

УДК 621.455

РАКЕТЫ. АВТОМАТЫ. НЕЙРОННЫЕ СЕТИ

А.В. Кретинин, Д.В. Солдатов, А.А. Шалыто, А.В. Шостак

Введение

Экспериментальные факторные модели не учитывают физических законов исследуемых процессов, а выражают лишь формальные зависимости некоторых критериев эффективности или работоспособности от входных параметров, посредством варьирования которых мы можем влиять на выходные характеристики объекта [1]. Таким образом, экспериментальная факторная модель представляется в виде «черного ящика», который можно характеризовать как имитационную модель функционирования, предсказывающую выходные параметры – отклики модели – в исследованном путем проведения физических или численных экспериментов пространстве входных факторов.

Графические нотации таких моделей представляют собой гиперповерхности зависимостей выходных факторов от входных: в одномерном случае – обычные графики характеристик. Графическую зависимость можно рассматривать своего рода как «подпись» объекта исследования. При нормальном функционировании данная «подпись» воспринимается как эталонная подпись «здорового» устройства. При наличии дефектов эта «подпись» будет, очевидно, отличаться от эталонной. Таким образом, если создать систему распознавания или идентификации изображений функциональных откликов, то возможно ее использование для диагностирования работоспособности технического устройства с учетом деградации характеристик и возникновения дефектов путем текущего контроля по измеряемым параметрам функционирования объекта исследования.

Одними из первых задач, на решение которых исторически были ориентированы искусственные нейронные сети (ИНС) – это задачи распознавания изображений. Эти задачи близки к обычным аппроксимационным проблемам, хотя особенности их решения весьма многочисленны, вследствие чего проблемы распознавания выделились в отдельный раздел нейроматематики. Изложим некоторые методические аспекты разработки нейросетевых моделей функционирования, которые образно можно назвать «портретами» функционирования технических устройств [2].

Первым этапом формирования нейросетевого портрета функционирования является определение границ пространства входных факторов, в пределах которого имеется экспериментальная информация о работоспособности объекта. При этом необходимо различать управляемые и неуправляемые факторы, активный или пассивный эксперимент. В случае активного эксперимента значения управляемых переменных должны варьироваться по определенному плану. Очевидно, можно использовать общепризнанные оптимальные планы, либо некоторые другие модернизированные алгоритмы, в частности, LP_T алгоритм генерации равномерных последовательностей чисел [3]. В этом случае границы факторного пространства заранее четко определены и осуществляется целенаправленный эксперимент для получения факторной модели, работоспособной во всех диапазонах изменения входных факторов.

При снятии экспериментальных характеристик непосредственно во время работы изделия в составе разрабатываемого технического устройства при «промышленном» эксперименте мы уже по сути дела оперируем лишь неуправляемыми факторами, которые изменяются не по плану эксперимента, а в соответствии с законами функционирования технической системы, которая может характеризоваться многосвязностью и многопараметричностью внутренней функциональной структуры. В этом случае важно четко определить границы применимости разрабатываемой

факторной модели в пространстве входных переменных. Далее при проведении вычислительного эксперимента необходимо контролировать сочетание входных факторов и при возникновении входного воздействия, не входящего в допустимую область определения факторного пространства, точность модели функционирования будет определяться лишь экстраполяционными возможностями разработанной имитационной математической модели. Следовательно, с большой вероятностью обладать недостаточной надежностью для применения в системах диагностирования работоспособности технического устройства.

Рассмотрим некоторые положения использования технологии ИНС для разработки нейросетевых портретов функционирования технических устройств.

1. На первом этапе осуществляется отбор входных переменных. В общем случае точно неизвестно, какие факторы влияют на критерии эффективности функционирования. С этой точки зрения необходимо учитывать максимальное количество факторов даже тех, чье влияние сомнительно. С другой стороны увеличение числа факторов приводит к трудностям получения малой ошибки обучения нейронной сети вследствие «проклятия размерности». Для отсеивания ненужных факторов существует несколько практических советов [4]. Это тестирование переменных методом проб и ошибок путем их наращивания или отсеивания, метод регуляризации весов по Вигенду и, наконец, генетический алгоритм отбора входных данных. Этот алгоритм экспериментирует с различными наборами входных переменных, кодированными в виде битовых масок, над которыми осуществляются генетические операции скрещивания и мутации, и осуществляется оптимизационный поиск по величине контрольной ошибки либо ошибки обучения.

2. Массивы экспериментальных данных используются для нахождения границ области определения пространства входных переменных. С этой целью могут использоваться самоорганизующиеся карты Кохонена. Вместе с

тем ниже используется несколько иной подход. Очередной вектор входных переменных $\mathbf{x}_i = \{x_1, x_2, \dots, x_N\}^T$ из таблицы испытаний будем рассматривать как центр гиперпараллелепипеда, длина сторон которого, параллельных координатным осям x_i , определяется с учетом максимальных допусков на их изменение в процессе функционирования

$$x_i^* - 2k\Delta \leq x_i \leq x_i^* + 2k\Delta,$$

где x_i^* - измеренное значение i -го фактора;

Δ - абсолютная экспериментальная погрешность его определения;

k - параметр, определяющий максимальный допуск на изменение фактора x_i .

В указанной области входного пространства генерируется 2^n точек равномерной последовательности с использованием LP_τ алгоритма. Эти значения входных переменных совместно с измеренными значениями будут составлять обучающую выборку входных переменных, а выходом сети будет являться $y=0$ в случае, если текущий вектор входов по каждой переменной попадает в интервал $x_i^* - k\Delta \leq x_i \leq x_i^* + k\Delta$, и $y = 1$ – в противном случае. Далее строится аппроксимирующая нейронная сеть с максимальной точностью. Функционирование сети происходит следующим образом: если выход сети $y_{NET} < 0.5$, то результатом ИНС будет диагностический параметр «допустимое сочетание входных факторов», иначе – «недопустимое...».

3. Разрабатываются портреты функционирования путем аппроксимации экспериментальных данных [2]. При этом целесообразно выделение характерных состояний и использование автоматного подхода при переходе из одного состояния в другое. Это приводит к повышению точности нейросетевых аппроксимаций и, следовательно, снижению допусков на возможные отклонения характеристик устройства для использования в системах диагностирования.

1. Выделение состояний и разработка конечного автомата

Характерным представителем сложных технических систем, для которых актуально создание функциональных моделей, является жидкостный ракетный двигатель (ЖРД). При огневых испытаниях ЖРД регистрируется несколько сотен параметров его функционирования такие, как давления, расходы, температуры, частоты вращений валов турбонасосных агрегатов, вибрационно-пульсационные характеристики быстро меняющихся процессов и т.д.

Разрабатываемая в настоящей работе методика создания нейросетевых конечных автоматов для моделирования агрегатов ЖРД иллюстрируется на примере моделирования функционирования турбонасосного агрегата (ТНА) ЖРД РД0124 на запуске. Рассматриваемый ТНА конструктивно состоит из осевой турбины, двухступенчатого центробежного насоса горючего и центробежного насоса окислителя и является основным агрегатом системы подачи (питания) ЖРД. В качестве входных параметров (изменение которых влияет на функционирование ТНА и значения которых измеряются на стенде) будем использовать:

- давления компонентов топлива на входе в насосы ТНА p_{O0} и $p_{Г0}$ (*ДОДН* и *ДГДН* – давления окислителя и горючего до насосов ТНА);
- давления окислительного газогенераторного газа до и после турбины ТНА $p_{Г0}$ (*ДОДТ* – давление до турбины) и $p_{Г1}$ (*ДОПТ* – давление после турбины).

Выходными параметрами, характеризующими работоспособность агрегата, являются:

- давления компонентов на выходе насосов p_{O1} , $p_{Г1}$ и $p_{Г2}$ (*ДОПН* – давление окислителя после насоса окислителя ТНА, *ДГПН1* и *ДГПН2* – давления горючего после первой и второй ступеней насоса горючего);
- число оборотов вала ТНА n (*ОТ* – обороты турбины).

Для создания модели агрегата используется автоматный подход [5], так как он позволяет исключить появление непредусмотренных состояний,

которые могут привести к непредсказуемым последствиям. Для переходов между состояниями агрегата в соответствии с подходом, изложенным в работе [5], используется единственная многозначная переменная Y с определенными заранее значениями. Поэтому появление непредсказуемых состояний в программе практически невозможно.

В соответствии с рекомендациями, изложенными в технологии автоматного программирования [5–9], при функционировании ТНА необходимо выделить состояния, в которых он может находиться.

В ходе анализа графических зависимостей характеристик агрегата выяснилось, что изменение оборотов вращения вала ТНА во времени имеет ярко выраженные участки (рис. 1).

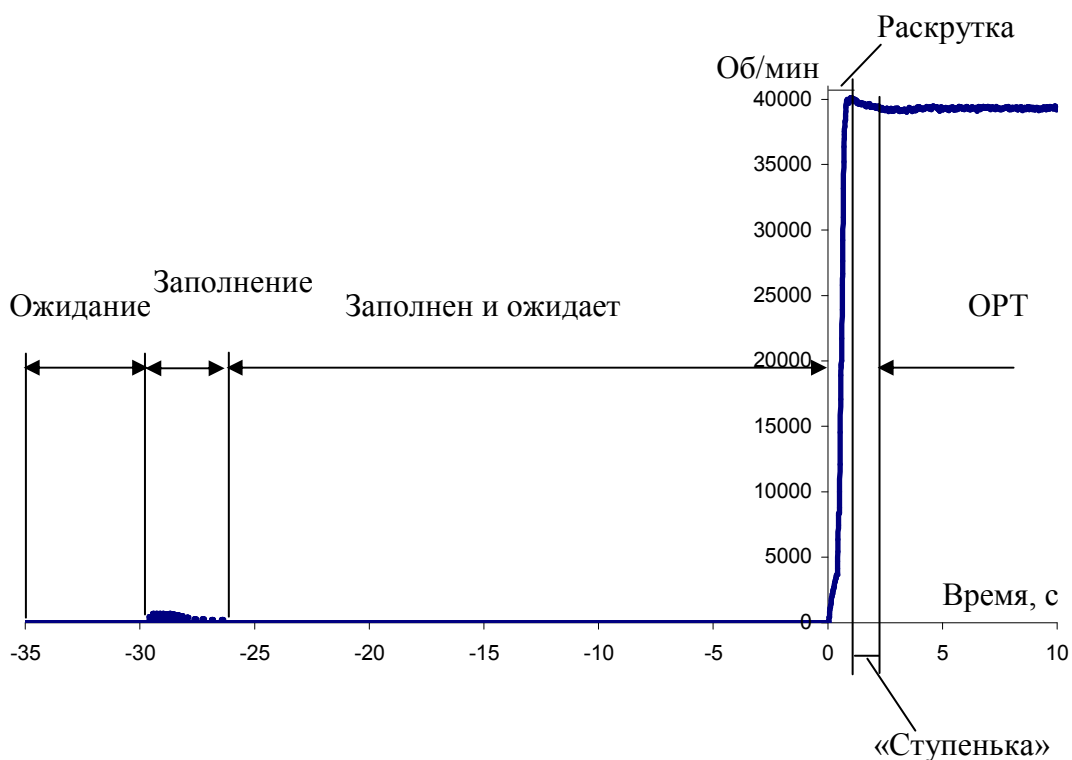


Рис. 1. Изменение оборотов ТНА во времени и соответствующие ему состояния

Поэтому были выделены семь состояний функционирования ТНА на запуске, которым присвоены следующие наименования:

0. *Ожидание* – компоненты топлива отделены от магистралей двигателя мембранными пусковыми клапанами.
1. *Заполнение топливом* (авторотация) – после срабатывания пиропатронов происходит заполнение топливом двигательных магистралей.
2. *Заполнен и ожидает* – в этом состоянии ТНА находится вплоть до прохождения команды *Зажигание*.
3. *Раскрутка ТНА* – прошла команда *Зажигание*.
4. *Ступенька* - состояние характеризуется повышенными оборотами вала ТНА по сравнению с оборотами на основном режиме тяги.
5. *Основной режим тяги* – состояние наступает при стационарном поведении параметров функционирования ТНА.
6. *Аварийное состояние* – диагностируется при отличном от экспериментального сочетании входных или выходных параметров агрегата.

