

## Секция 5

### *Нейросетевые системы обработки данных, распознавания образов и управления*

**Е.Е. МАРУШКО, А.А. ДУДКИН**

Объединенный институт проблем информатики  
Национальной академии наук Беларуси, Минск  
marushko@lsi.bas-net.by, doudkin@newman.bas-net.by

### **ДОЛГОСРОЧНЫЙ ПРОГНОЗ ПАРАМЕТРОВ СИСТЕМЫ ЭЛЕКТРОСНАБЖЕНИЯ КОСМИЧЕСКИХ АППАРАТОВ**

Рассматривается задача прогнозирования многомерных временных рядов телеметрической информации космического аппарата. Приводится подход для долгосрочного прогноза телеметрических параметров системы энергоснабжения космических аппаратов с помощью ансамблей нейронных сетей.

**Ключевые слова:** ансамбль нейронных сетей, многомерный временной ряд, телеметрическая информация, прогнозирование, обучение.

#### **Введение**

Космическая телеметрия – это совокупность технологий, позволяющая производить дистанционный (удаленный) сбор информации о состоянии бортовых подсистем космических аппаратов. Их функционирование контролируется путем анализа показаний датчиков, которые распределены по модулям подсистем, таким образом, телеметрия представляет собой многомерный временной ряд. Одной из задач анализа является прогнозирование данного ряда [1].

В работе рассматривается задача прогнозирования параметров системы электроснабжения (СЭС) космических аппаратов с использованием ансамблей нейронных сетей по поступившей телеметрической информации (ТМИ).

В состав СЭС входят: модуль регулирования и распределения мощности; батарея солнечная (БС); литий-ионная аккумуляторная батарея (АБ).

БС со временем деградируют под действием следующих факторов: метеорная эрозия, уменьшающая оптические свойства поверхности фотоэлектрических преобразователей; радиационное излучение, особенно при

солнечных вспышках и при полёте в радиационном поясе Земли; термические удары из-за охлаждения конструкции на затенённых участках орбиты и нагрева на освещённых и наоборот. Литий-ионные АБ неизбежно начинают стареть с момента их производства. Происходит это из-за деградации силовых модулей в аккумуляторе как из-за присутствующих химических процессов, так и под воздействием постоянных циклов перезарядки. Скорость деградации зависит не только от внешних факторов, но и от режимов эксплуатации. Вышеперечисленное означает, что время эффективной работы СЭС ограничено и прогноз состояния позволяет проводить мониторинг и увеличивать ресурс системы [2].

Состояние СЭС описывается набором телеметрических данных: токи заряда и разряда батарей, напряжения батарей, напряжение шины питания и электрические параметры различных компонент системы. Данный набор представляет собой многомерный временной ряд, а прогнозирование состояния СЭС сводится к решению задачи прогнозирования данного многомерного ряда или отдельных рядов.

Задача прогнозирования временного ряда в общем виде формулируется следующим образом [3, 4]: по известному текущему значению последовательности  $y(k)$  и некоторой предыстории  $y(k-1), y(k-2), \dots, y(k-m)$  дать оценку следующего значения  $\hat{y}(k+1)$ . Каждый элемент последовательности  $y(k)$  представляет собой набор значений в момент  $k$ . Длина предыстории  $m$ , которая используется для прогнозирования, называется временным окном.

Широкое распространение для решения задач прогнозирования находит нейросетевой подход, так как он позволяет моделировать зависимости между данными в результате обучения на примерах. При этом эффективность использования нейронных сетей (НС) зависит от архитектурных решений и методов обучения [3, 5], что приводит к необходимости многократного проведения экспериментов.

В данной работе исследуется возможность долгосрочного прогноза телеметрических параметров с использованием ансамблей нейронных сетей (АНС) [6, 7], т.е. набора НС, принимающего решения путем усреднения результатов работы отдельных НС.

В прогнозном анализе и машинном обучении имеет место дрейф, означающий, что статистические свойства целевой переменной, которую модель пытается предсказать, меняются с течением времени непредсказуемым образом [8], что увеличивает ошибку прогнозирования. Отсюда эффективность нейросетевой модели прогнозирования может быть повышена при помощи методов итерационного обучения АНС [6, 8, 9]. Эти методы подразумевают оценку точности всех моделей и их ранжирование

по точности на каждой итерации анализа. При понижении суммарной точности АНС детектирует дрейф целевой переменной, и производится добавление в ансамбль нового элемента, обученного на релевантных данных. При таком подходе сохраняется модель, заложенная при начальном обучении, и вносятся новые параметры без проблемы «забывания». Таким образом, реализуется дообучение АНС.

