model of the power supply system (PSS) of a satellite are described. The model based on a mathematical apparatus of artificial neural networks is presented. The optimal structure of a neural network which allows to forecast voltage processes on main power bus of PSS on enough time slice is determined. The steady-state error accumulation for model can be neglected, as well as the dynamic error value is admissible for process of simulation by standard deviation. Practical approbation of the simulation model during autonomous and complex tests of PSS has allowed to diminish out expenditures of labour to implantation of the software and has minimize usage of resource for PSS and check-out equipment.

Keywords: simulation model, artificial neural networks, power supply system of a satellite.

Туркін Ігорь Борисович – д-р техн. наук, проф., зав. кафедрой, Национальный аэрокосмический университет им. Н.Е. Жуковского «ХАИ», Харьков, Украина, e-mail: energy@d4.khai.edu.

Лучшев Павел Александрович – ст. преп. кафедры, Национальный аэрокосмический университет им. Н.Е. Жуковского «ХАИ», Харьков, Украина, e-mail: lpa@ai.kharkov.com.