

головного мозга на быстро происходящие сдвиги газового гомеостаза (CO_2 , водородные ионы, O_2) зависит эффективность обратной связи от хеморецепторов мозга к нейронам дыхательного и сосудодвигательного центров.

Подобные закономерности для контроля результативности функционирования разработанных алгоритмов в нейросетях целесообразно учитывать в новых моделях искусственного интеллекта. ■

СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

1. Qingzhou L., Yihang L., Ji L., Christian L., Fanqi W., Anyi Z., Zhen L., Mingrui C., Hongyu F., Jeffrey D., Xuan C., Chongwu Z. Fully Printed All-Solid-State Organic Flexible Artificial Synapse for Neuromorphic Computing // *ACS Appl Mater Interfaces*. 2019. №11 (18). P. 16749–16757.
2. Wang Z., Liu J., Chen X., Li G., Han H. Sparse self-attention aggregation networks for neural sequence slice interpolation // *BioData Min*. 2021. №14 (1). P. 1–19.
3. Melamane S., Walker R. B., Khamanga S. M. M. Formulation optimization of smart thermosetting lamotrigine loaded hydrogels using response surface methodology, box behken design and artificial neural networks // *Drug Dev Ind Pharm*. 2020. №46 (9). P. 1402–1415.
4. Bermudez-Contreras E. Deep reinforcement learning to study spatial navigation, learning and memory in artificial and biological agents // *Biol Cybern*. 2021. №115 (2). P. 131–134.
5. Sun J., Han G., Zeng Z., Wang Y. Memristor-Based Neural Network Circuit of Full-Function Pavlov Associative Memory With Time Delay and Variable Learning Rate // *IEEE Trans Cybern*. 2020. №50 (7). P. 2935–2945.
6. Vitalii M.P., Andrii O.H., Yevheniia O.H. Artificial intelligence in medical practice: regulative issues and perspectives // *Wiad Lek*. 2020. №73 (12). P. 2722–2727.
7. Segato A., Marzullo A., Calimeri F., De Momi E. Artificial intelligence for brain diseases: A systematic review // *APL Bioeng*. 2020. №4(4). P. 041503.
8. Yang H., Di X., Gong Q., Sweeney J., Biswal B. Investigating inhibition deficit in schizophrenia using task-modulated brain networks // *Brain Struct Funct*. 2020. №225 (5). P. 1601–1613.
9. Fürbass F., Kural M. A., Gritsch G., Hartmann M., Kluge T., Beniczky S. An artificial intelligence-based EEG algorithm for detection of epileptiform EEG discharges: Validation against the diagnostic gold standard // *Clin Neurophysiol*. 2020. №131 (6). P. 1174–1179.

Полный список использованных источников размещен

ПРОГНОЗИРОВАНИЕ ВРЕМЕННЫХ РЯДОВ ТЕЛЕМЕТРИИ КОСМИЧЕСКИХ АППАРАТОВ НА ОСНОВЕ АНСАМБЛЕЙ НЕЙРОННЫХ СЕТЕЙ

Александр Дудкин,
завлабораторией
идентификации систем
Объединенного института
проблем информатики
НАН Беларуси, доктор
технических наук,
профессор

Евгений Марушко,
научный сотрудник
лаборатории
идентификации систем
Объединенного института
проблем информатики
НАН Беларуси, магистр
профессор

Валентин Ганченко,
ст. научный сотрудник
лаборатории
идентификации систем
Объединенного института
проблем информатики
НАН Беларуси, кандидат
технических наук

Телеметрия космических аппаратов (КА) представляет собой значения датчиков в виде многомерных временных рядов. Одной из задач в области контроля, управления и распознавания полученной информации является прогнозирование многомерного временного ряда [1, 2] по известному текущему значению последовательности $y(k)$ и некоторой предыстории $y(k-1), y(k-2), \dots, y(k-t)$ дать оценку следующего значения $\hat{y}(k+1)$. Каждый элемент данной последовательности представляет собой набор значений в момент k . Длина предыстории t называется временным окном.

