

УДК 004.62

## МОДЕЛИРОВАНИЕ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ИДЕНТИФИКАЦИИ СОСТОЯНИЯ ПОДСИСТЕМ КОСМИЧЕСКИХ АППАРАТОВ



**А.А. Дудкин**  
Заведующий лабораторией идентификации систем, доктор технических наук, профессор ”



**Е.Е. Марушко**  
Магистрант БГУИР



**В.В. Ганченко**  
Сотрудник лаборатории идентификации систем

ОИПИ НАН Беларуси  
E-mail: [doudkin@newman.bas-net.by](mailto:doudkin@newman.bas-net.by)

### **А.А. Дудкин**

*Д.т.н., проф. – ученый в области технической кибернетики и информатики, заведующий лабораторией идентификации систем ОИПИ НАН Беларуси. Области научных интересов: цифровая обработка изображений; идентификация и распознавание образов в системах компьютерного зрения.*

### **Е.Е. Марушко**

*Магистр - научный сотрудник лаборатории идентификации систем ОИПИ НАН Беларуси. Области научных интересов: цифровая обработка сигналов и изображений; распознавание образов; нейронные сети.*

### **В.В. Ганченко**

*К.т.н., старший научный сотрудник лаборатории идентификации систем ОИПИ НАН Беларуси. Области научных интересов: цифровая обработка сигналов и изображений; распознавание образов; архитектуры и модели систем высокопроизводительной обработки информации.*

**Аннотация.** Описаны нейросетевые средства системы мониторинга состояния подсистем космических аппаратов по телеметрическим данным для наземного командно-измерительного комплекса, который обеспечивает контроль и прогнозирование состояния и работоспособности ряда подсистем Белорусского космического аппарата. Подробно рассмотрен ансамбль нейронных сетей для решения задач прогнозирования состояния подсистем космического аппарата и его экспериментальное исследование на различных вычислительных архитектурах.

**Ключевые слова:** нейронная сеть, ансамбль, телеметрические данные, космический аппарат, мониторинг, моделирование, идентификация.

### **Введение**

В докладе рассматривается нейросетевой подход для решения задач в области контроля, управления и распознавания телеметрической информации. Благодаря возможности обучения нейронные сети (НС) позволяют при распознавании учесть не только случайный характер сигналов, но и особенности поведения конкретных подсистем в заданных условиях. Но при этом вычислительная процедура обучения нейронной сети связана с проведе-

нием больших объемов вычислений с данными, диапазоны изменения которых могут существенно различаться и которые имеют случайные разбросы, обусловленные погрешностью их измерения или задания [1-4]. С применением суперкомпьютерной технологии вычислений выполняется:

- параллельное обучение НС и их ансамблей;
- имитация отдельных НС и ансамбля в целом (как параллельных структур).

#### **Моделирование работы подсистем КА.**

Для задачи мониторинга были выделены следующие системы КА:

- целевая аппаратура (ЦА);
- система обеспечения теплового режима (СОТР);
- корректирующая двигательная установка (КДУ).

Функционирование подсистем контролируется путем анализа телеметрической информации (ТМИ).

ЦА имеет следующие режимы функционирования: дежурный (поддержание теплового режима), штатные режимы (режимы съемки, передачи и записи), калибровка, тестирование (анализа неисправностей или нештатных ситуаций), служебный (передача команд).

Существуют следующие эксплуатационные ограничения:

- температурные условия – от минус 10 °С до плюс 40 °С;
- ограничение по первичному питанию – от 24 до 34 В;\*;
- ограничения по включению источников питания;
- ограничения повремени съемки.

СОТР обеспечивает в течение всего срока эксплуатации температуру посадочных мест бортовой аппаратуры в пределах от 0 до 40°С. В СОТР входит блок управления нагревателями.

При работе КДУ необходимо контролировать температурные параметры, которые при работе двигателя не должны превышать 65°.

Для обучения и оценки системы диагностики необходимо провести моделирование наблюдаемых подсистем. С этой целью разработана имитационная модель подсистем КА.