### Организация вычислительного эксперимента

*Выборка* – конечный набор прецедентов, некоторым способом выбранных из множества всех возможных прецедентов, называемого *генеральной совокупностью*.

Набор данных, на которых проводился анализ, представляет собой телеметрические данные, формируемые датчиками СЭС белорусского космического аппарата и характеризующей функционирование данной подсистемы Значения, выдаваемые датчиками контролируемых параметров, зависят от режима работы СЭС, который в свою очередь задается командами управления, передаваемыми с Земли. Значения датчиков СЭС коррелируют между собой, что позволяет рассчитывать на удовлетворительные оценки прогноза.

Опрос датчиков на борту производится каждые 0,1 с. Но формирование долгосрочного прогноза в данном масштабе представляется крайне сложной задачей, поэтому было предложено для реализации долгосрочного прогнозирования вычислять интервальные оценочные параметры ТМИ каждого датчика. Были определены следующие параметры:

- минимальное значение на интервале;
- максимальное значение на интервале;
- среднее значение на интервале.

Интервал вычисления параметра равен 24 ч.

Эксперимент проводился с использованием ТМИ СЭС за период с 2012 по 2017 г. Набор данных представляет собой 1569 отсчетов, каждый содержит 145 параметров. Построение НС выполнялось для отдельных датчиков. Прогноз вычислялся для значения через 30 дней.

Так как обучение выполняется с учителем, то необходимо сформировать обучающую выборку из пар «входной вектор, выходной вектор». Формирование пары обучающих примеров осуществляется по принципу скользящего окна [4]: т.е. берется некоторый отрезок временного ряда и из него выделяется несколько наблюдений, которые и будут представлять собой входной вектор. Значением желаемого выхода в обучающем примере будет следующее по порядку наблюдение. Затем окно сдвигается на

одну позицию в направлении возрастания времени, и процесс формирования следующей пары обучающей выборки повторяется.

При подготовке ТМИ для обучения НС выполняется масштабирование. Масштабирование необходимо, чтобы привести данные в допустимый диапазон  $[-1, 1]$ . Выходы сети также масштабируются.

Целью эксперимента является определение оптимальных гиперпараметров АНС: размер скрытого слоя, временное окно прогнозирования.

В качестве базового элемента АНС используется многослойный перцептрон с одним скрытым слоем с нелинейной функцией активации *гиперболический тангенс*. Обучение одиночной НС осуществляется алгоритмом RPROP [10].

В предлагаемой модели выходное значение АНС формируется как взвешенная сумма выходов отдельных НС, в предыдущей работе [11] была показана их сравнительная эффективность. АНС включает 20 базовых элементов.

Для оценки качества обученных НС и АНС используются следующие величины:

- средний квадрат ошибки (mean square error, MSE);
- средняя абсолютная ошибка в процентах (mean absolute percentage error, MAPE).

Для оценки точности использовалась 8-кратная перекрестная проверка. Для этого общая обучающая выборка разделялась 8 равных частей (12,5 % от общего набора), и обучение повторялось 8 раз для каждой пары параметров, при этом каждая из 8-ми частей последовательно назначалась тестовой выборкой, а оставшаяся часть данных использовалась для обучения с ранним остановом, для этого делилась на валидационную (10 %) и обучающую (90 %) выборки случайным образом.

Для поиска гиперпараметров использовался сеточный поиск [12].

### Оценка гиперпараметров НС

Сеточный поиск предполагает задание наборов всех параметров, в области которых производится поиск. Набор данных ограничен по размеру, отсюда следует, что сложные НС (с большим количеством настраиваемых параметров) не будут достаточно обучены, и поиск гиперпараметров стоит вести в области с малыми размерами входного и скрытого слоя. Были выбраны следующие диапазоны: размер окна прогнозирования от 8 до 120 дней, размер скрытого слоя от 8 до 120 нейронов.

Поиск проводился по следующему алгоритму.

- 1) Выбор пары параметров из области поиска.

- 2) Формирование тестовой и обучающей выборки для 8-кратной перекрестной проверки.
- 3) Обучение с ранним остановом 20 НС с размером скрытого слоя, равным текущему на интервале.
- 4) Формирование из 20 НС взвешенного АНС.
- 5) Вычисление MAPE ошибки.
- 6) Выбор следующей тестовой выборки и формирование обучающей выборки.
- 7) Если не закончена 8-кратная перекрестная проверка, то переход на п. 3.
- 8) Пока не конец области поиска, переход к следующей паре параметров.
- 9) Выбор АНС с наименьшей ошибкой на интервале поиска, размер скрытого слоя элемента АНС и размер временного окна прогнозирования будут подходящим решением.