Широкое распространение для решения задач прогнозирования находит нейросетевой подход, позволяющий моделировать зависимости между данными в результате обуче-

SEE http://innosfera.by/2021/05/artificial_intelligence

ния на примерах [4, 5]. При этом эффективность использования нейронных сетей (НС) зависит от архитектурных решений и методов обучения [1, 3], что приводит к необходимости многократного проведения экспериментов.

В данной работе исследуется возможность кратковременного прогноза телеметрических параметров с применением ансамблей нейронных сетей (АНС) [6–12], то есть набора НС, принимающего решения путем усреднения результатов работы отдельных из них. Базовыми моделями для АНС являются разнотипные, или гибридные нейросети. Последнюю можно построить, по крайней мере, из двух различных типов НС [13–18]. 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 [7], что увеличивает вероятность ошибки прогнозирования. Следовательно, эффективность нейросетевой модели прогнозирования может быть повышена при помощи методов инкрементного обучения АНС [7, 11, 19].

ПОСТРОЕНИЕ АНСАМБЛЯ ДЛЯ ОБРАБОТКИ ТЕЛЕМЕТРИИ

Рассмотрим построение ансамбля, когда в качестве базового элемента АНС используется многослойный перцептрон с одним скрытым слоем с нелинейной функцией активации *гиперболический тангенс*.

Размер входного слоя NI для НС одного АНС определяется как произведение числа датчиков подсистемы и временного окна. Размер выходного слоя NO – числом датчиков подсистемы. Размер скрытого слоя NH для НС одного АНС устанавливается при проведении эксперимента с процедурой поиска субоптимального размера скрытого слоя одиночных НС. Обучение последних осуществляется алгоритмом RPROP [20]. Выходное значение АНС формируется следующим образом:

1 как сумма выходов отдельных НН и для случая с одним выходным нейроном вычисляется по формуле:

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

где n – число моделей НН, y_i – выход i -й НС;

2 как взвешенная сумма выходов отдельных НН. Для случая с одним выходным нейроном вычисляется по формуле:

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

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

$$w_i = \frac{mse_i}{\sum_{i=1}^n mse_i}, \quad (3)$$

где mse_i – среднеквадратическая ошибка (mean square error, MSE) i -й НС на валидационном наборе;

3 как взвешенная сумма выходов отдельных НС (формулы 2 и 3), при этом взвешивание повторяется через определенный интервал обработанных наборов (временных отсчетов) с оценкой по этому набору (динамически взвешиваемый АНС), *рис. 1*.

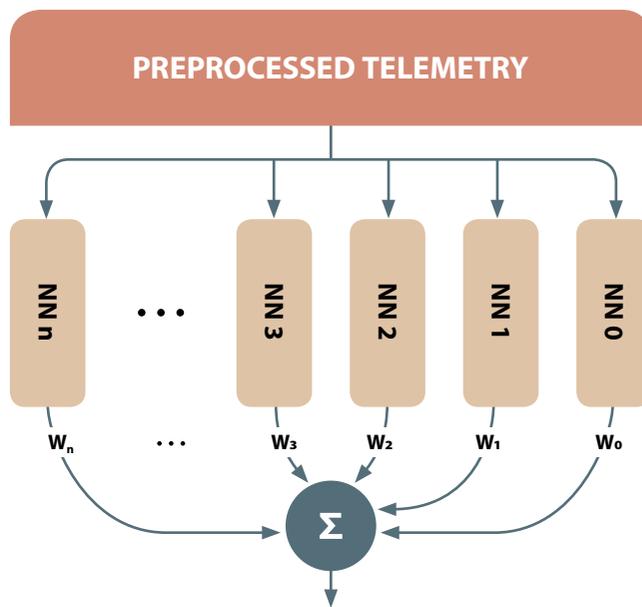


Рис. 1. АНС формирует взвешенную сумму выходов отдельных НН

Инкрементное обучение АНС может использоваться для детектирования *дрейфа значений* [7, 12]. Оно подразумевает оценку точности всех моделей и их ранжирование по точности на каждой итерации прогнозирования. При повышении ошибки АНС детектируется дрейф целевой переменной, и в ансамбль добавляется

