

Подход к разработке систем управления малыми космическими аппаратами в нейросетевом базисе

© В.Н. Коновалов, М.О. Корлякова

КФ МГТУ им. Н.Э. Баумана, Калуга, 248000, Россия

Представлен обзор основных направлений аппаратной реализации нейронных сетей и оценены их возможности для использования на борту малых космических аппаратов. Рассмотрены основные требования к бортовым системам управления и подходы к их нейросетевой реализации. Перечислены ограничения и требования к ресурсам, выдвигаемые для бортовых систем малых космических аппаратов. Показано, что возможно реализовать эффективное решение задачи в сетях небольшой сложности. Проведено моделирование отдельных узлов нейросетевой системы управления в условиях ограниченных ресурсов. Представлена нейросетевая модель аппроксимации табличной модели атмосферы. Сформированы варианты решения задачи в вещественных и дискретных форматах синаптических весов. Проведен анализ ошибок аппроксимации в сетях разной архитектуры. Показано, что даже для вариантов с дискретизированной формой входов и коротким форматом представления синаптических весов качество решения задачи является достаточным.

Ключевые слова: нейронные сети, малые космические аппараты, системы управления.

Системы управления летательных аппаратов решают широкий спектр задач разного типа. При этом значительно отличаются объекты управления и требования к качеству. Однако все системы этого класса должны быть надежны, устойчивы к внешним искажениям, работать в большом диапазоне входных характеристик и по возможности обеспечивать автономное управление летательным аппаратом.

В настоящее время значительно возрос интерес к интеллектуальным системам управления. Обусловлено это развитием аппаратных средств и появлением новых методов формирования таких систем. Основным преимуществом интеллектуальных систем управления можно считать следующие их особенности [1]:

система формируется в результате обучения, т. е. предъявления примеров и поощрения/наказания изменяемых параметров;

разработаны различные типы обучаемых систем для решения широкого круга задач, активно совершенствуется аппаратная база для реализации интеллектуальных систем управления;

системы адаптивны, что позволяет работать в широком диапазоне условий и целей.

Можно привести примеры успешного решения задач управления в рамках нейросетевого подхода, который в наибольшей степени ориентирован на работу в условиях автономного обучения и управ-

ления, один из них — модель нейросетевого управления для решения задач наблюдения на борту космического аппарата [2]. В работе [3] предложено использовать нейросетевую модификацию инверсно-адаптивной модели стабилизации угла тангажа. Отмечено, что система справляется с поставленной задачей стабилизации высоты и скорости, но в режиме моделирования не обеспечивает достаточного быстродействия; его можно достичь решением задачи в реально параллельном аппаратном базисе.

Нейросетевые модели принятия решений ориентированы, как правило, на решение задач низкого уровня управления. Однако в настоящий момент существует развитый класс нечетких нейронных сетей, которые аппроксимируют процедуры нечеткого дедуктивного вывода, например известная архитектура ANFIS [4], которая обеспечивает интеграцию нечетких, нейросетевых моделей и технологий самоорганизации. Преимуществом такой формы нейросетевого подхода является способность к самоорганизации и адаптации в процессе жизни системы.

Недостаток нейронных сетей состоит в значительной избыточности модели, необходимой для качественного решения задачи. Однако избыточность заключена в числе нейронов и их размере, а основная вычислительная сложность решения задачи переносится на этап обучения. Это позволяет значительно повысить скорость обработки на этапе решения задач. Кроме того, необходимо отметить, что надежность систем нейросетевого типа обеспечена их способностью удовлетворительно решать задачи даже при отказе существенной части системы. Из опыта известно, что отключение 15 % нейросетевой системы не приводит к существенному снижению качества решения задачи [4]. По итогам моделирования нейронной сети прямого распространения (многослойного перцептрона) показано, что отключение слабых связей не приводит к значительному снижению качества классификации [4, 5].

Из сказанного выше следует, что интеллектуальные технологии нашли довольно широкое применение в современных системах управления летательных аппаратов. Они позволяют решать задачи управления на борту с качеством, сравнимым с традиционными подходами, и обеспечивают высокую надежность и быстродействие вычислительной системы. Однако, поскольку в рассмотренных примерах использованы нейронные сети с настраиваемыми параметрами вещественного типа, существуют определенные трудности при решении задачи их аппаратной реализации. Параллельная обработка информации в нейронных сетях может быть сделана на разном уровне сложности аппаратного базиса. Например, использование параллельных вычислителей в форме связанных между собой микроконтроллеров-нейронов, позволяет создать нейронную сеть из слож-

ных нейронов с непрерывными входами. Такая сеть для бортовой системы управления не всегда подходит, поскольку размер ее аппаратной реализации может оказаться достаточно значительным. Однако использование специализированного аппаратного базиса (например, нейропроцессоров) создает более компактную модель, но не обладает достоинствами универсальной вычислительной системы при решении задач, отличных от реализации нейронной сети. Таким образом, необходимо рассматривать не только возможность решения в нейросетевом базисе задач управления на борту летательного аппарата, но и пути реализации такой формы управления.

Рассмотрим в качестве примера систему управления малым космическим аппаратом (МКА). В структуре МКА можно выделить полезную нагрузку и служебные подсистемы, обеспечивающие процесс целевого функционирования [6]. Интерес представляет одновременное в однородном базисе решение всех поставленных задач. Современные МКА активно внедряют на практике. Как правило, они построены на цифровой элементной базе [7]. Удачные примеры реализации МКА показывают единство подходов при решении задач управления и взаимодействия с наземными информационными системами.

Эксплуатация МКА протекает в удаленных условиях, на орбите, в связи с чем актуальны средства моделирования процессов функционирования спутника для оценки орбитальной обстановки и поддержки принятия решений по управлению микроспутником в режиме реального времени [8]. Эти средства должны обеспечить прогнозирование состояния всех систем МКА при условии, что сложность решаемых задач может существенно отличаться, и необходим аппарат, одинаково успешно работающий для простых и сложных объектов.

Процесс обучения может быть достаточно длительным, но процесс принятия решения в нейросети определяется только количеством слоев (и нейронов для случая последовательной обработки). В нейросетевом базисе можно эффективно решить задачу аппроксимации функции поиска управляющего воздействия за время, меньшее или сравнимое с традиционным подходом. Кроме того, следует отметить, что однородные методы решения разнородных задач управления позволят существенно упростить аппаратную реализацию системы управления.

Таким образом, нейронные и нейро-нечеткие системы управления удовлетворяют требованиям, предъявляемым к бортовым системам МКА, и формируют модели управления в общем технологическом ключе как с точки зрения аппаратного решения, так и в смысле единства способов получения решения.

Аппаратная реализация разрабатываемых нейронных сетей должна обеспечивать небольшую массу, высокую надежность и иметь достаточно универсальный характер для реализации разнородных задач.

Рассмотрим возможные варианты реализации бортовых систем управления МКА в нейросетевом базисе.

Элементарной базой нейровычислительных систем являются заказные кристаллы ASIC, встраиваемые микроконтроллеры mC, процессоры общего назначения GPP, программируемые логические интегральные схемы (ПЛИС), транспьютеры, цифровые сигнальные процессоры DSP (Digital Signal Processor) и нейрочипы. Применение любых из них позволяет сегодня реализовать нейровычислители, функционирующие в реальном масштабе времени, однако наибольшее использование при реализации нейровычислителей нашли ПЛИС, DSP и, конечно, нейрочипы.

Обладая мощной вычислительной структурой, DSP позволяют реализовать различные алгоритмы обработки информационных потоков. Сравнительно невысокая цена, а также развитые средства разработки программного обеспечения позволяют легко применять их при построении вычислительных систем с массовым параллелизмом.

Программируемая логика способна работать на более высоких частотах, но поскольку управление реализовано аппаратно, изменение алгоритмов работы требует перепрограммирования ПЛИС. Низкая тактовая частота DSP пока ограничивает максимальную частоту обрабатываемого аналогового сигнала до 10...20 МГц, однако программное управление позволяет достаточно легко изменять не только режимы обработки, но и функции, выполняемые DSP. Помимо обработки и фильтрации данных, DSP могут осуществлять маршрутизацию цифровых потоков, выработку управляющих сигналов, формирование сигналов системных шин ISA, PCI и др.

Особенностью использования DSP и ПЛИС в качестве элементной базы нейровычислителей является то, что ориентация в выполнении нейросетевых операций обуславливает, с одной стороны, повышение скоростей обмена между памятью и параллельными арифметическими устройствами, а с другой — уменьшение времени весового суммирования (умножения и накопления) в результате применения фиксированного набора команд типа регистр-регистр [9–11].

Среди DSP с фиксированной точкой весьма достойно выглядит первый российский сигнальный процессор (нейросигнальный процессор) Neuro Matrix фирмы «Модуль» [11]. При тактовой частоте 50 МГц он практически не уступает по производительности изделиям мировых лидеров, а по некоторым параметрам даже превосходит их.

При создании нейровычислительных систем на базе сигнальных процессоров необходимо помнить, что DSP обладают высокой степенью специализации. В них широко используются методы сокращения длительности командного цикла, характерные для универсальных RISC-процессоров, такие как конвейеризация на уровне отдельных микроинструкций и инструкций, размещение операндов большинства

команд в регистрах, использование теневого регистра для сохранения состояния вычислений при переключении контекста, разделение шин команд и данных (Гарвардская архитектура). В то же время для сигнальных процессоров характерным является наличие аппаратного умножителя, позволяющего выполнять умножение как минимум двух чисел за один командный такт. Еще одной особенностью сигнальных процессоров является включение в систему команд таких операций, как умножение с накоплением MAC ($C = AB + C$ с указанным в команде числом выполнений в цикле и с правилом изменения индексов используемых элементов массивов A и B , т. е. уже реализованы прообразы базовых нейроопераций — взвешенное суммирование с накоплением), инверсия бит адреса, разнообразие битовые операции [11].

Отдельно следует рассмотреть возможность создания параллельных вычислителей (в том числе и нейро-) на базе ПЛИС. В настоящее время множество фирм в мире занимается разработкой и выпуском различных типов ПЛИС, однако лидерство делят фирмы Xilinx и ALTERA. Выделить продукцию какой-либо одной из них невозможно, поскольку по техническим характеристикам они почти не различаются.

В настоящее время фирма ALTERA выпускает семь семейств ПЛИС, а компания Xilinx выпускает семь серий ПЛИС двух типов: FPGA (Field Programmable Gate Array) и CPLD (Complex Programmable Logic Device). Покажем на примере ПЛИС Xilinx их основные особенности [10]:

- значительный объем ресурсов — до 4 млн системных вентилях на кристалл;

- высокая производительность с системными частотами до 300 МГц;

- технологические нормы — до 0,18 мкм на шести слоях металла;

- высокая гибкость архитектуры с множеством системных особенностей, таких как внутреннее распределенное и блочное ОЗУ, логика ускоренного переноса, внутренние буферные элементы с третьим состоянием и т. д.;

- низкое энергопотребление;

- короткий цикл проектирования и быстрое время компиляции;

- развитые и недорогие средства проектирования;

- возможность перевода проектов в заказные схемы.

Реализация нейровычислителей на основе ПЛИС требует участия эксперта на топологической стадии проектирования. Это обусловлено тем, что автоматизированный режим разводки пока не позволяет достигать 60...100 % использования ресурсов кристалла по разводке, что является принципиальным для сильносвязанных схем, к которым относятся и нейровычислители. Построение нейровычислителей на их основе хотя и дает высокую гибкость создаваемых структур, но пока еще проигрывает по производительности по сравнению с другими решениями.

Таким образом, реализация нейровычислительных систем и специализированных вычислителей с массовым параллелизмом на базе DSP и ПЛИС эффективна при решении задач цифровой обработки сигналов, обработки видео- и аудиоданных и построения технических систем управления. При реализации нейровычислителей сегодня, как правило, приоритетно используется гибридная структура, в которой блок матричных вычислений реализуется на базе кластерного соединения DSP-процессоров, а логика управления — на основе ПЛИС.

Основной элементной базой перспективных нейровычислителей являются нейрочипы. Их производят во многих странах мира, причем большинство из них на сегодняшний день ориентированы на закрытое использование (были созданы для конкретных специализированных управляющих систем). В настоящий момент можно выделить две базовые линии развития вычислительных систем с массовым параллелизмом (ВСП) [10]: с модифицированными последовательными алгоритмами, характерными для однопроцессорных фоннеймановских алгоритмов, и на базе принципиально новых сверхпараллельных нейросетевых алгоритмов решения различных задач (нейроматематики). В России разработан нейросигнальный процессор Neuro Matrix NM6403 [11]. Основой Neuro Matrix NM6403 является процессорное ядро NeuroMatrixCore, которое представляет собой синтезобильную модель высокопроизводительного DSP-процессора с архитектурой VLIM/SIMD (язык Verilog). Ядро состоит из двух базовых блоков: 32-битного RISC-процессора и 64-битного векторного процессора, обеспечивающего выполнение векторных операций над данными переменной разрядности [12]. Базовыми для нейропроцессора являются вычисления вида

$$Z_i = f(Y_i) = f\left(U_i + \sum(X_j, W_{ij})\right), \quad i = 1, \dots, M; \quad j = 1, \dots, N,$$

где Z_i — выходной сигнал i -го нейрона; f — функция активации; Y_i — сумма взвешенных входов i -го нейрона; U_i — смещение i -го нейрона; X_j — j -й входной сигнал слоя; W_{ij} — весовой коэффициент j -го входа 1-го нейрона; N — количество входных сигналов слоя; M — количество нейронов в слое. Операнды Z_i , X_j , U_i и W_{ij} представлены в дополнительном параллельном коде и могут иметь произвольную разрядность.

Основными особенностями рассматриваемого нейропроцессора являются:

возможность работы с входными сигналами (синапсами) и весами переменной разрядности (от 1 до 64 бит), задаваемыми программно, что обеспечивает уникальную способность нейропроцессора увеличивать производительность с уменьшением разрядности операндов;

быстрая подкачка новых весов на фоне вычислений;

24 операции умножения с накоплением за один такт при длине операндов 8 бит;

реализация функции активации в виде пороговой или функции ограничения;

возможность работать с данными переменной разрядности по различным алгоритмам, реализуемым с помощью хранящихся во внешнем ОЗУ программ.

Благодаря своей универсальности нейропроцессор может применяться как базовый элемент для плат нейроускорителей IBM PC, для создания нейрокомпьютерных параллельных вычислительных систем большой производительности, для аппаратной поддержки операций над матрицами большой размерности, а также в задачах цифровой обработки сигналов. Указанный нейропроцессор используется в нейроускорителях фирмы «Модуль» (Россия) [11].

Таким образом, нейропроцессоры имеют большие перспективы применения в нейросетевых системах управления в силу изначальной ориентации на нейроподобную структуру организации вычислений. Однако, как и другие рассмотренные варианты организации нейросетевых систем управления, они имеют ограничения при представлении входных и выходных данных, а также ограниченное разрешение для представления синаптических весов. Поэтому моделирование систем управления в нейросетевом базисе должно подразумевать разумное ограничение представления входов и настраиваемых параметров сетей.

Проведем моделирование отдельных элементов бортовых систем управления для решения вопроса о способе аппаратной реализации управляющей нейронной сети. В качестве простой линейной системы рассмотрим модель атмосферы, которая задает зависимость от высоты h (от 0 до 32 000 м), температуры T (К), давления p (Па), скорости звука a (м/с) и плотности ρ (кг/м³) [13]. Данные для моделирования были сформированы через блок COESA Atmosphere Model block пакета Aerospace Blockset Simulink MatLab. Общая выборка данных содержала 1000 примеров по каждой выходной характеристике.

В данном случае модель не требует формирования динамической нейронной структуры, поскольку известно, что все выходные характеристики непосредственно связаны с текущей высотой и не определяются предшествующими измерениями. В этом случае модель атмосферы можно аппроксимировать сетью вида многослойный перцептрон. Поскольку характеристика зависимости выходных величин $T(h)$, $a(h)$, $P(h)$, $\rho(h)$ модели близка к линейной в рассматриваемом диапазоне значений h , то имеет смысл использовать двухслойную сеть прямого распространения [5], структура которой приведена на рис. 1.




Рис. 1. Схема двухслойной гомогенной нейронной сети для моделирования атмосферы

Варьируемые параметры модели: число нейронов n , тип нейронов $f(X)$, число слоев.

В процессе обучения весовые коэффициенты нейронной сети изменяются до тех пор, пока не будет обеспечена наименьшая ошибка обучения и обобщения (исследуемая как среднее абсолютное отклонение). Моделирование нейронной сети выполнено в пакете Neural Network ToolBox.

Для каждой конфигурации проведены 10 перезапусков сети со случайного начального состояния с усреднением ошибок по всем реализациям. Таким образом, проводится сравнение средних возможностей обучения нейросетей различных архитектур.

Входные и выходные переменные подвергаются предварительной обработке в форме простейшей нормализации на основании исследования примеров обучающей выборки, что позволяет повысить скорость и качество обучения.

Все сети обучены на основе алгоритма обратного распространения ошибки с изменением весовых коэффициентов по методу сопряженного градиента [4]. Результаты обучения приведены в табл. 1.

Таблица 1

Относительные ошибки обучения и тестирования для двухслойной гомогенной нейронной сети (логистический нейрон) с алгоритмом обучения по методу сопряженного градиента

n	Обучение				Тестирование			
	Δp	$\Delta \rho$	Δa	ΔT	Δp	$\Delta \rho$	Δa	ΔT
1	0,503	0,4148	0,3474	0,259	0,492	0,3937	0,3347	0,2465
3	0,312	0,2678	0,3249	0,408	0,301	0,2602	0,3130	0,3884
4	0,251	0,2718	0,2671	0,286	0,237	0,2629	0,2601	0,2815
5	0,231	0,2576	0,2358	0,291	0,222	0,2517	0,2232	0,2874
6	0,302	0,3479	0,4860	0,311	0,290	0,3330	0,4673	0,2983

Примечание. Здесь и далее во всех таблицах p — в Па; ρ — в кг/м^2 ; a — в м/с; T — в К.

Сеть с наилучшим параметром $n = 4$ определена по минимальной ошибке тестирования как двухслойная сеть логистических нейронов.

Вариант с $n = 0$ (без скрытого слоя) гомогенной сети логистических нейронов дает ошибки, приведенные в табл. 2.

Таблица 2

Относительные ошибки обучения и тестирования для сетей без скрытого слоя ($n = 0$)

Сеть	Обучение				Тестирование			
	Δp	Δp	Δa	ΔT	Δp	Δp	Δa	ΔT
Гомогенная	0,340	0,2695	0,3653	0,483	0,333	0,2637	0,3626	0,4778
Гетерогенная	0,179	0,0370	0,0135	0,109	0,180	0,0372	0,0136	0,1099

Следующая моделируемая структура соответствует варианту гетерогенной сети, где два нейрона выходного слоя логистические и два нейрона линейные. Схема такой конфигурации сети может быть описана следующим образом:

число нейронов скрытого слоя — $n = 0$ (сеть имеет только один слой);

тип нейронов $f(X)_1, f(X)_2$ — логистические; $f(X)_3, f(X)_4$ — линейные. Ошибки обработки тестов и обучения для этого случая приведены в табл. 2.

Таким образом, очевидно, что с позиции критерия минимальной сложности сети наиболее эффективной является модель, схема которой приведена на рис. 2.

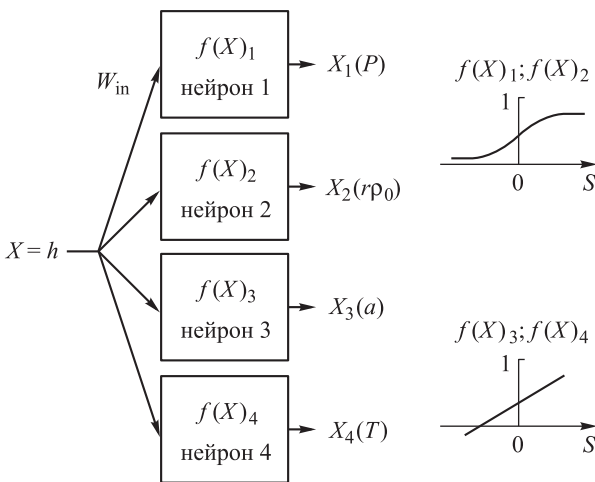


Рис. 2. Схема однослойной гетерогенной нейронной сети для моделирования атмосферы

Моделирование линейных и слабо нелинейных объектов и подсистем гетерогенными однослойными сетями с подбором нейронов соответствующего аппроксимируемой зависимости типа позволяет минимизировать размер системы управления и перейти к однородным формам моделирования различных процессов.

Поскольку нейронные сети типа многослойного перцептрона являются универсальным аппроксиматором [4], можно построить модели более сложных подсистем летательных аппаратов. Рассмотрим в качестве примера моделирование системы наведения и определения ускорения, которое должна развивать противоракета при решении задачи поражения движущейся мишени. В качестве модели используем один из демонстрационных примеров *Aerospace Toolbox MatLab* [14].

Модельные данные сформированы для управления противоракетой относительно подмножеств случайных значений начальной высоты и начальной скорости мишени. Общий объем данных составляет 2 500 примеров, из которых 2 300 использованы для обучения. Ошибки обучения и тестирования формируемой нейросетевой модели приведены в табл. 3.

Таблица 3

Относительные ошибки моделирования параметров управления противоракетой в нейросетевой системе

n	Обучение					Тестирование				
	X_1	X_2	X_3	X_4	X_5	X_1	X_2	X_3	X_4	X_5
4	0,070	0,013	0,016	0,084	0,047	0,070	0,013	0,015	0,084	0,046
6	0,056	0,015	0,016	0,065	0,036	0,057	0,016	0,014	0,067	0,036
8	0,044	0,014	0,016	0,064	0,028	0,043	0,014	0,015	0,065	0,028
10	0,038	0,013	0,018	0,062	0,027	0,038	0,014	0,017	0,063	0,027

Примечание. Здесь X_1 — угловая скорость противоракеты; X_2 — ускорение противоракеты; X_3 — угол между объектом и целью; X_4 — скорость противоракеты; X_5 — расстояние до цели. Все моделируемые величины приведены к диапазону $[-1, 1]$.

Поскольку реализация непрерывных моделей входных сигналов в цифровой элементной базе может быть затруднена, рассмотрим моделирование линейной системы (атмосферы) с дискретной моделью кодирования входного сигнала. Будем представлять каждый из входов 8-разрядным числом со знаком. Тогда входной сигнал будет представлен шиной из 8 бинарных входов, а выходной — шиной из 32 бинарных выходов.

По итогам моделирования (табл. 4), получена следующая схема сети: число нейронов $n = 6$; диапазон входов $X_i = \{-1, 1\}$; тип выход-

ного нейрона $f(X)_1, \dots, f(X)_6$ — с отсеченной линейной функцией активации, настраиваемые параметры сети определены из интервала $[-1, 1]$; значения выходного параметра сети $f(X)_i$ определены в интервале $[0, 1]$.

Таблица 4

**Относительные ошибки моделирования атмосферы
в системе с дискретными входами**

n	Обучение				Тестирование			
	Δp	Δr	Δa	ΔT	Δp	Δr	Δa	ΔT
1	0,287	0,3336	0,3379	0,310	0,306	0,3376	0,3398	0,3216
3	0,204	0,1961	0,1804	0,199	0,216	0,2051	0,1860	0,2062
5	0,084	0,0996	0,0562	0,116	0,088	0,1066	0,0572	0,1148
6	0,108	0,0644	0,0625	0,048	0,117	0,0697	0,0667	0,0532

Реализация нелинейной модели с дискретизированными входами позволила получить сеть, которая содержит 32 бинарных входа, 40 бинарных выходов и нейроны скрытого слоя по типу отсеченной линии. Результаты моделирования приведены в табл. 5.

Таблица 5

**Относительные ошибки обучения и тестирования
для бинарной модели входов и выходов нелинейного объекта**

n	Обучение					Тестирование				
	X_1	X_2	X_3	X_4	X_5	X_1	X_2	X_3	X_4	X_5
4	0,3071	0,2333	0,0460	0,1289	0,2392	0,3136	0,2349	0,0498	0,1390	0,2412
8	0,2192	0,0493	0,0365	0,1289	0,1832	0,2228	0,0499	0,0399	0,1386	0,1853
12	0,2762	0,0524	0,0326	0,1338	0,2154	0,2755	0,0555	0,0321	0,1341	0,2187
16	0,2700	0,0732	0,0330	0,1341	0,2062	0,2677	0,0753	0,0327	0,1345	0,2093
20	0,2361	0,0568	0,0312	0,1320	0,1903	0,2345	0,0590	0,0306	0,1324	0,1920

Рассмотрим вариант реализации системы с бинаризацией синаптических весов сети после общего обучения (все веса из W и W_{in} приведены к виду -1 или $+1$).

Ошибки обучения для модели с бинарными весами составляют $e_{test} = [0,3236; 0,1986; 0,0360; 0,1379; 0,2320]$, что несколько больше, чем у исходной модели, но сравнимы по уровню. Таким образом, нелинейные модели, характерные для бортовых систем управления летательными аппаратами, также удачно аппроксимируют гетерогенные нейронные сети.

Общая характеристика ошибок для всех типов моделей приведена на рис. 3. Видно, что наилучшим качеством моделирования при минимальных аппаратных затратах обладают гетерогенные нейронные сети.




Рис. 3. Относительные ошибки тестирования для нейросетевых моделей: 1 — гомогенные сети (логический нейрон); 2 — гетерогенные сети (тангенциальные и линейный нейрон); 3 — бипарные модели (пороговый нейрон)

Полученные результаты моделирования позволяют утверждать, что даже для нелинейных объектов можно сформировать систему управления или модель в бинарном базисе на основе нейросетевого подхода.

ЛИТЕРАТУРА

- [1] Пролетарский А.В. Системный синтез интеллектуальных систем управления космических аппаратов и комплексов. [Электронный ресурс]. *Наука и образование*, 2007, № 3. URL: <http://cactus.stack.net/doc/64655.html> (дата обращения 12.12.2013).
- [2] Ефимов В.В. Нейросетевое обеспечение бортовых комплексов управления космических аппаратов наблюдения. *Мехатроника, автоматизация, управление*, 2003, № 5, с. 26–32.
- [3] Никишов А.Н., Олейник А.А., Талиманчук Л.Л., