

УДК 629.785

**Разработка прототипа интеллектуальной системы
оперативного мониторинга и технического состояния основных
бортовых систем космического аппарата**

Воронцов В.А.*, Федоров Е.А.**

*Научно-производственное объединение им С.А. Лавочкина» Ленинградское
шоссе, 24, Химки, Московская область, 141400, Россия*

**e-mail: vorontsov@laspacespace.ru*

***e-mail: feea@laspacespace.ru*

Аннотация

В данной статье приводится описание научно исследовательской работы по созданию программно-математической модели с элементами интеллектуальной системы для оперативного контроля состояния космического аппарата, которая будет применяться для наземного программного комплекса. Данная работа позволяет решать следующие задачи:

1. Возможность избежать непредвиденных нештатных ситуаций в космическом аппарате.
2. Прогнозирование возможных отказов с некоторой долей вероятности.
3. Возможность применения частичной автоматизации принятия решений для ликвидации отказов на борту.

Ключевые слова: интеллектуальная система, диагностика, контроль состояния, оперативный мониторинг, бортовые системы КА.

Введение

На сегодняшний момент практически любой бортовой комплекс относится к классу сложных технических систем. Поэтому повышение качества функционирования и определение полного технического состояния бортовых систем является важной проблемой. В обеспечении требуемого уровня качества функционирования и надежности сложных технических систем, особая роль принадлежит различным методам диагностирования. Ведь от работы этих систем зависит миссия всего аппарата, и сегодня недопустима потеря работоспособности хотя бы части бортовой системы.

Поэтому главная задача любого конструктора бортовых систем – это оценка качества надежности бортовой аппаратуры. Но идеальная «работоспособности» и полная «неработоспособность» на практике встречаются очень редко, эти состояния скорее являются сейчас некими граничными состояниями на шкале всех возможных состояний космического аппарата.

На данном этапе развития бортовых систем полный контроль состояния осуществляется через анализ телеметрической информации. Рассмотрим, как это происходит. Готовятся информационные кадры о состоянии бортовой системы, потом они подготавливаются в формат для передачи на наземный комплекс приема телеметрии, затем происходит сеанс связи, после этого телеметрия анализируется и, если в информации находятся какие-то кадры которые требуется

вмешательства наземных операторов, производится передача информации о реконфигурации «критичной» системы. Несложно проследить долгую цепочку взаимодействий. [1]

Здесь стоит отметить, что все нештатные ситуации делятся на парируемые, т.е. ожидаемые и неожиданные. И если информация в телеметрии будет указывать на неожиданную нештатную ситуацию, то время для принятия решения по парированию такой ситуации может очень сильно растянуться во времени, это время может оказаться судьбоносным, особенно если космический аппарат готовится на освоение дальнего космоса.

По той причине, что не предусмотрена возможность автоматизированного выявления «пред-дефектных» состояний на борту КА, все это не дает возможности предсказания состояния КА на следующие сеансы связи и не позволяет своевременно принять меры по предотвращению аппаратных сбоев. [2]

Данную проблему можно минимизировать, применяя интеллектуальную систему диагностики оперативного контроля состояния систем космического исполнения. Идеальным вариантом была бы диагностика неисправностей «на лету» и принятие мер для правильной оценки и ликвидации нештатной ситуации.

В данной статье предлагается краткий обзор технологии диагностики технического состояния некоторой части космического аппарата (посадочная платформа). Технология, основанная на использовании аппроксимации поверхности вероятности отказов с помощью экспертных систем. Одним из эффективных методов реализации данной технологии диагностики, основан на

нейросети, обеспечивающий адаптивность, точность и высокую вычислительную экономичность построения поверхности вероятности отказов. Преимущества нейронной сети реализуются за счет предварительного формирования поверхности вероятности отказов с помощью правил и последующего уточнения путем обучения на примерах, формируемых на модели диагностируемой системы.

Предлагаемая технология позволит обеспечить адаптацию поверхности вероятности отказов к изменяемым условиям функционирования при различных режимах работы посадочной платформы, имея существенно меньший требуемый объем экспериментальных данных по сравнению с традиционными методами.

1. Структура модели основных подсистем космического аппарата.

За основу были взяты три основные структуры диагностирования подсистем посадочной платформы, которые указаны на рис. 1, а именно системы энергоснабжения, системы терморегуляции и самой бортовой вычислительной машины, которая будет представлена в виде математической модели.

На рис. 1 представлена схема, включающая диагностируемые подсистемы посадочной платформы.

Подсистема 1. Бортовая ВМ.