#### **Идентификация состояний подсистем космического аппарата**

На рисунке 1 представлена схема функционирования системы нейросетевой идентификации состояния подсистем космического аппарата.

Входными данными для функционирования предложенной модели являются:

- данные ТМИ соответствующих подсистем (параметры СОТР (включая СОТР ЦА), параметры системы энергоснабжения (КА и ЦА), параметры КДУ);
- командно-программная информация (разовые команды, передаваемые с наземного командно-измерительного комплекса, предполагаемые режимы функционирования согласно полетному заданию);
- дополнительно используются данные баллистических траекторных измерений.

Анализ режимов функционирования КА задействует блок анализа переключений режимов систем КА, блоки контроля анализируемых систем КА, которые обращаются к нейросетевым модулям идентификации.

Совместно блок анализа переключений режимов и блоки контроля функционируют по схеме конечного автомата, в котором множество состояний содержит все допустимые режимы функционирования систем КА, а переходы ограничиваются допустимыми последовательностями функционирования, ограничениями по управлению, по температурным условиям и по шинам питания. Блок анализа переключений режимов на основе поступающих команд формирует управляющие воздействия для соответствующего блока контроля.

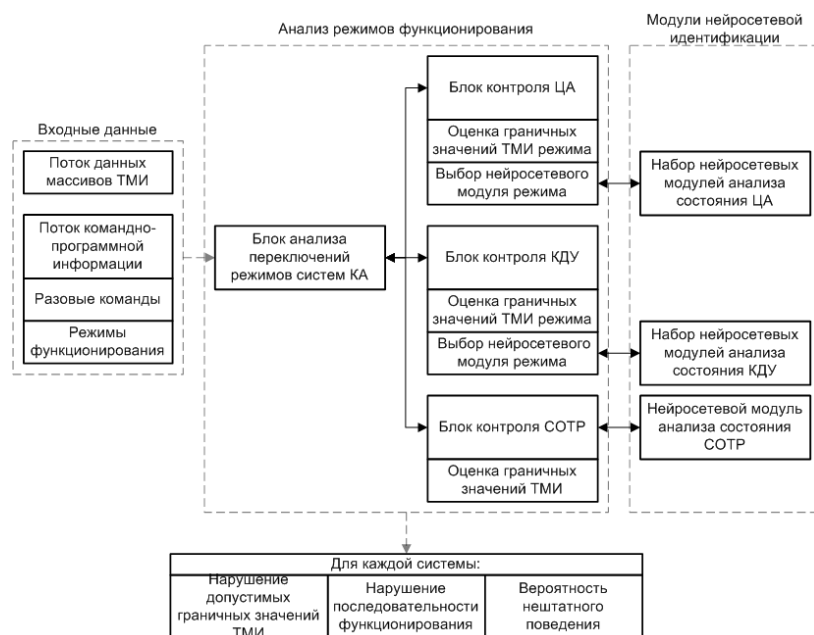


Рисунок 1. Схема функционирования нейросетевой системы идентификации состояния подсистем космического аппарата

В каждом блоке контроля выполняются следующие операции:

- проверка возможности выполнения текущей команды, и соответствие последовательности команд;
- анализ нахождения ТМИ в границах допустимых значений;
- при успешном выполнении предыдущих операций, выполняется выбор нейросетевого модуля идентификации, который на основе ТМИ делает заключение о возможности появления нештатной ситуации в анализируемой системе КА (на основе идентификации паттернов нештатных и преднештатных явлений во временных рядах ТМИ).

Таким образом, для каждой системы КА формируются решения о нарушении/не нарушении последовательности функционирования (определяет сбой в управлении и поведении всей системы), выходе параметров определенных датчиков за диапазон допустимых значений, заключение о возможности нештатного поведения.

Функционирование по данной схеме предполагает наличие этапа обучения. Данный этап включает формирование конечного автомата на основе описания режимов и ограниченный функционирования, конструирование нейросетевых модулей для каждого режима функционирования, обучение данных модулей на выборке соответствующей режиму.