Классификация текущего состояния ТНА осуществляется с использованием шести нейронных сетей, которые по значениям входных параметров *ДОДТ*, *ДОПТ*, *ДОДН* и *ДГДН* формируют классификационный признак.

По значениям откликов шести нейросетей формируется шестизначная переменная Y , определяющая переходы между состояниями агрегата: значение этой переменной 100000 определяет переход в состояние “0”. При этом первая нейросеть на выходе выдала единицу, а все остальные нейросети выдали ноль, так как не распознали вектор входных параметров, как относящийся к какому-либо состоянию. Значение 010000 соответствует переходу к состоянию ”1”, значение 001000 – к состоянию “2” и т.д.

При любом другом значении переменной Y осуществляется переход к состоянию “6”.

Кроме того, для каждого идентифицированного состояния строятся нейронные сети – «портреты» функционирования. Они применяются для

анализа экспериментальных данных в каждом состоянии агрегата и диагностирования дефектов. Выход сети может принимать значения «В норме», «Завышен» или «Занижен».

В результате строятся схема связей конечного автомата, моделирующего работу ТНА (рис. 2), и соответствующий граф переходов (рис. 3).

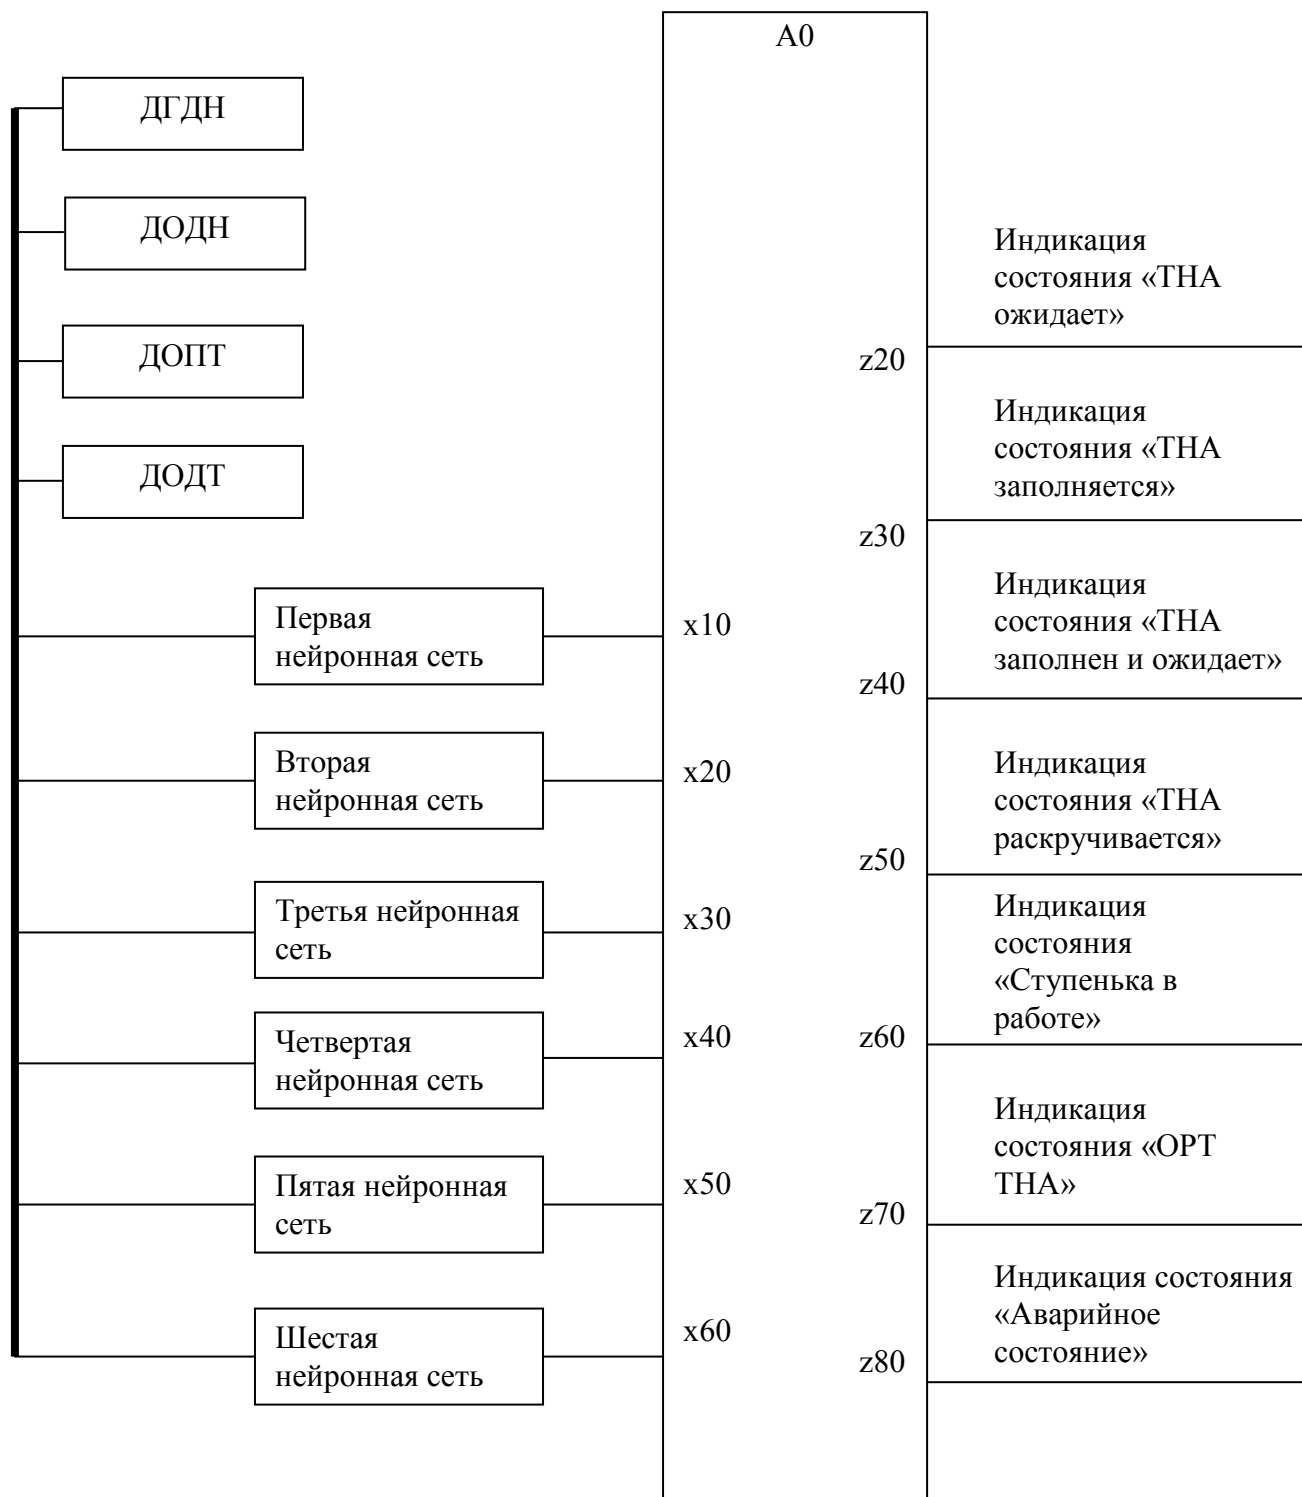


Рис.2. Схема связей конечного автомата A0, моделирующего ТНА

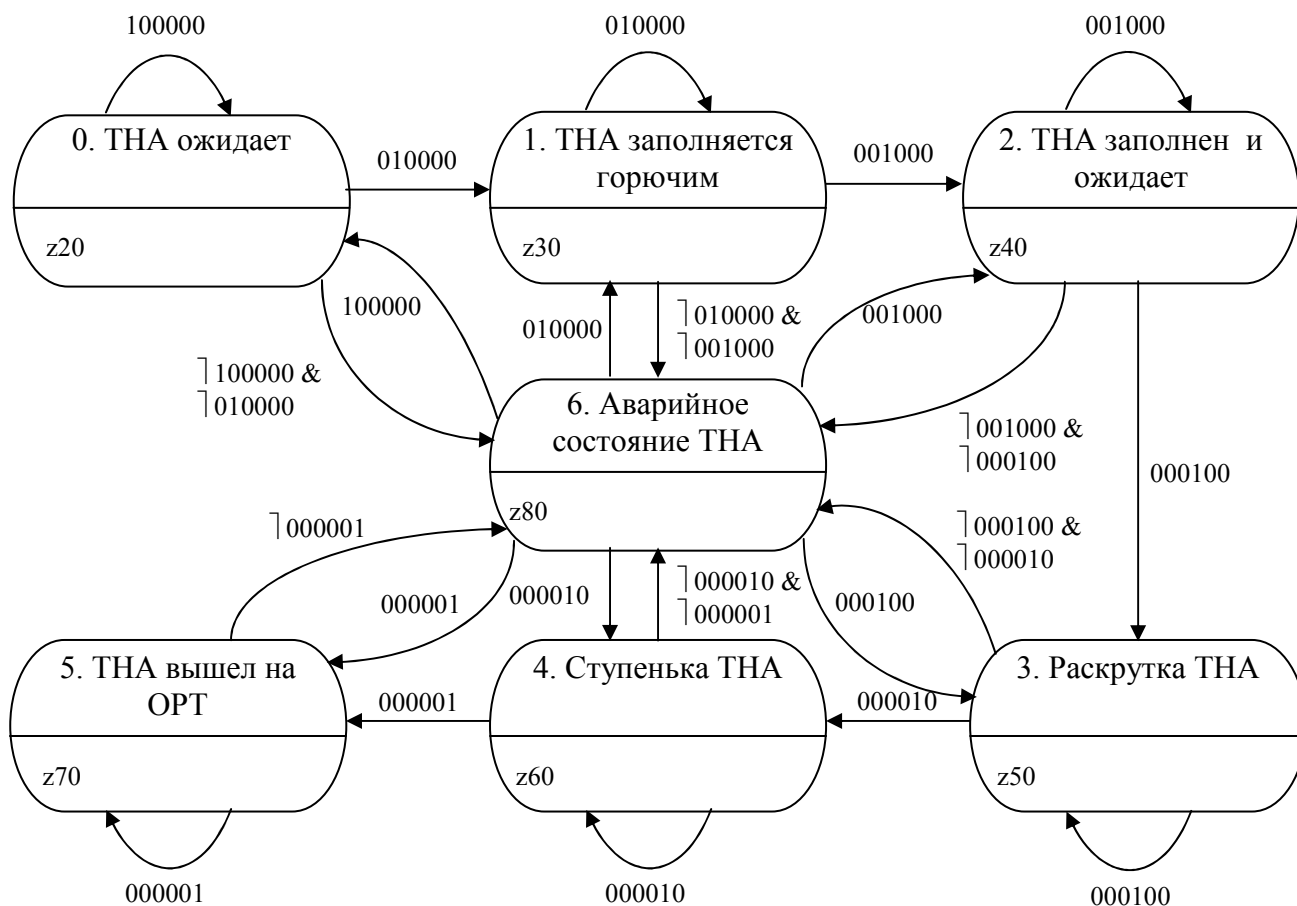


Рис. 3. Граф переходов автомата А0, моделирующего ТНА

Экспериментальные данные, получаемые при огневых испытаниях от датчиков с промежутком времени в 0,01 с, используются нейронными сетями в качестве входных воздействий. В каждый момент времени данные с датчиков подаются на соответствующие входы нейронных сетей. После срабатывания всех шести нейросетей формируется переменная Y , которая и определяет, перейдет ли автомат в новое состояние или нет. Если автомат на предыдущем шаге перешел в какое-либо состояние, а на текущем шаге выходы сетей остались прежними, то новый переход не происходит. Недопустимыми является комбинация выходов нейронных сетей, при которой присутствуют две и более единицы, а также все нули. В результате этого автомат переходит в аварийное состояние “6”.

2. Структура и составные части имитационной модели энергетической головки ЖРД

Задача обучения нейронной сети моделей функционирования формулируется так: необходимо настроить ИНС таким образом, чтобы сеть по известным ей значениям параметров функционирования системы на данном временном слое определяла (предсказывала) совокупность этих параметров на следующем временном слое. Далее при моделировании рабочего процесса в технической системе обученная ИНС уже не использует экспериментальных данных, которые применялись в виде обучающего и контрольного множеств при ее создании.

Для иллюстрации методики моделирования ниже рассматривается проблема разработки функциональной модели энергетической головки ЖРД на стационарных и переходных режимах работы ракетного двигателя. Несмотря на большое разнообразие существующих схем ЖРД, различный набор агрегатов и элементов системы регулирования, ограничимся рассмотрением довольно типичного для ЖРД турбонасосной подачи топлива замкнутой схемы набора агрегатов и элементов системы подачи компонентов топлива в камеру сгорания ЖРД, а именно: бустерные насосные агрегаты горючего (БТНАГ) и окислителя (БТНАО), турбонасосный агрегат (ТНА), газогенератор (ГГ) и регулятор расхода (РР). За основу моделирования принимается поагрегатный анализ функционирования ЖРД с последующей увязкой параметров агрегатов с учетом их взаимного влияния друг на друга.

Для обеспечения функционирования камеры ЖРД на заданном режиме необходимо, чтобы в ГГ, ТНА и других агрегатах поддерживалось определенное давление жидкости или газа. При этом необходимо учитывать и перепады давлений в насосах и на турбинах, и гидравлические сопротивления топливных магистралей двигателя, которые предварительно оцениваются во время пневмогидравлического расчета. Таким образом, из нескольких сотен параметров, измеряемых во время огневых испытаний ЖРД, ограничимся рассмотрением только давлений и чисел оборотов

агрегатов энергетической головки ЖРД и установлением функциональных связей внутри и между агрегатами по этим параметрам.

Рассмотрим структурную схему нейросетевой модели функционирования агрегатов ЖРД, обеспечивающих подачу компонентов топлива с заданным давлением в камеру сгорания (КС). На рис. 4 приведена графическая нотация разрабатываемой модели с указанием используемых параметров.

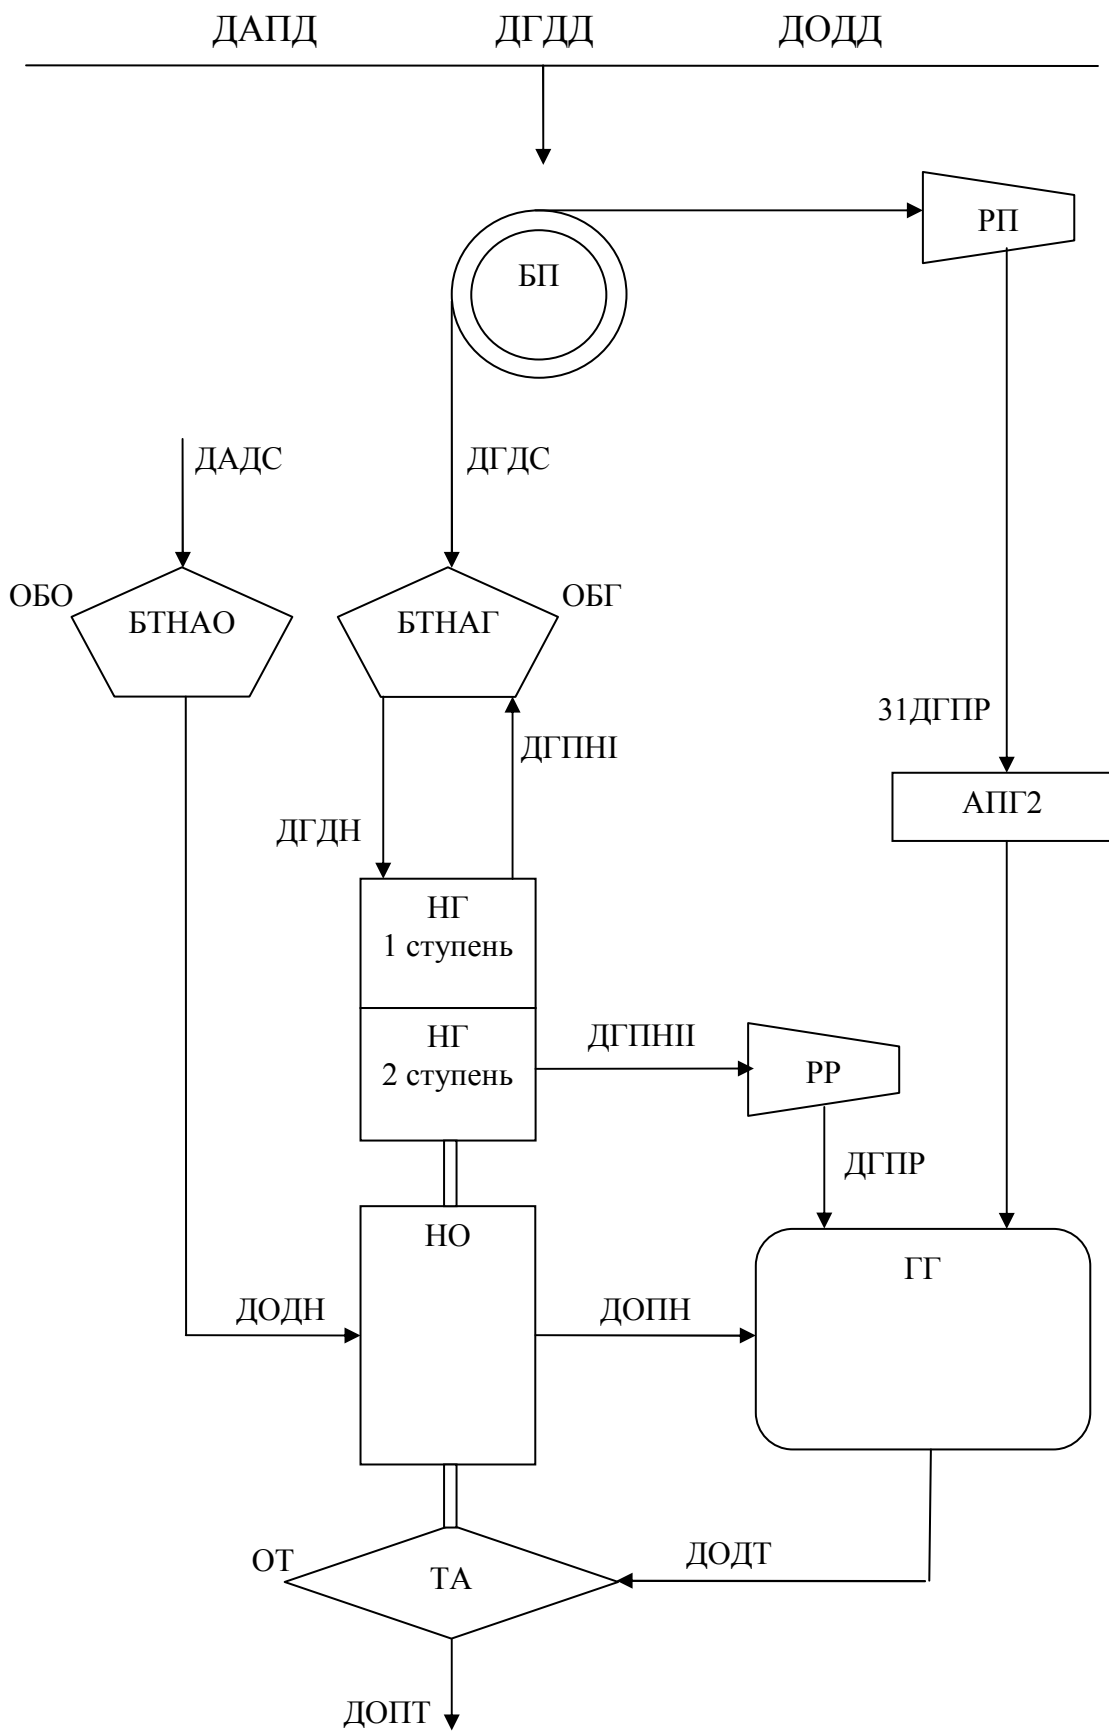


Рис. 4. Граф межагрегатных взаимодействий

В дальнейшем будем применять следующие условные обозначения (в соответствии с принятыми в *Воронежском КБ химавтоматики*):

ДАПД – давление азота после демпфера;

ДГДД – давление горючего до двигателя;

ДОДД – давление окислителя до двигателя;

ДГДС – давление горючего до соплового аппарата турбины БТНАГ;

ДГПН1 – давление горючего после первой ступени насоса горючего ТНА;

ОБГ – обороты вращения вала БТНАГ;

ДГДН – давление горючего до насоса;

ДАДС – давление азота до соплового аппарата турбины БТНАО;

ДОПН – давление окислителя после насоса окислителя ТНА;

ОБО – обороты вращения вала БТНАО;

ДОДН – давление окислителя до насоса окислителя ТНА;

ДОДТ – давление окислительного газа до турбины ТНА;

ДОПТ – давление окислительного газа после турбины ТНА;

ОТ – обороты вращения вала ТНА;

ДГПНII – давление горючего после 2 ступени насоса горючего ТНА;

ДГПР – давление горючего перед ГГ.

Для каждого моделируемого агрегата совокупность параметров окружения на i -ом временном слое составляет вектор входов, а выходом является один из параметров функционирования агрегата на $i+1$ -ом временном слое. Избыточность входных параметров, если она имеет место, обнаруживается в процессе обучения ИНС. Те переменные, которые имеют очень маленькие веса соединений с нейронами, являются незначимыми и их можно исключить из структуры сети. Для учета межагрегатных функциональных связей сформированы и обучены следующие нейросетевые параметрические модели:

$$1. ДГДС_{i+1} = f_{NET}(ДГДС_i; ДАПД_i);$$

$$2. ДГПН1_{i+1} = f_{NET}(ДГПН1_i; ДГДН_i; ОТ_i);$$

$$3. ОБГ_{i+1} = f_{NET}(ОБГ_i; ОБГ_{i-1}; ДГДД_i; ДГДС_i; ДГПН1_i);$$

4. $ДГДН_{i+1} = f_{NET}(ДГДН_i; ОБГ_i; ДГДС_i; ДГПН1_i; ДГДД_i);$
5. $ДАДС_{i+1} = f_{NET}(ДАДС_i; ДАПД_i);$
6. $ДОПН_{i+1} = f_{NET}(ДОПН_i; ОТ_i; ДОДН_i);$
7. $ОБО_{i+1} = f_{NET}(ОБО_i; ОБО_{i-1}; ДОДД_i; ДОПН_i; ДАДС_i);$
8. $ДОДН_{i+1} = f_{NET}(ДОДН_i; ОБО_i; ДОДД_i; ДОПН_i; ДАДС_i);$
9. $ДОДТ_{i+1} = f_{NET}(ДОДТ_i; ДГПР_i; ДОПН_i);$
10. $ДОПТ_{i+1} = f_{NET}(ДОПТ_i; ДОДТ_i; ОТ_i);$
11. $ОТ_{i+1} = f_{NET}(ОТ_i; ОТ_{i-1}; ДОДТ_i; ДОПТ_i; ДОДН_i; ДГДН_i);$
12. $ДГПН1_{i+1} = f_{NET}(ДГПН1_i; ОТ_i; ДГДН_i);$
13. $ДГПР_{i+1} = f_{NET}(ДГПР_i; ДАПД_i; ДГПН1_i).$

Функции оборотов включают параметры с запаздыванием на 0,01 с для учета инерционности измеряемого параметра, что потребовало введения дополнительной точки на предыдущем временном слое для более точного позиционирования нейросетей замеров оборотов.

На этапе определения функциональных зависимостей, подлежащих моделированию, основная проблема состояла в выражении связей между агрегатами через параметры, характеризующие работу этих узлов. Необходимо также было учесть только замеры, непосредственно характеризующие функционирование системы. Внесение в модель необязательного параметра добавило бы к нейросетевой последовательности дополнительный узел, что, исходя из требований высокой точности и скорости работы модели, неоправданно.

Необходимо отметить, что ни в одной из ИНС время не является параметром. Используя полученные зависимости можно, задаваясь допустимыми сочетаниями параметров функционирования в начальный момент времени t_0 , рассчитать состояние системы в любой последующий момент времени, если только сочетание входных параметров в момент t_0 будет известным ИНС, т.е. это может быть один из входных векторов, которые использовались в обучающем множестве при настройке сети.

Обеспечение проверки работы узла на испытательном стенде в большинстве случаев сопряжено со значительными материальными затратами, несравнимыми с компьютерным моделированием. Интервал, на который нейросеть способна выдать прогноз, ограничен лишь мощностью ЭВМ, а также требованиями точности. Естественно, что с включением в набор статистики вновь проведенных испытаний, возрастет и точность «предсказания». Исходными данными, которые необходимы для инициирования процесса моделирования, являются значения параметров в точке начала отсчета (например, во время подачи команды «Зажигание»).

Для достижения как можно более точных результатов моделирования при достаточно небольшом для исследования большинства стационарных и переходных процессов шаге по времени ($\Delta t=0,01$ с), временной интервал, на котором осуществляется моделирование также дискретизируется на характерные состояния для применения автоматного подхода. Как уже отмечалось, нейросетевые модели агрегатов не привязаны ко времени. Они способны по текущему своему микросостоянию при определенной величине внешнего воздействия рассчитать свое микросостояние в следующий момент времени, т.е. моменты времени рассматриваются как номера микросостояний системы. Микросостояния объединяются в состояния, такие как запуск, основной режим тяги (ОРТ), дросселирование или форсирование, конечная ступень тяги (КСТ), останов и т.д. Если при заданных реальных значениях входов нейромодулей функционирования агрегатов при очередном испытании ошибка предсказания сетью выхода будет возрастать, то это будет свидетельствовать об отклонении работы агрегата от «нормы».

Для анализа функционирования энергетической головки ЖРД в нашем случае принято всего 13 параметров, для моделирования поведения которых и необходимо разработать нейросетевые структуры. Первоначально разрабатывались отдельные сети для каждого из параметров функционирования. Например, для нейросетевой функции параметра ДОДН структура модели представлена на рисунке 5:




Рис. 5. Сеть для параметра $ДОДН$

Настройка сети осуществляется согласно следующей методике. Значения входных параметров $ДОДН$, $ОБО$, $ДОДД$, $ДОПН$ и $ДАДС$ берутся из протокола испытаний двигателя и подаются на вход нейросети. Выходом ИНС является опережающее на шаг по времени значение $ДОДН$. Обучающая выборка формируется исходя из возможности получения высокой точности обучения либо для всего временного интервала переходного процесса, либо для его участка, который возможно идентифицировать при применении автоматного подхода.

Обилие экспериментальных данных позволяет при обучении разбивать статистику наблюдений и на обучающее, и на контрольное, и на тестовое множества. Кроме того, как и рекомендуется в теории нейронных сетей, отдельные наблюдения в массивах данных случайным образом перемешиваются и далее запускается одна из оптимизационных стратегий обучения, например, Левенберга-Маркардта. При обучении предъявляются повышенные требования к точности приближения и обобщения сети, т.к. результаты работы каждой отдельной ИНС будут использоваться с учетом межсетевых взаимодействий другими сетями, и погрешности функционирования одной могут привести к распространению погрешности на другие сети, даже если они сами по себе работают удовлетворительно. Несмотря на то, что нейронная сеть может приблизить любую функцию с

любой точностью, проблема получения этой точности не имеет тривиального решения и весьма сложна так же, как и сложен вычислительный параллельный механизм получения нейросетевого численного решения.

Использование нейросетевой вычислительной структуры позволяет получить очень высокую точность соответствия расчетных и экспериментальных результатов. Для примера на рисунке 6 изображены совмещенные графики изменения оборотов вала ТНА на запуске.




Рис. 6. Сравнительный анализ работы нейросети и экспериментальных данных в первую секунду запуска

Разработанная нейронная сеть функционирования ТНА, например, по параметру *ОТ*, позволяет автоматизировать анализ огневых испытаний агрегата для повышения качества процессов диагностики и контроля

технического состояния изделия. Нейросетевой портрет агрегата функционирует согласно следующему алгоритму.

На вход нейронной сети подаются величины входных параметров, регистрируемые датчиками во время огневых испытаний. Выход сети рассчитывается по формуле

$$n_{NET}(\mathbf{x}) = \sum_{j=1}^N w_j \sigma_j(\mathbf{x}) - b_0, \quad (1)$$

где \mathbf{x} – вектор входов, соответствующий определенному моменту времени (для оборотов турбины шестимерный (OT ; OT_{-1} ; $ДОДТ$; $ДОПТ$; $ДОДН$; $ДГДН$));

$\sigma(\mathbf{x})$ – функция активации;

w_j – веса соединений выходного нейрона с j -ым нейроном скрытого слоя;

b_0 – порог выходного нейрона;

j – номер нейрона в скрытом слое.

В качестве функции активации используется логистическая сигмоида (функция Ферми):

$$\sigma_j(\mathbf{x}) = \frac{1}{1 + e^{-t_j(\mathbf{x}, b_j)}}.$$

Здесь b_j — порог j -го нейрона скрытого слоя, а функция $t_j(\mathbf{x}, b_j)$ имеет вид:

$$t_j(\mathbf{x}, b_j) = \sum_{i=1}^5 v_{ij} \cdot x_i - b_j,$$

где v_{ij} — вес соединения j -го нейрона скрытого слоя с i -ым входом.

При величине измеренного числа оборотов n^{i+1} в момент времени t^{i+1} , удовлетворяющему неравенству

$$n_{NET}^{i+1} - \Delta_{\min} < n^{i+1} < n_{NET}^{i+1} + \Delta_{\max},$$

где $\Delta_{\min}, \Delta_{\max}$ - максимальные допуски отклонения параметра числа оборотов ниже и выше эталонного, определяемого согласно нейросетевой модели функционирования, выдается сообщение о «нормальной работе»

ТНА, в противном случае проходит сигнал о том, что «обороты завышены» или «обороты занижены» [8].

3. Программная реализация конечного автомата ТНА

При тестировании автомата осуществлялась проверка его работоспособности для различных комбинаций входных и выходных переменных. На рис. 7 представлен график, показывающий работу автомата в идеальном случае, когда параметры функционирования не содержат ошибочных данных.




Рис. 7. Изменение состояний автомата ТНА во времени

Из анализа графика следует, что автомат последовательно переключается из одного состояния в другое в соответствии с его логикой. При этом аварийное состояние не использовано.

Исходя из данной технологии, была разработана компьютерная программа, производящая автоматический анализ работы ТНА. Одно из достоинств SWITCH-технологии – автоматическое создание протокола работы автомата [5]. Это позволяет проводить автоматизированный анализ работоспособности агрегата и диагностировать дефекты функционирования. Рис. 7 представляет работу программы, моделирующей функционирование турбонасосного агрегата в случае, когда входные параметры

диагностируются нейросетями, как относящиеся к одному из неаварийных состояний. При этом выходные параметры находятся в соответствии с созданными «портретами» функционирования. В реальных условиях возможны отклонения параметров от нормы. Эти отклонения могут привести к нештатным ситуациям в работе всей двигательной установки.

Поэтому необходимо протестировать полученный конечный автомат на работу в условиях отклонений входных и выходных переменных. При внесении в массивы экспериментальных данных искусственных ошибочных данных по произвольному параметру функционирования автомат ТНА диагностирует дефекты и отражает их в протоколе. Шесть нейронных сетей, влияющих на формирование автоматной переменной перехода между состояниями Y , при появлении нераспознанных сочетаний входных воздействий переводят автомат ТНА в состояние 6 («аварийное» состояние). Кроме того, если выходные параметры агрегата *ДОПН*, *ДГПН1* и *ДГПН2*, *ОТ* не соответствуют нейросетевым моделям функционирования, то в этом случае также диагностируется «аварийное» состояние.

График изменения состояний в этом случае имеет вид, приведенный на рис. 8.

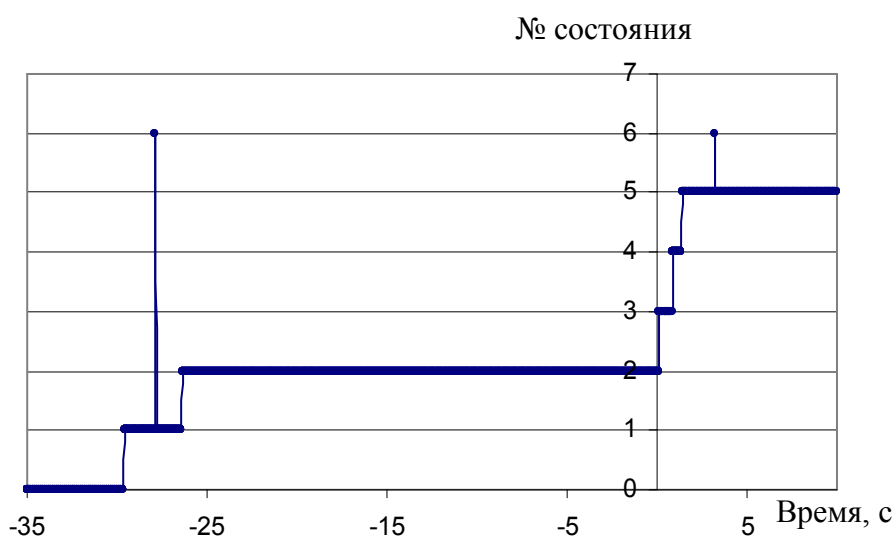


Рис. 8. Работа автомата ТНА при отклонении параметров от нормы

Резкие скачки на этом графике показывают переходы автомата ТНА в шестое состояние, в котором он находится пока автоматная переменная Y не примет допустимый вид.

ВЫВОДЫ

Разрабатываемые функциональные модели, основанные на конечных автоматах с нейросетевой внутренней структурой, могут быть использованы для автоматизированного анализа проблем функционирования промышленного оборудования и энергетических устройств, диагностирования дефектов и деградации характеристик при текущем контроле и диагностировании работоспособности технических устройств.

Литература

1. *Тарасик В.П.* Математическое моделирование технических систем. Минск: ДизайнПРО, 1997. – 640 с.
2. *Кретинин А.В.* Разработка нейросетевых портретов функционирования агрегатов ЖРД для автоматизированного анализа результатов испытаний // Автоматизация и современные технологии. 2004, № 9, с. 24–30
3. *Статников Р.Б., Матусов И.Б.* Многокритериальное проектирование машин. М.: Знание, 1989. – 317 с.
4. Нейронные сети. STATISTICA NEURAL NETWORKS. М.: Горячая линия – Телеком. 2000. – 182 с.
5. *Шальто А.А.* SWITCH-технология. Алгоритмизация и программирование задач логического управления. СПб.: Наука. 1998. – 628 с.
<http://is.ifmo.ru/books/switch/1>
6. *Дейкстра Э.* Взаимодействие последовательных процессов // Языки программирования. М.: Мир. 1972, с. 9 – 86.
7. *Брукс Ф.* Мифический человек – месяц, или как создаются программные системы. СПб.: Символ, 2000. – 304 с.

8. *Герр Р.* Новый поворот // PC Magazine/RE. 1998. № 10, с. 88 – 90.

<http://is.ifmo.ru/recensions/gerr/>

9. *Шалыто А.А.* Логическое управление. Методы аппаратной и программной реализации алгоритмов. СПб.: Наука, 2000. – 773 с.

http://is.ifmo.ru/books/log_upr/1