Модель ВМ состоит из 5 модулей:

- Измерительный модуль. Производит измерение и фильтрацию входных сигналов;

- 1-й процессорный модуль. Формирует управляющие сигналы на системы потребители (система энергоснабжения);
- 2-й процессорный модуль. Формирует управляющие сигналы на системы потребители (система терморегулирования);
- 3-й процессорный модуль. Реализует работу системы диагностики, основой которой является нейросеть;
- Общая сетевая шина информационных данных.

Подсистема 2. Система энергоснабжения

Принятая СЭС включает подсистемы:

- Солнечные батареи. Работа солнечных батарей контролируется датчиками напряжения и тока;
- Модуль интеллектуальной зарядки. Работа зарядки контролируется датчиками напряжения и тока;
- Аккумуляторные батареи. Работа аккумуляторных батарей контролируется датчиками напряжения и тока.

Подсистема 3. Система терморегулирования

Система терморегулирования включает подсистемы:

- Нагревательная система. Работа контролируется датчиками температуры. Управление работой нагревателя реализуется реле при подаче

управляющих сигналов от вычислительной машины. Контроль срабатывания реле обеспечивается датчиком реле.

- Охладительная система. Работа контролируется датчиками температуры. Управление работой охладителя реализуется реле при подаче управляющих сигналов от вычислительной машины. Контроль срабатывания реле обеспечивается датчиком реле.

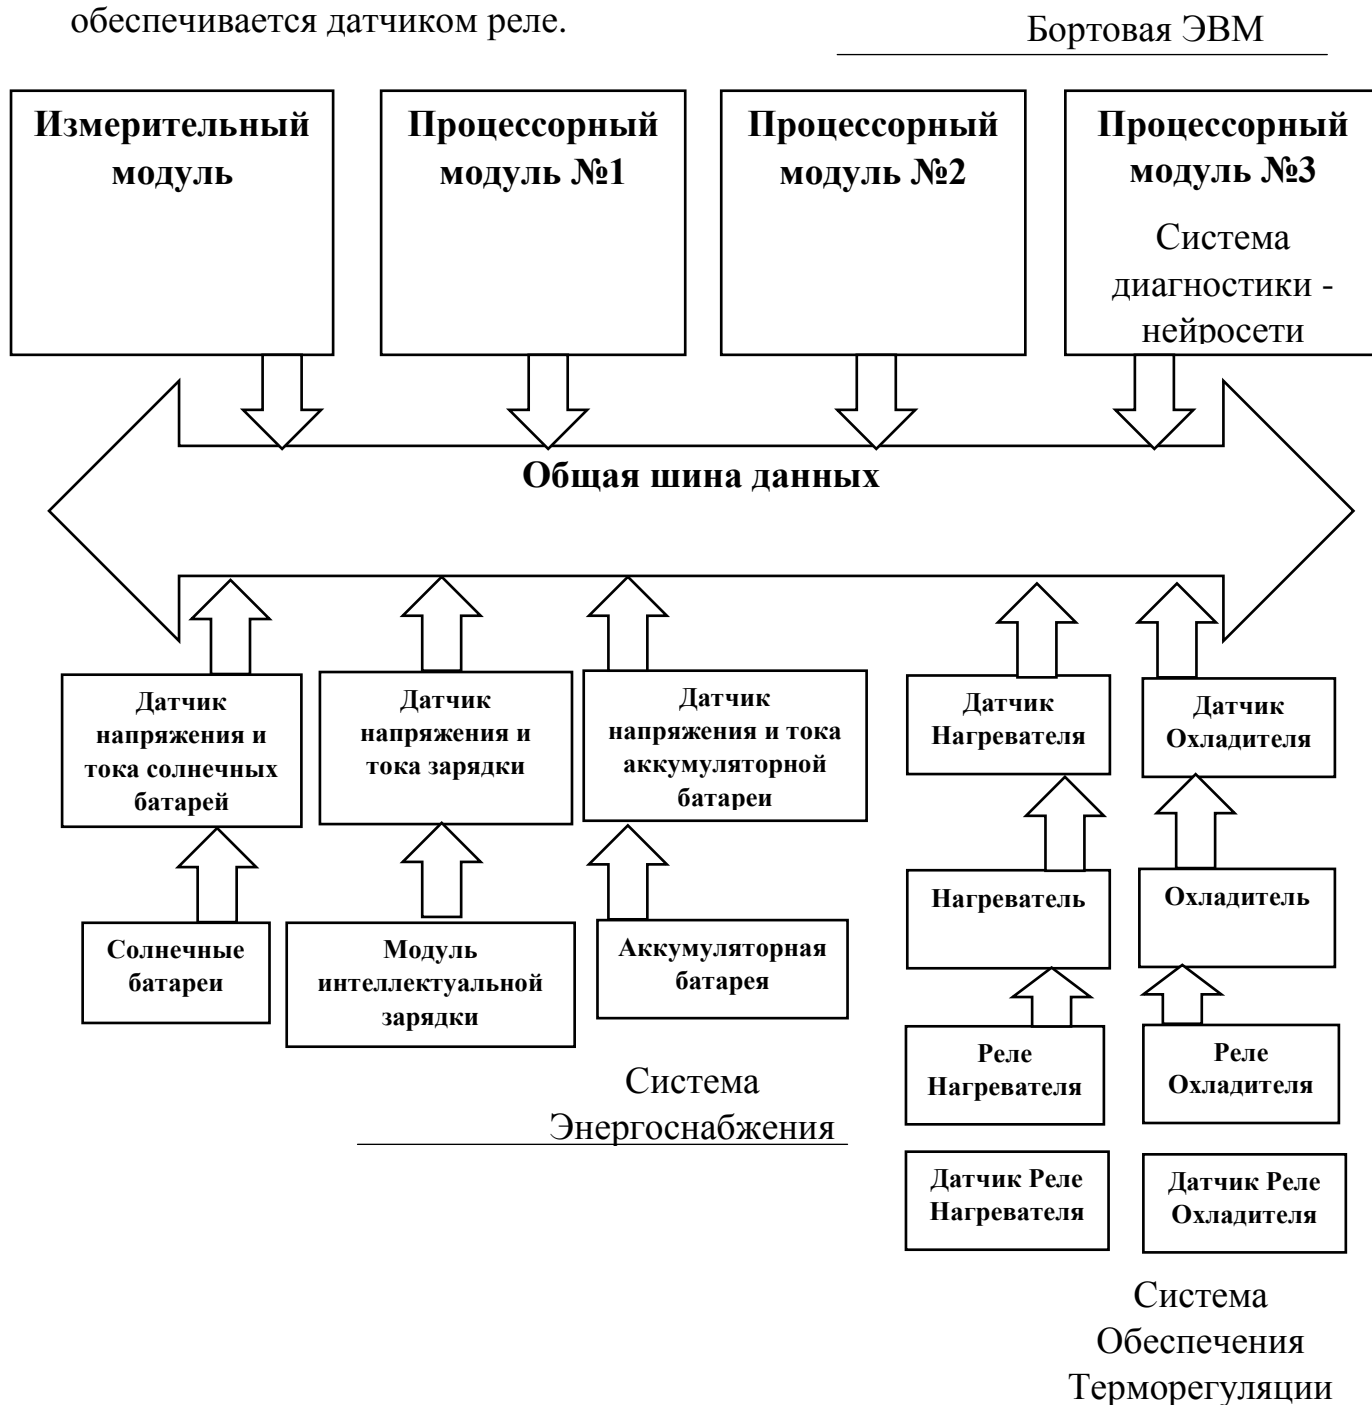


Рис.1. Структура диагностируемой подсистемы космического аппарата.

Перед тем как рассматривать эффективность нейросетевого подхода к задачам мониторинга функционального состояния технических систем, дадим описание самой нейронной сети.

Нейронные сети – это одно из направлений исследований в области искусственного интеллекта, основанное на попытках воспроизвести нервную систему человека. А именно: способность нервной системы обучаться и исправлять ошибки, что должно позволить смоделировать, хотя и достаточно грубо, работу человеческого мозга.

Биологический нейрон – это специальная клетка, которая структурно состоит из ядра, тела клетки и отростков. Одной из ключевых задач нейрона является передача электрохимического импульса по всей нейронной сети через доступные связи с другими нейронами. При этом, каждая связь характеризуется некоторой величиной, называемой силой синаптической связи. Эта величина определяет, что произойдет с электрохимическим импульсом при передаче его другому нейрону: либо он усилится, либо он ослабится, либо останется неизменным.

Нейронные сети– это упрощенные модели биологических нейронных сетей. На этом сходство заканчивается. Структура человеческого мозга гораздо более сложная, чем описанная выше, и поэтому воспроизвести ее хотя бы более-менее точно не представляется возможным. [4,5]

У нейронных сетей много важных свойств, но ключевое из них – это способность к обучению. Обучение нейронной сети в первую очередь

заключается в изменении «силы» или «веса» синаптических связей между нейронами.

Рассмотрим математическую модель нейрона, которая строится следующим образом как показано на рисунке 2:

В этой модели нейрона можно выделить три основных элемента:

- **синапсы**, каждый из которых характеризуется своим весом или силой.

Осуществляют связь между нейронами, умножают входной сигнал x_i на весовой коэффициент синапса w_i , характеризующий силу синаптической связи;

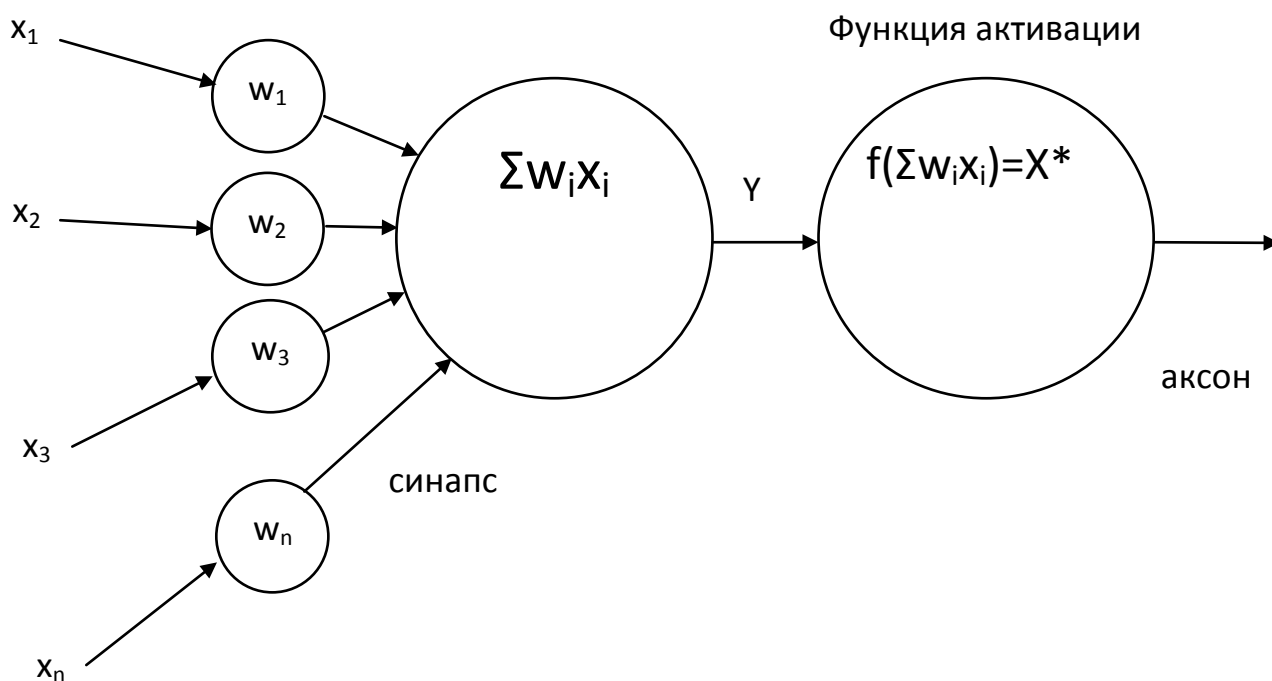


Рис. 2. Модель искусственного нейрона.

- **сумматор**, аналог тела клетки нейрона. Выполняет сложение внешних входных сигналов или сигналов, поступающих по синаптическим связям от других нейронов. Определяет уровень возбуждения нейрона;

- **функция активации**, определяет окончательный выходной уровень нейрона, с которым сигнал возбуждения (торможения) поступает на синапсы следующих нейронов.

Модель нейрон имитирует в первом приближении свойства биологического нейрона. На вход искусственного нейрона поступает некоторое множество сигналов, каждый из которых является выходом другого нейрона. Каждый вход умножается на соответствующий вес, пропорциональный синаптической силе, и все произведения суммируются, определяя уровень активации нейрона.

Хотя сетевые парадигмы весьма разнообразны, в основе почти всех их лежит эта модель нейрона. Здесь множество входных сигналов, обозначенных x_1, x_2, \dots, x_n поступает на искусственный нейрон. Эти входные сигналы, в совокупности, обозначаемые вектором X , соответствуют сигналам, приходящим в синапсы биологического нейрона. Каждый сигнал умножается на соответствующий вес w_1, w_2, \dots, w_n и поступает на суммирующий блок, обозначенный $\sum w_i x_i$. Каждый вес соответствует «силе» одной биологической синаптической связи. Множество весов в совокупности обозначается вектором W . Суммирующий блок, соответствующий телу биологического элемента, складывает взвешенные входы алгебраически, создавая выход Y . Далее Y поступает на вход функции активации, определяя окончательный сигнал возбуждения или торможения нейрона на выходе. Этот сигнал поступает на синапсы следующих нейронов и т.д.

Теперь применим нейронную сеть для решения сложных, плохо формализуемых задач диагностирования, где эффективность нейросетевого подхода проявляется в полной мере и может быть успешно реализована при решении задач мониторинга функционального состояния технических систем. В настоящее время искусственные нейронные сети с успехом используются для решения большого количества различных задач, в том числе задач идентификации моделей, кластеризации данных и задач распознавания образов. Задача мониторинга функционального состояния параметров технических систем также может быть представлена как задача кластеризации данных или распознавания образов, в которой распознаваемыми образами являются состояния структурных единиц и элементов диагностируемой системы, а входной набор данных искусственной нейронной сети представляет собой массив значений основных диагностических признаков.