### Обучение нейросетевых модулей

Алгоритм обучения нейросетевых модулей состоит из следующих шагов:

- 1 Подготовка и отбор релевантных телеметрических данных.
- 2 Предобработка данных.
- 3 Для каждой системы КА в соответствии с режимами функционирования выполняется:
  - а) Выбор поднабора входных данных для обучения.
  - б) Синтез и обучение нейронной сети на выбранном поднаборе.
  - в) Включение нейронной сети в блок модулей нейросетевой идентификации и определение связи с соответствующим блоком контроля.

Начальным этапом построения нейросетевой модели является отбор входных данных, влияющих на ожидаемый результат. Из исходной информации необходимо исключить все сведения, не относящиеся к исследуемой проблеме. В то же время следует располагать достаточным количеством примеров для обучения. Для факторов, которые включаются в обучающую выборку, целесообразно предварительно оценить их значимость, проведя корреляционный и регрессионный анализ.

На основе описания режимов функционирования и допустимых диапазонов значений датчиков, формируется обучающая выборка для модулей нейросетевой идентификации состояний систем КА.

Проводится предобработка входных данных. Выполняется ресемплирование для преобразования исходной временной структуры данных к более удобной для обработки структуре, в которой данные «измеряются» в конце каждого временного интервала и формируют собой таблицу. Суть ресемплирования состоит в последовательном продвижении от времени самого раннего съема данных ко времени самого позднего съема данных с заданным шагом, при этом данные текущего состояния датчиков сохраняются в новые массивы (рисунок 2).




Рисунок 2. Пример исходных и ресемплированных данных

Далее осуществляется преобразование исходных данных с учетом характера и типа проблемы, отображаемой нейросетевой моделью, и выбираются способы представления информации. Эффективность нейросетевой модели повышается, если диапазоны изменения входных и выходных величин приведены к диапазону  $[-1,1]$ .

При обучении ставится задача минимизации целевой функции  $E$ , формируемой, как правило, в виде квадратичной суммы разностей между фактическими  $y_s$  и ожидаемыми  $d_s$  значениями выходных сигналов ( $M$  – число выходных сигналов), которая для  $P$  обучающих выборок определяется по формуле:

$$E = \frac{1}{2} \sum_{t=1}^P \sum_{s=1}^M (y_s^{(t)} - d_s^{(t)})^2. \quad (1)$$

В машинном обучении, существует термин «concept drift», который означает, что статистические свойства целевой переменной, которую модель пытается предсказать, меняются с течением времени непредсказуемым образом [5]. Это вызывает проблемы, потому что предсказания становятся менее точными, с течением времени. Отсюда эффективность нейросетевой модели для детектирования нештатных ситуаций и прогнозирования параметров может быть повышена при помощи ансамблей нейронных сетей (АНС), обучаемых с использованием алгоритмов итерационного обучения.

Архитектура АНС, обучаемых для подсистем космического аппарата, представлена на рисунке 3.

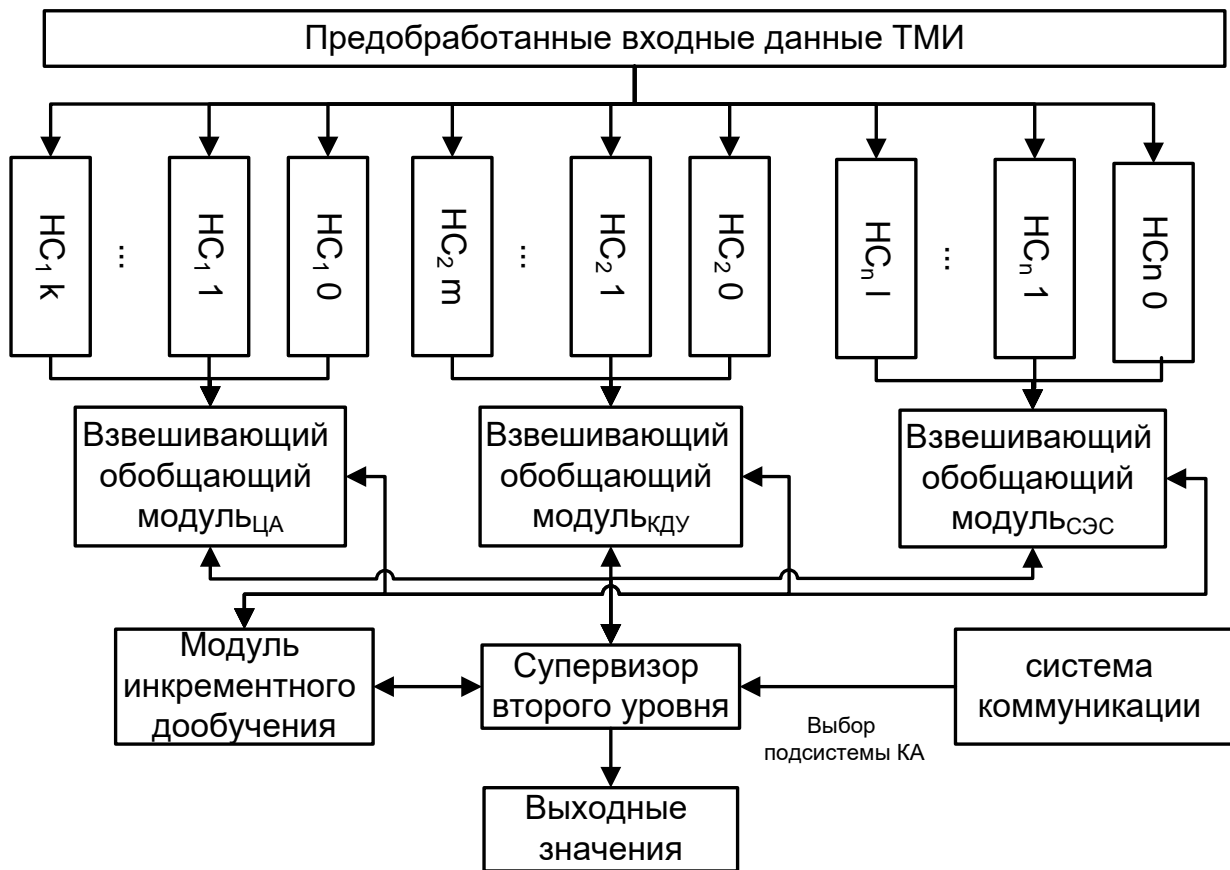


Рисунок 3. Архитектура АНС, обучаемых для подсистем космического аппарата

### Тестирование нейросетевых моделей.

Целью эксперимента является определение различия в скорости выполнения обучения одиночной нейронной сети на центральном процессоре (ЦП) и графическом процессоре (ГП).

В качестве аппаратных средств использованы: ЦП Intel Core i5 4200H, 2 процессорных ядра, 4 потока выполнения, частота 2 800 МГц, Turbo-частота 3 400 МГц; ГП NVIDIA GeForce GTX 860M, частота 1029 МГц, 640 ядер CUDA.

В качестве экспериментальной платформы выбран набор средств Matlab. В эксперименте использовались следующие параметры при обучении нейронной сети:

- архитектура – многослойная нейронная сеть с одним скрытым слоем;
- размер скрытого слоя в диапазоне [4, 56] нейронов;
- обучение методом RPROP;
- обучающая выборка 6613 образцов;
- размер входного слоя 480;
- размер входного слоя 1.

Процедура эксперимента:

- 1) Задать интервал размеров скрытого слоя.
- 2) Выбрать аппаратное средство (ЦП, ГП).
- 3) Выбрать значение из интервала.
- 4) Обучить 10 одиночных нейронных сетей.
- 5) Оценить среднее время выполнения.
- 6) Если не все значения из интервала использованы, то перейти к п. 3.
- 7) Если не все аппаратные средства использованы, то перейти к п.2.

Результаты представлены в таблице 1.

Таблица 1

Оценка времени обучений нейронных сетей на различных вычислительных архитектурах

Размер скрытого слоя	Matlab CPU, с.	Matlab GPU(CUDA), с.	Ускорение
4	93,9962	17,2422	5,4515
8	103,0904	20,9661	4,917
12	109,2202	19,5071	5,599
16	95,9692	19,459	4,9319
20	86,2531	18,4156	4,6837
24	112,8482	20,143	5,6024
28	105,0203	20,0411	5,2402
32	105,6314	25,4046	4,158
36	113,4552	18,902	6,0023
40	127,1681	20,6285	6,1647
44	90,6871	19,8095	4,578
48	112,9013	21,1254	5,3443
52	95,4515	16,4389	5,8064
56	107,1488	20,8944	5,1281
Среднее			5,2577
Медиана			5,2923
Минимум			4,1580

Как видно из таблицы, в среднем наблюдается пятикратное уменьшение времени обучения одной нейронной сети при использовании графического процессора с поддержкой технологии CUDA. Таким образом, применение ГП для ускорения обучения нейронных сетей позволяет значительно ускорить процедуру.

Программная имитация ансамбля на кластере БГУИР (кафедра ЭВМ) также реализована на базе пакетной обработки телеметрической информации, предназначенной для последовательной обработки однотипных блоков с использованием единого алгоритма. Она позволяет осуществлять запуск алгоритмов на базе MPI, задаваемых XML-описанием, которое содержит информацию для выбора блоков данных для обработки и вызова вычислительного ядра с заданным алгоритмом. Она позволяет осуществлять запуск алгоритмов на базе MPI, задаваемых XML-описанием, которое содержит информацию для выбора блоков данных для обработки и вызова вычислительного ядра с заданным алгоритмом.

Кластер состоял из 8 узлов – 1 обслуживающий сервер и 7 вычислительных.

Конфигурация обслуживающего сервера:

- Intel(R) Xeon(R) CPU E5606 2.13GHz (4 ядра);
- 20GB RAM;
- 2 SSD 80GB (Используется в режиме RAID 1);
- 4 HDD 300GB (Используется в режиме RAID 10);
- 1Gbps ethernet;
- 40Gbps Mellanox MT26428 InfiniBand.

Конфигурация вычислительных узлов:

- Intel(R) Xeon(R) CPU E5-2650 2 GHz (16 физических ядер);
- 32GB RAM;
- 2 GPU NVidia Tesla M2075;
- 1Gbps ethernet;

– 40Gbps Mellanox MT26428 InfiniBand.

В экспериментах было задействовано от 1 до 7 вычислительных узлов (не меньше общего числа нейронных сетей), сокращение времени работы пропорционально количеству задействованных узлов.

#### Анализ подходов к формированию выходного значения АНС.

Проведен сравнительный анализ следующих подходов к построению АНС.

1) Выходное значение АНС формируется как сумма выходов отдельных НС. Для случая с одним выходным нейроном:

$$y = \frac{1}{n} \sum_{i=1}^n y_i, \quad (2)$$

где  $n$  – число моделей НС,  $y_i$  – выход  $i$ -й НС.

2) Выходное значение АНС формируется как взвешенная сумма выходов отдельных НС. Для случая с одним выходным нейроном:

$$y = \sum_{i=1}^n y_i \cdot w_i, \quad (3)$$

где  $n$  – число моделей,  $y_i$  – выход  $i$ -й НС,  $w_i$  – вес  $i$ -й НС, который формируется по формуле:

$$w_i = \frac{mse_i}{\sum_{i=1}^n mse_i}, \quad (4)$$

где  $mse_i$  – MSE-ошибка  $i$ -й НС на валидационном наборе.

3) Выходное значение АНС формируется как взвешенная сумма выходов отдельных НС (формулы (4-5)), при этом взвешивание повторяется через определенный интервал обработанных наборов (временных отсчетов) с оценкой по этому набору (динамически взвешиваемый АНС).

Сравнивались среднеквадратичная и средняя абсолютная ошибки прогнозирования для одиночных нейронных сетей, ансамблей нейронных сетей с различными подходами к формированию выходного значения АНС. Средневзвешенный ансамбль нейронных сетей показал точность на уровне лучшей одиночной нейронной сети, при этом обучение и выбор архитектуры не потребовали больших временных затрат. Тогда как для определения лучшей нейронной сети обучались 10 одиночных сетей.

Результаты показали, что наименьшей ошибкой обладает динамически взвешиваемый АНС, при этом разница в оцениваемых параметрах между динамически и однократно взвешенными АНС очень мала (таблица 2).

Таблица 2.

Оценка различных архитектур на одном тестовом наборе

Архитектура	MSE, $10^{-4}$	MAE, $10^{-3}$
Одиночная НС	3.51	0.115
АНС	3.66	0.114
Взвешенный АНС	2.76	9.65
Динамически взвешиваемый АНС, шаг 10	2.75	9.59

Наименьшая среднеквадратичная ошибка при анализе телеметрической информации, формируемой датчиками КДУ, достигается при использовании динамически взвешиваемого АНС с шагом взвешивания 10 и равна  $2,75 \times 10^{-4}$ .

## Заключение

Тестирование показало, что выполнение обучения одиночной нейронной сети на ГП с поддержкой технологии CUDA дает пятикратное уменьшение времени обучения одной нейронной сети по сравнению с ЦП, для указанного оборудования.

Также следует отметить, что применение вычислительного кластера на базе ГП, позволяет обучать одиночные сети параллельно на отдельных модулях. Исходя из представленной в докладе архитектуры ансамблей нейронных сетей, обучение ансамбля может быть выполнено за время достаточное для обучения одиночной нейронной сети, при условии, что размер кластера больше либо равен размеру обучаемого ансамбля.

Наименьшей среднеквадратичной ошибкой обладает динамически взвешиваемый АНС с малым шагом взвешивания, при этом разница в оцениваемых параметрах между динамически взвешиваемым и однократно взвешенным АНС незначительна.

## Литература

- [1] Карелин В. П., Протасов В. И. Эволюционно-генетические и бионические методы моделирования коллективного интеллекта в системах управления и поддержки принятия решений // Вестник ТИУиЭ. – 2012. – №1. – С.71-76.
  - [2] Оссовский С. Нейронные сети для обработки информации / Пер. с пол. И.Д. Рудинского. – М.: Финансы и статистика, 2002. – 344 с.: ил.
  - [3] Riedmiller M., Braun H. A direct adaptive method for faster backpropagation learning: The RPROP algorithm. In Proceedings of the IEEE International Conference on Neural Networks (ICNN), pages 586-591, San Francisco, 1993.
  - [4] Царегородцев В.Г. Конструктивный алгоритм синтеза структуры многослойного перцептрона // Вычислительные технологии, 2008. Т.13 - Вестник КазНУ им. Аль-Фараби, серия "математика, механика, информатика", 2008. №4 (59). (Совм. выпуск). Часть 3. - с.308-315.
  - [5] Elwell R. Incremental Learning of Variable Rate Concept Drift / Ryan Elwell and Robi Polikar // MCS, volume 5519 of Lecture Notes in Computer Science. – Springer 2009. – p. 142-151.
  - [6] Принципы создания базовых конфигураций суперкомпьютерных систем отраслевого назначения / В. В. Анищенко [и др.] // Информатика. – 2012. – №1 (33). – С. 97–105.
- Исследование выполнено при частичной финансовой поддержке (проект № Ф18В-005) и ГКНТ Республики Беларусь (проект № Ф18ПЛШГ-008П).

## MODELING NEURAL NETWORKS TO IDENTIFY THE STATE OF SPACECRAFT SUBSYSTEMS

**A.A. DOUDKIN**

*Head of the System Identification  
Laboratory, Dr.Sc., Professor*

**E.E. MARUSHKO**

*Master student of  
BSUIR*

**V.V. GANCHENKO**

*Employee of the System  
Identification Laboratory*

**Abstract.** The article describes the neural network means of monitoring the state of subsystems of spacecraft by telemetry data for the ground command and measurement complex, which provides control and forecasting of the state and performance of a number of subsystems of the Belarusian spacecraft. The ensemble of neural network models for solving the problems of predicting the state of spacecraft subsystems and its experimental study on various computing architectures is considered in detail.

**Keywords:** Neural network, Ensemble of neural networks, Telemetry data, spacecraft, Monitoring, Modeling, Identification.