На рис. 1 приведена область поиска с полученными значениями ошибки.

Как видно, наименьшая ошибка получена при размере временного окна прогнозирования равном 56 дней, и размере скрытого слоя 48 нейронов.

На рис. 2 приведены графики среднесуточного значения реальной ТМИ и прогноза для параметра «напряжение батареи» СЭС.

В табл. 1 представлены оценки ошибок MSE и MAPE для параметра «напряжение батареи» без масштабирования значений.

Были также рассчитаны значения MAPE ошибки для других типов датчиков. Для тока заряда АБ ошибка MAPE составляет 4,1712, тока разряда АБ – 5,9721, для напряжения шины питания – 0,1968. Разница в значении MAPE для токов и напряжений вытекает из того, что токи в данном случае измеряются в мА и изменяются в пределах нескольких сотен, а напряжения измеряются в В и изменяются в пределах 3–4 В.

Таблица 1

#### Оценка для параметра «напряжение батареи»

Прогнозируемый параметр	MSE	MAPE
Минимальное значение	0,2925	0,4938
Максимальное значение	0,0152	0,1485
Среднее значение	0,0525	0,2280

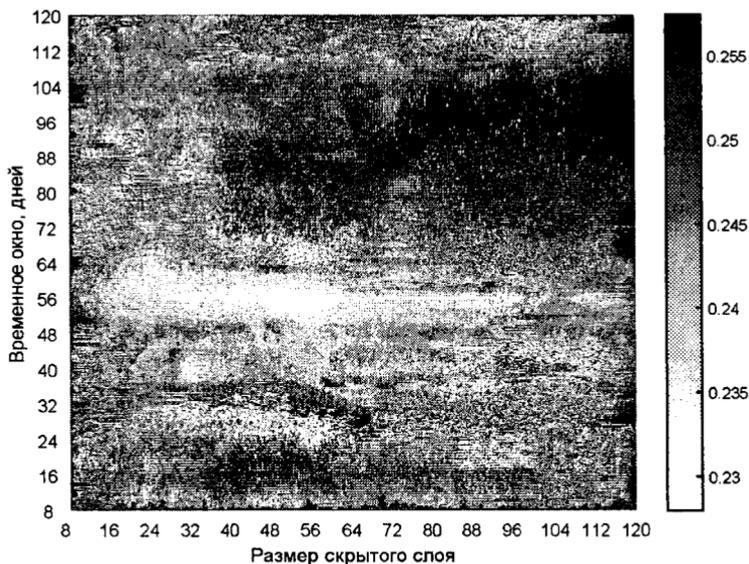


Рис. 1. Сеточный поиск гиперпараметров АНС, МАРЕ

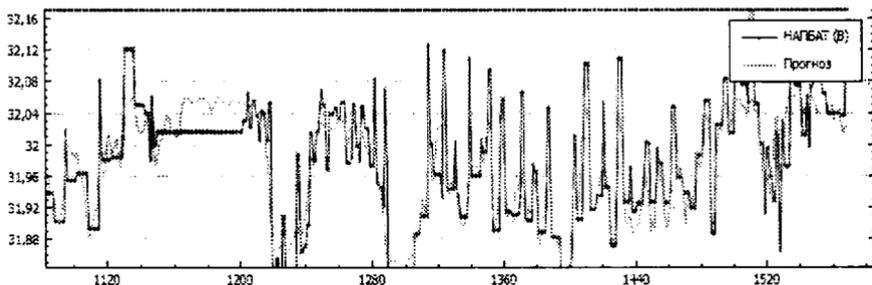


Рис. 2. Реальная ТМИ напряжения батареи и прогноз

### Заключение

Эксперимент показал, что для указанных условий долгосрочного прогнозирования телеметрических параметров минимальная ошибка получена при размере временного окна прогнозирования равном 56 дней, и размере скрытого слоя 48 нейронов.

Для найденных гиперпараметров средняя абсолютная ошибка в процентах среднего значения на интервале при прогнозировании ТМИ, формируемой датчиками СЭС, для напряжения АБ составляет 0,2280, для напряжения шины питания 0,1968, для тока заряда АБ 4,1712.

Нейросетевая модель на основе взвешенных АНС предоставляет интеллектуальный инструмент решения задач прогнозирования ТМИ для разрабатываемого в ОИПИ НАН Беларуси совместно с центром управления полетами БКА экспериментального образца нейросетевой системы мониторинга состояния подсистем космических аппаратов по телеметрическим данным.

### *Список литературы*

1. Нейросетевая система мониторинга состояния и поведения подсистем космических аппаратов по телеметрическим данным для наземного командно-измерительного комплекса / А.А. Дудкин [и др.] // Актуальные проблемы создания космических систем дистанционного зондирования Земли: материалы II Междунар. науч.-техн. конф. (Москва, 15 мая 2014 г.). М.: ВНИИЭМ, 2014. С. 194–204.
2. Азарнов А.Л. Исследование факторов, оказывающих влияние на деградацию литий-ионных аккумуляторов / А.Л. Азарнов [и др.] // Issn 1727-7337. Авиационно-космическая техника и технология. 2016. № 4 (131). ISSN: 1727-7337. С. 10–17.
3. Short-Term Load and Wind Power Forecasting Using Neural Network-Based Prediction Intervals / Hao Quan [et al.] // IEEE Transactions on Neural Networks and Learning Systems. Short-Term Load and Wind Power Forecasting Using Neural Network-Based Prediction Intervals. 2013. Vol. 25. Iss. 2. ISSN: 2162-237X. P. 303–315.
4. Лысяк А.С. Прогнозирование многомерных временных рядов / А.С. Лысяк, Б.Я. Рябко // Вестник СибГУТИ. 2014. № 4. С. 75–88.
5. Comparison of the ARMA, ARIMA, and the autoregressive artificial neural network models in forecasting the monthly inflow of Dez dam reservoir / M. Valipour [et al.] // Journal of Hydrology 476 (2013). P. 433–441.
6. Marushko Y. Using Ensembles of Neural Networks with Different Scales of Input Data for the Analysis of Telemetry Data / Y. Marushko // Proc. of the XV Intern. PhD Workshop OWD 2013 (Wisla, 19–22 Oct. 2013). Gliwice: Silesian University of Technology, 2013. P. 386–391.
7. Neural network ensemble operators for time series forecasting / Nikolaos Kourentzes [et al.] // Expert Systems with Applications. July 2014. Vol.41. Iss. 9. ISSN: 0957-4174. P. 4235–4244.
8. Elwell, R. Incremental Learning of Variable Rate Concept Drift / R. Elwell, R. Polikar // MCS. Vol. 5519 of Lecture Notes in Computer Science. 2009. P. 142–151.
9. Parikh D. An ensemble-based incremental learning approach to data fusion / D. Parikh, R. Polikar // IEEE Transactions on Systems, Man and Cybernetics – Part B: Cybernetics. 2007. Vol. 37. № 2. P. 437–450.

10. Riedmiller M. A direct adaptive method for faster backpropagation learning: The RPROP algorithm / M. Riedmiller, H. Braun // In Proceedings of the IEEE International Conference on Neural Networks (ICNN), San Francisco. 1993. P. 586–591.

11. Дудкин А.А. Исследование эффективности ансамблей нейронных сетей для прогнозирования временных рядов телеметрии космических аппаратов / А.А. Дудкин, Е.Е. Марушко // Материалы международной научно-технической конференции «Нейроинформатика-2016». Россия. Москва, 25–29 апреля 2016 г. М.: НИЯУ МИФИ, 2016. С. 162–172.

12. Bengio, Yoshua. Random Search for Hyper-Parameter Optimization / James Bergstra, Yoshua Bengio // J. Machine Learning Research. 2012. 13. P. 281–305.

**А.А. ЛИТВИН<sup>1</sup>, О.Г. ЖАРИЧЕВ<sup>2</sup>, В.А. КОВАЛЕВ<sup>3</sup>**

<sup>1</sup>Балтийский федеральный университет им. И. Канта. Калининград

<sup>2</sup>Гомельская областная клиническая больница, Беларусь

<sup>3</sup>Объединенный институт проблем информатики  
Национальной академии наук Беларуси, Минск  
alitvin@kantiana.ru

## **СИСТЕМА ПРОГНОЗИРОВАНИЯ И ДИАГНОСТИКИ ИНФИЦИРОВАННОГО ПАНКРЕОНЕКРОЗА НА ОСНОВЕ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ**

Рассматриваются результаты разработки и изучения эффективности системы прогнозирования и диагностики инфицированного панкреонекроза, созданной на основе использования искусственных нейронных сетей. Созданная система поддержки принятия решений показала хорошие прогностические и диагностические характеристики. Применение разработанной системы в клинической практике позволило улучшить прогнозирование и диагностику тяжелого острого панкреатита, инфицированного панкреонекроза.

**Ключевые слова:** *система поддержки принятия решений, искусственные нейронные сети, медицина, тяжелый острый панкреатит, инфицированный панкреонекроз, прогнозирование, диагностика.*

### **Введение**

В последние годы в медицине все большее внимание исследователей обращено на использование в сложных клинических случаях систем поддержки принятия решений (СППР) [1]. В неотложной панкреатологии