Существуют два больших класса искусственных нейронных сетей, классифицируемых по реализации обучения:

- **сети, обучаемые с учителем;** обучение нейронной сети с учителем предполагает, что для каждого входного вектора из обучающего множества существует требуемое значение выходного вектора, называемого целевым. Эти вектора образуют обучающую пару. Веса сети изменяют до тех пор, пока для каждого входного вектора не будет получен приемлемый уровень отклонения выходного вектора от целевого;

- **сети, обучающиеся без учителя (самообучающиеся);** обучение нейронной сети без учителя является намного более правдоподобной моделью обучения с точки зрения биологических корней искусственных нейронных сетей. Обучающее множество состоит лишь из входных векторов. Алгоритм обучения нейронной сети подстраивает веса сети так, чтобы получались согласованные выходные векторы, т.е. чтобы предъявление достаточно близких входных векторов давало одинаковые выходы.

При реализации системы мониторинга функционального состояния с использованием сетей, обучаемых с учителем, например, многослойного персептрона, в системе мониторинга или диагностики должна быть предусмотрена процедура получения обучающей выборки, в которой должны присутствовать как входные данные, так и соответствующие им результаты диагностирования работы технической системы. Таким образом, обучающая выборка должна быть сформирована с участием эксперта, и в связи с этим, такая нейросетевая система диагностирования фактически представляет собой нейросетевую экспертную систему. [3]

В случае использования самообучающейся искусственной нейронной сети (например, сеть Кохонена или сеть адаптивного резонанса) обучающая выборка представляет собой набор векторов измеряемых параметров объекта мониторинга. Сеть самостоятельно разделяет их на классы в соответствии с заложенным в нее алгоритмом. Тем не менее, интерпретировать полученные

результаты, прежде чем они будут использованы для мониторинга технической системы, в большинстве случаев также должен человек-эксперт.

Наиболее распространенный метод диагностики работы основных бортовых систем и подсистем (ЭВМ, терморегуляция, энергообеспечение) заключается в проведении ряда различных тестов. Для каждой подсистемы разрабатываются свои тесты, по результатам которых можно судить об отказе подсистемы.

Ставится задача анализа отказов вычислительной машины по косвенным признакам. Под косвенными признаками понимаются результаты работы вычислительной машины, например, управляющие сигналы на системы потребители, результаты промежуточных вычислений, показания телеметрии и т.д.

Использование косвенных признаков для анализа отказов вычислительной машины существенно сокращает объем анализируемой информации. При этом возникает возможность диагностирования неявных отказов и прогнозирования возникновения отказа.

Рассмотрим структуру бортовой вычислительной машины, которая состоящую:

1. Измерительный модуль.
2. Первый процессорный модуль (для системы энергоснабжения).
3. Второй процессорный модуль (для системы терморегулирования).

Рассмотрим каждый модуль по отдельности:

Измерительный модуль производит измерение и преобразование сигналов (преобразование в цифровую форму, фильтрация), а также передачу преобразованных сигналов на процессорные модули. Этот модуль состоит из следующих систем:

- Модуль обработки и преобразования сигналов.
- Контроллер шины передачи данных, который осуществляет передачу преобразованных измерений.

Первый процессорный модуль осуществляет управление и контроль подсистем энергоснабжения.

На вход модуля подаются значения измерений от измерительного модуля. Внутри модуля полученные значения преобразуются в сигналы управления системы энергоснабжения.

Модуль процессора состоит из следующих элементов:

- ОЗУ - оперативная память процессорного модуля.
- Многоядерный процессор.
- ПЗУ - энергонезависимая память процессорного модуля.

ОЗУ и ПЗУ разбиты на области. Каждая область относится к определенной подпрограмме.

Второй процессорный модуль осуществляет управление и контроль подсистемы терморегулирования. Устройство модуля аналогично первого процессорного модуля.

Предполагается, что в диагностируемых системах описанной структуры могут возникнуть следующие отказы:

- Отказ модуля обработки сигналов – полный отказ. Приводит к выводу необработанного (зашумленного) сигнала.
- Отказы контроллера шины – замедление работы, потеря данных.
- Отказы процессорных модулей:
 - Отказ области памяти ОЗУ.
 - Отказ арифметико-логического устройства процессора.
 - Отказ области памяти ПЗУ.

Задачей является формирование поверхности вероятности безотказной работы диагностируемых систем.

Для решения этой задачи был применен подход с использованием нейронных сетей.

Для разработки и отладки нейронной сети использовался пакет среды LabVIEW, на котором были разработаны программы, позволяющие моделировать работу и обучение многослойной нейронной сети.

2. Моделирование работы нейронной сети

Программа состоит из 3 основных модулей:

- нейросетевого модуля,
- модуля обучения,
- модуля формирования структуры сети.

Многослойная сеть представляется в виде массива, каждый элемент которого описывает один слой сети. При этом, каждый слой представляет собой набор структур, как показано на рис. 3, описывающих связи нейронов текущего слоя.

Link				
Layer	Neur	In	W	type
0	0	0	0	0

Рис. 3. Структура связей нейросети.

Структура связей содержит следующие элементы:

1. Индекс слоя, к которому относится связь (Layer),
2. Индекс нейрона, которому принадлежит связь (Neur),
3. Индекс нейрона предыдущего слоя (In),
4. Вес связи (W),
5. Тип функции активации нейрона (type).

На рис. 4 и 5 показана схема и фрагмент кода модуля формирования структуры сети. По заданному описанию модуль генерирует многослойный персептрон. Веса связей задаются случайными числами в интервале от 0 до 1.




Рис. 4. Модуль формирования структуры нейронной сети.

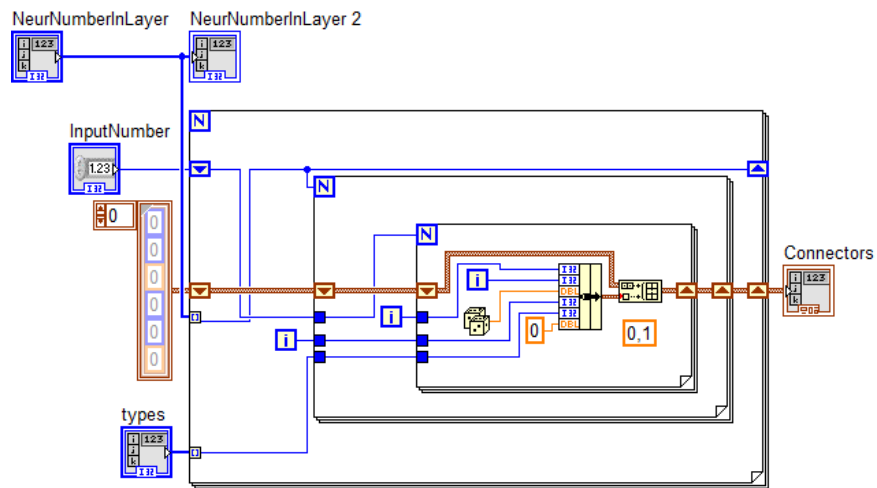


Рис. 5. Модуль формирования структуры нейронной сети.

На вход модуля поступают:

1. Массив *NeurNumberInLayer*, количество элементов которого соответствует количеству слоев в сети. Элементы массива соответствуют числу нейронов в каждом слое.

2. Массив *NeurType*, каждый элемент которого содержит индекс функции активации.

3. Количество входов в нейросеть.

На выходе модуля - структура связей нейросети.

На рисунке 6 и 7 представлены соответственно схема и фрагмент кода модуля, моделирующего работу нейросети. (0 – треугольная, 1 – гиперболический тангенс, 2- линейная с насыщением и т.д.)




Рис. 6. Модуль нейронной сети.

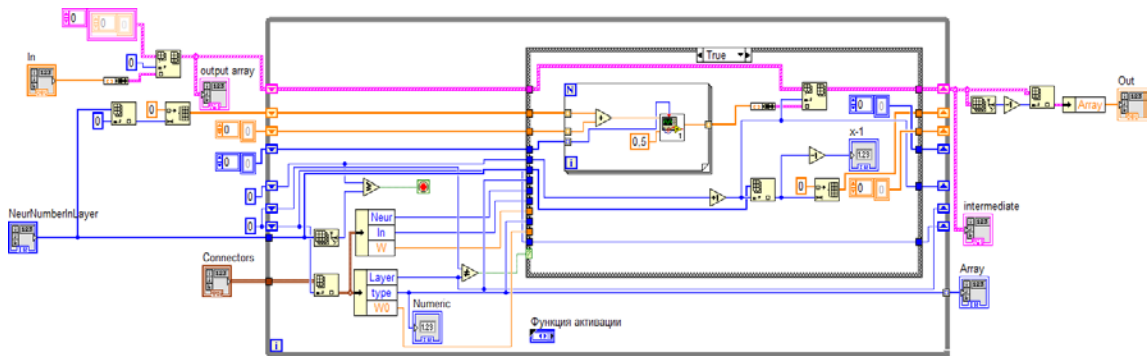


Рис. 7. Модуль нейронной сети.

Входы *NeurNumberInLayer* и *Connectors*, описывают структуру сети, а вход *In* задает вектор входных значений. Соответственно в вектор *Out* выводится выходной вектор сети. Также предусмотрен выход *intermediate*, содержащий промежуточные результаты расчетов для каждого слоя.

Схема модуля обучения показана на рис. 8 и 9. В модуле обучения реализован алгоритм методом обратного распространения ошибки, который представляет собой метод обучения нейросети. Это итеративный градиентный алгоритм, который используется с целью минимизации ошибки работы нейросети и получения желаемого выхода. Метод является модификацией классического метода градиентного спуска.




Рис. 8. Модуль обучения нейронной сети.

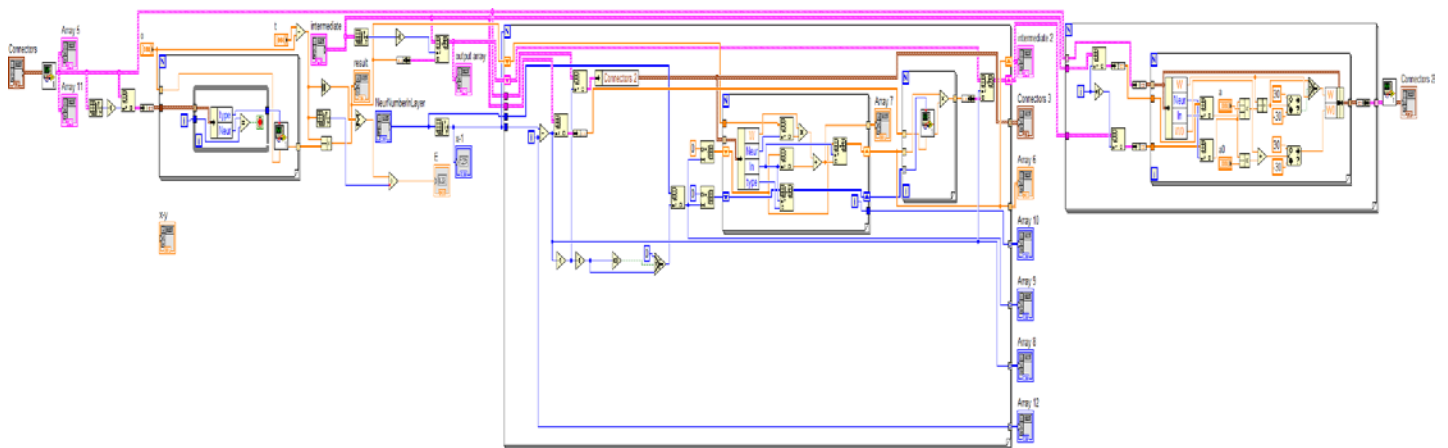


Рис. 9. Модуль обучения нейронной сети.

Входами модуля являются:

1. Текущий и ожидаемый выходной вектор нейронной сети – соответственно o и t ,
2. Структуру сети и связей – *NeurNumberInLayer* и *Connectors*,
3. Промежуточные результаты расчетов выходов слоев – *intermediate*,
4. Коэффициенты скорости обучения – a , $a\theta$.

Результатом работы модуля обучения является обновленная структура сети (*Connectors 2*) и модуль ошибки для текущего обучающего примера.

Программа позволяет моделировать нейронную сеть с произвольным количеством входов, выходов, слоев, нейронов в слое и типов нейронов.

Для системы диагностики отказов вычислительной машины была выбрана следующая структура сети: 3 входных нейрона, 1 внутренний слой с 300 нейронами и 3 выходных нейрона.

На вход системы диагностики будут подаваться значения: ошибки обработки измерений, ошибки управления системой энергоснабжения. А на выходе будут степени достоверности отказа для каждого модуля.

3. Обучение нейронной сети.

При обучении сначала на входы исходной нейронной сети подаются первые три значения первой строки табл. 1. Это оценочные значения, моделирующие величину ошибки, которые могут вноситься неисправной системой в измерения и в их обработку, т.е. саму тестовую выборку. В результате, такая накопительная ошибка окажется на выходе неисправной системы. Для примера, взяты три выхода, которые можно проследить в диагностируемой системе, поэтому входов на нейронную сеть тоже три. Таким образом на реальную диагностируемую систему подается набор тестовых сигналов, считываются конкретные выходные значения, которые не привязаны к конкретным физическим величинам, получившийся вектор выходов получается выборкой при всех рабочих модулях. Далее производится моделирование неисправностей различных модулей, таких как одиночные и совместные, и также записываются все выходы. Далее для каждого примера записывается величина ошибки (оценка ошибки) по сравнению со случаем рабочей системы. Полученные значения записываются в табл. 1 (в первые три колонки).

Полученные результаты, т.е. достоверность отказа того или иного модуля (одного из трех или комбинацией из этих же трех модулей) при возникновении

текущего сочетания ошибок. Эти значения возникают после подачи на нейронную сеть значений ошибок. Полученные результаты сравниваются с ожидаемыми (т.е. с последними тремя колонками табл. 1) и подаются на вход модуля обучения (методом обратного распространения ошибки). Ожидаемые значения – реальные значения показаний отказов (модуль один - отказ с достоверностью 1, модуль 2 - отказ с достоверностью 0), или значения, которые мы хотим, чтобы сеть выдавала после обучения.

Модуль обучения изменяет веса связей в нейросети в зависимости от величины рассогласования полученных и ожидаемых значений выходов.

Алгоритм обучения следующий: берутся текущие выходы, ожидаемые выходы. Считается их разница (для каждого выхода). Далее меняются параметры и веса связей нейронов, соответствующих этому выходу. Величина изменения веса и параметра зависит от величины рассогласования, типа нейрона (типа функции активации) и параметров, задаваемых до обучения (например, параметр скорости обучения).

Алгоритм обучения повторяется для каждого примера обучающей выборки (строки табл. 1).

Далее рассчитывается значение средней ошибки по всем примерам выборки. Если это значение больше некоторого порога – обучение останавливается, если нет – все шаги обучения повторяются.

Табл. 1. Часть обучающей выборки системы диагностики отказов вычислительной машины.

Ошибка модуля измерений	Ошибка управления системой энергоснабжения	Ошибка управления системой терморегулирования	Отказ модуля измерений	Отказ модуля процессора №1	Отказ модуля процессора №2
1100	3139	1100	1	1	0
0	0	3041	0	0	1
1051	3052	4092	0	1	1
0	2074	3082	0	1	1
1100	1100	4141	1	0	1
1050	3089	4091	1	1	1
1051	3119	4092	0	1	1
0	0	0	0	0	0
...

Для системы диагностики отказов диагностируемых систем обучение нейросети происходило отдельно для каждого отказа.

Динамика изменения средней ошибки по всей обучающей выборке показана на рисунках 10, 11 и 12.

0




Рис. 10. График средней ошибки обучения по всей выборке в зависимости от шага обучения для отказов модуля измерителя.

1




Рис. 11. График средней ошибки обучения по всей выборке в зависимости от шага обучения для отказов модуля процессора №1.




Рис. 12. График средней ошибки обучения по всей выборке в зависимости от шага обучения для отказов модуля процессора №2.

Для оценки качества работы обученной сети проводится ряд тестов.

Во время тестов происходит моделирование отказов. Параметры, полученные при моделировании, подаются на вход системы диагностики.

Возможно два варианта ошибок системы диагностики: пропуск отказа (ошибка 1-го рода) и ложное срабатывание (ошибка 2-го рода). В табл. 2 приведены результаты тестов.

Табл. 2. Результаты тестов нейронной сети

Проведено 50 тестов	Ошибки 1-го рода	Ошибки 2-го рода
Отказ МИ – 10 примеров	0.1	0
Отказ МЦП 1 – 20 примеров	0	0.2
Отказ МЦП 2 – 20 примеров	0.1	0.15

Заключение

На сегодняшний момент очевидно, что нейронные сети черпают своё преимущество из-за возможности распараллеливания обработки информации, а также из способности самообучаться, т.е. создавать обобщения. Под термином обобщение понимается способность получать обоснованный результат на основании данных, которые не встречались в процессе обучения. Эти свойства позволяют нейронным сетям решать масштабные задачи мониторинга и диагностики, которые на сегодняшний день считаются трудноразрешимыми. Однако на практике при автономной работе нейронные сети не могут обеспечить готовые решения, их непременно нужно интегрировать в объект исследования, в данном случае сверхсложные бортовые системы космического применения.

Библиографический список

1. Матюшин М.М., Саркисян Х.И. Построение оценочной функции поддержки принятия оперативных решений при контроле параметров состояния космического аппарата // Наука и Образование. 2011. №4. С. 1-15с.
2. Соловьёв В.А., Лысенко Л.Н., Любинский В.Е. Управление космическими полётами. - М.: МГТУ им. Н.Э.Баумана, 2009. – 426с.
3. Круглов В.В., Борисов В.В. Искусственные нейронные сети. Теория и практика. –М.: Горячая линия. Телеком, 2001, – 382 с.

4. Tracy Cooke, Helen Lingard and Nick Blismas. The development and evaluation of a decision support tool for health and safety in construction design. *Engineering, Construction and Architectural Management*. Vol. 15 No. 4, 2008, pp. 336-351, Emerald Group Publishing Limited
5. Stuart J. Russell and Peter Norvig. *Artificial Intelligence. A Modern Approach*. 1999. – 31 – 57 c.