новый элемент, обученный на релевантных данных. Для всех НС ансамбля производится пересчет весовых коэффициентов по формуле (3). При таком подходе сохраняется модель, заложенная при начальном обучении, и вносятся новые параметры без проблемы «забывания». Таким образом реализуется дообучение АНС.

Задача прогнозирования телеметрических данных решалась для трех подсистем БКА. Это система энергоснабжения (СЭ), корректирующая двигательная установка (КДУ) и целевая аппаратура (ЦУ). Соответственно, для обработки телеметрической информации (ТМИ) разработаны три АНС (рис. 2).

На вход АНС поступает предварительно обработанная ТМИ и идентификатор требуемой подсистемы. Супервизор формирует для нее сигнал выбора АНС, получает прогноз и инициирует процедуру дообучения. Блок инкрементного дообучения отвечает за подготовку набора данных и обучение новых элементов АНС.

Таким образом, двухуровневая модель АНС для прогнозирования телеметрии подсистем космического аппарата, представленная на рис. 2, формируется и работает по следующему алгоритму.

1. Указание размеров NPS ENNPS для обработки ТМИ СЭ, NCPS ENNCPS – для ТМИ КДУ, NTE ENNTE – для ТМИ ЦА.
2. Обучение NPS одиночных НС на наборе ТМИ СЭ.
3. Обучение NCPS одиночных НС на наборе ТМИ КДУ.
4. Обучение NTE одиночных НС на наборе ТМИ ЦА.
5. Расчет по формуле (3) весовых коэффициентов для одиночных НС каждого ENNPS, ENNCPS, ENNTE.
6. Получение ТМ-данных для обработки.
7. Определение обрабатываемой подсистемы СЭ, КДУ, ЦА.
8. Передача ТМ-данных в соответствующий АНС.
9. Формирование результата по формуле (1) или (2).
10. Выполнение инкрементного дообучения выбранного АНС.
11. Если есть данные для обработки, перейти на шаг 6.
12. Завершение работы.

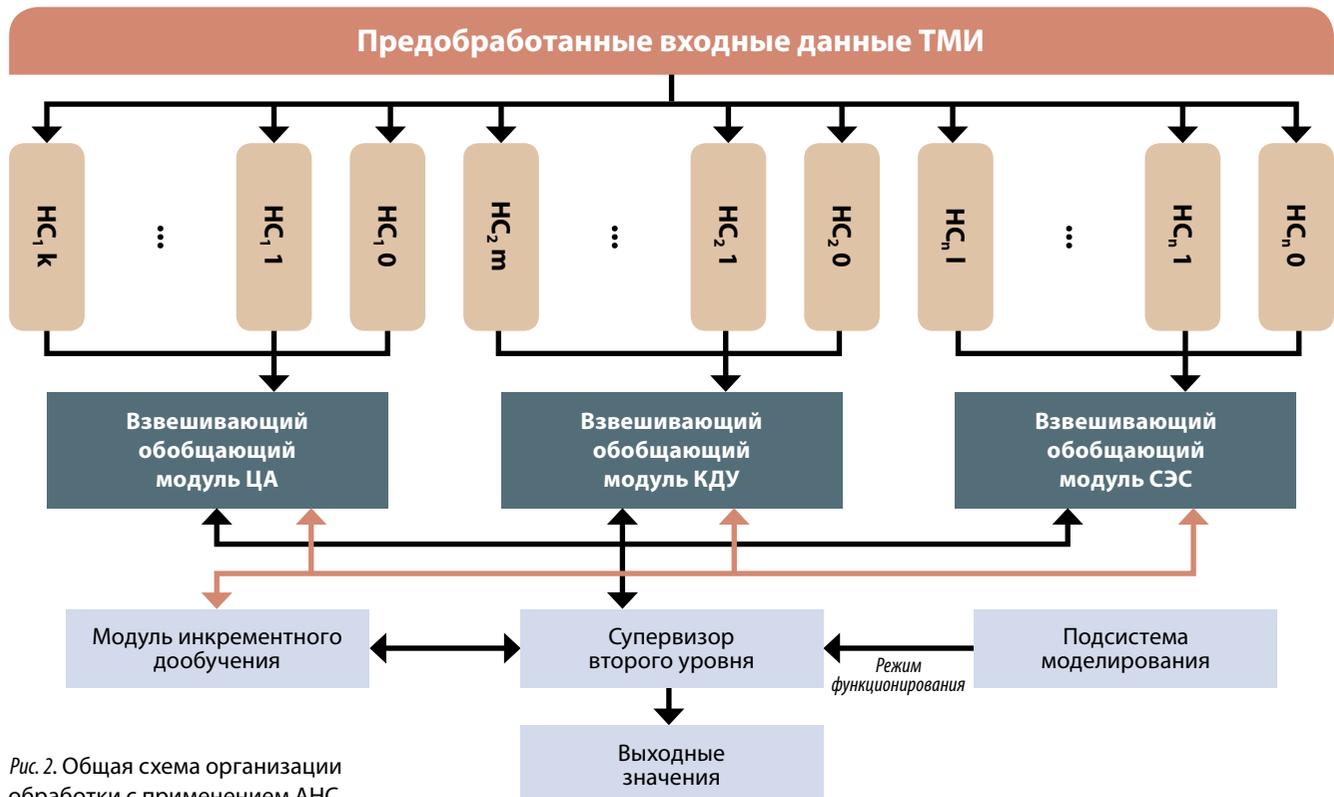


Рис. 2. Общая схема организации обработки с применением АНС

ОРГАНИЗАЦИЯ ЭКСПЕРИМЕНТА ДЛЯ ИССЛЕДОВАНИЯ ЭФФЕКТИВНОСТИ АНСАМБЛЕЙ

В *табл. 1* представлены параметры наборов данных, на которых проводился эксперимент. Его цель – определение влияния характеристик одиночной НС и архитектур АНС на результативность прогноза при окне прогнозирования, равном 20 отсчетам.

Набор представляет собой перечень телеметрической информации, формируемой датчиками КДУ и характеризующей функционирование данной подсистемы.

Создание пары обучающих примеров осуществляется по принципу скользящего окна [2]. При размерности временного ряда данных, равной N , размере окна – W НС должна принимать на вход образец размером $N \times W$. Так, для $W=20$ набор Dt_set_s1 преобразуется во входной размер 480×6589 и целевой размером 28×6589 наборы.

При подготовке обучающих данных выполняется ресемплирование (для преобразования исходных сведений, представляющих собой последовательность временных отметок важных событий в форму с фиксированным временем дискретизации) и масштабирование (для приведения данных в допустимый диапазон $[-1, 1]$). Выходы сети также масштабируются.

Для оценки качества обученных НС и АНС,

$$MSE = \frac{1}{m} \sum_{i=1}^m e_i^2 \quad (4)$$

а также для сравнения различных архитектур АНС используются следующие величины:

- среднеквадратическая ошибка:
- средняя абсолютная ошибка (mean absolute error, MAE):

$$MAE = \frac{1}{m} \sum_{i=1}^m |e_i| \quad (5)$$

Название набора	Шаг дискретизации, сек.	Размерность временного ряда	Количество отсчетов
Dt_set_s01	1	24	57501
Dt_set_s05	0,5	24	12245
Dt_set_s1	0,1	24	6613

Таблица 1. Наборы ТМИ КДУ

где $e_i = y_i - t_i$, y_i и t_i – полученный и желаемый сигналы на выходе i -го нейрона выходного слоя соответственно, m – размер выходного слоя НС.

В данном эксперименте входной набор разделялся в соотношении 9:1 на общую обучающую выборку и итоговую тестовую. Первая разделялась на валидационную (15%), тестовую (15%) и обучающую (70%) случайным образом, которые использовались для обучения, оценки и поиска лучшей архитектуры НС. Итоговая тестовая выборка применялась для вычисления конечных оценок полученных НС.

ОЦЕНКА РАЗМЕРА СКРЫТОГО СЛОЯ НС

Оценивалась возможность поиска субоптимального размера скрытого слоя одиночной НС по следующему алгоритму.

1. Определение ряда значений для поиска размера скрытого слоя.
2. Обучение 10 НС с размером скрытого слоя, равным текущему в ряду значений, формирование из 10 НС взвешенного ансамбля.
3. Оценка точности АНС.
4. Пока не просмотрены все значения из ряда для поиска, переход к следующему элементу интервала.
5. Выбор АНС с наименьшей MSE на интервале поиска, размер скрытого слоя элемента АНС будет подходящим решением. Критерием выбора является наименьшее значение среднеквадратической ошибки АНС.

Набор данных	Размер скрытого слоя
Dt_set_s1	28
Dt_set_s05	33
Dt_set_s01	70

Таблица 2. Оценка размера скрытого слоя НС

Стоит отметить, что данный алгоритм значительно увеличивает время создания архитектуры НС.

АНАЛИЗ ПОДХОДОВ К ФОРМИРОВАНИЮ ВЫХОДНОГО ЗНАЧЕНИЯ АНС

В *табл. 3* приведены оценки различных архитектур на тестовом наборе Dt_set_s1 с размером скрытого слоя одиночной нейронной сети согласно данным *табл. 2*.

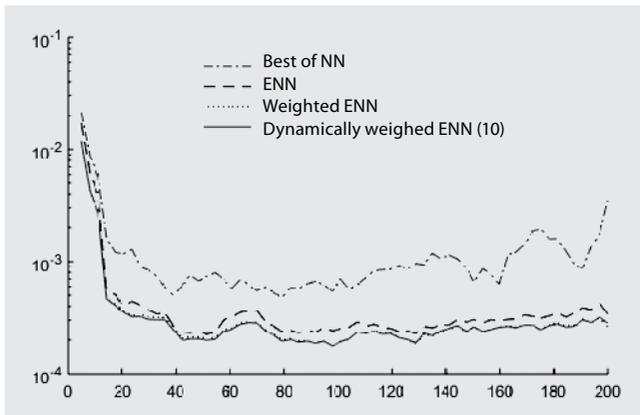


Рис. 3. Оценка различных архитектур в зависимости от размера скрытого слоя базовой НС

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

Таблица 3. Оценка различных архитектур на тестовом наборе Dt_set_s1

Из данных в табл. 3 видно, что наименьшей ошибкой обладает динамически взвешиваемый АНС, при этом разница в оцениваемых параметрах между динамически и однократно взвешенными АНС очень мала.

ОЦЕНКА ДИНАМИЧЕСКИ ВЗВЕШИВАЕМОГО АНС

Проведена оценка шага взвешивания для динамически взвешиваемого АНС. На рис. 4 представлен график MSE для различных АНС.

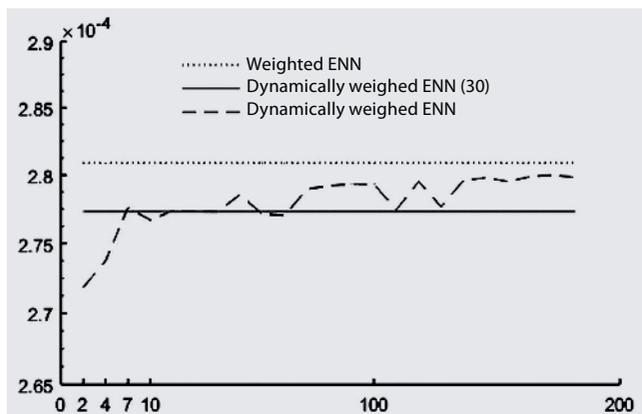


Рис. 4. Оценка динамически взвешиваемого АНС в зависимости от шага взвешивания

Архитектура	MSE	MAE
Одиночная НС	0,6035	0,48428
АНС	0,030388	0,12742
Взвешенный АНС	0,028874	0,12115
Динамически взвешиваемый АНС с шагом 10	0,02661	0,11703
Динамически взвешиваемый АНС с шагом 10 с дообучением	0,015286	0,08767

Таблица 4. Оценка архитектур на тестовом наборе с трендом и сезонным отклонением

Процедура оценки состоит из следующих шагов: обучение АНС с субоптимальным размером скрытого слоя; определение интервала поиска шага взвешивания; оценка MSE АНС, взвешенного АНС, динамически взвешенного АНС с фиксированным шагом, а также с шагом, равным текущему значению из интервала; до конца интервала поиска – переход к следующему его элементу.

Из данных табл. 4 видно, что наименьшей ошибкой обладает динамически взвешиваемый АНС с малым шагом (менее 10 временных отсчетов).

ОЦЕНКА АРХИТЕКТУР НС ПРИ НАЛИЧИИ ДРЕЙФА ЦЕЛЕВОЙ ПЕРЕМЕННОЙ

Для данного эксперимента в исследуемые данные искусственно вносились модификации. Был добавлен линейно возрастающий тренд, а в качестве периодической составляющей моделировался синусоидальный сигнал. На рис. 5 показана модификация набора данных Dt_set_s1

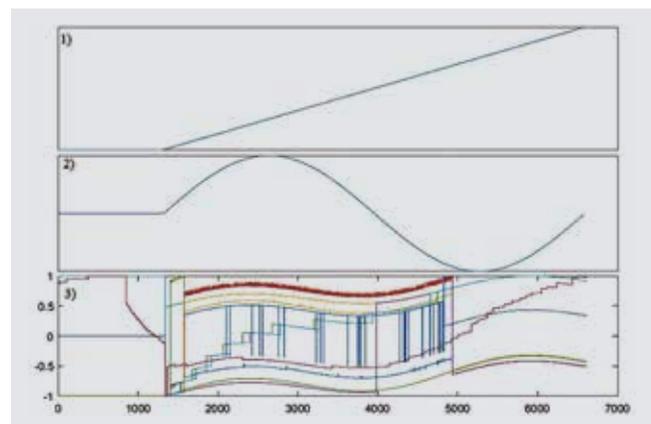


Рис. 5. Модификация набора данных для оценки дообучения АНС: 1) возрастающий тренд; 2) периодическая составляющая; 3) модифицированный многомерный сигнал

для оценки дообучения АНС. Первые 1319 отсчетов используются без модификации.

Процедура оценки состоит из следующих шагов: обучить АНС; модифицировать набор данных для обработки добавлением тренда и (или) сезонной составляющей; задать порог для алгоритма данного процесса и минимальный объем дообучающей выборки; оценить точность лучшей НС из 10, АНС, взвешенного АНС, динамически взвешенного АНС с фиксированным шагом, динамически взвешенного АНС с дообучением, которое производится только при накоплении указанного объема данных.

Все модели показали значительное падение точности на модифицированном наборе, включая и АНС с дообучением, что связано с интервалом накопления минимального объема выборки.

СИСТЕМА НЕЙРОСЕТЕВОЙ ИДЕНТИФИКАЦИИ СОСТОЯНИЯ ПОДСИСТЕМ КА

На рис. 6 представлена схема функционирования системы нейросетевой идентификации состояния подсистем космического аппарата.

Совместно блок анализа переключений режимов и блоки контроля функционируют по схеме конечного автомата, в котором множество состояний содержит все допустимые режимы функционирования систем КА. В каждом блоке контроля выполняются следующие операции: проверка возможности реализации текущей команды; анализ нахождения ТМИ в границах допустимых значений; при успешном осуществлении предыдущих операций выбирается нейросетевой модуль идентификации, который на основе ТМИ делает заключение о вероятности появления нештатной ситуации в анализируемой системе КА.

Работа по данной схеме предполагает наличие этапа обучения, который включает формирование конечного автомата на основе описания режимов и ограничений функционирования, конструирование нейросетевых модулей для каждого режима их обучения на соответствующей выборке. При этом минимизируется целе-

вая функция, выстроенная в виде квадратичной суммы разностей между фактическими и ожидаемыми значениями выходных сигналов. Далее исходные данные преобразуются с учетом характера и типа проблемы, отображаемой НС моделью, и выбираются способы представления информации. Эффективность НС-модели повышается, если диапазоны изменения входных и выходных величин приведены к диапазону $[-1, 1]$.

Организация АНС в два уровня [11, 22] реализует гетерогенность нейросетевой системы, где первый уровень структуры представлен набором ансамблей разнородных сетей, а второй – одним обобщающим модулем. В качестве эксперта второго уровня может применяться ансамбль или одиночная сеть-супервизор, обрабатывающие выходные значения всех элементов первого уровня. АНС анализа временного ряда с различным шагом дискретизации представлена на рис. 7. В качестве базовой сети использовалась НС прямого распространения.

На первом этапе обучения исследовались 4 масштаба дискретизации входного временного ряда (элемент входного временного ряда

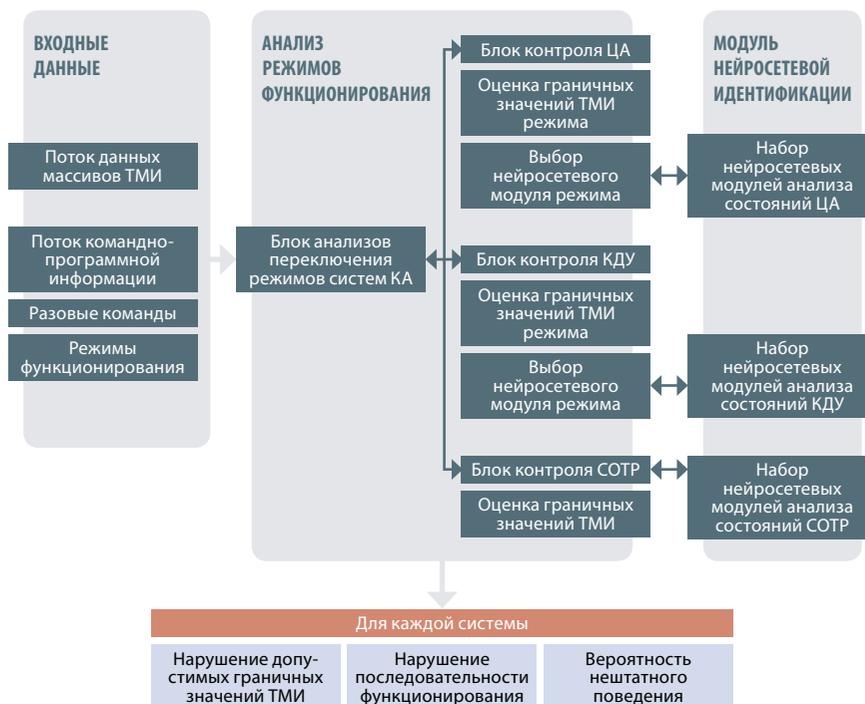


Рис. 6. Схема функционирования нейросетевой системы идентификации состояния подсистем КА

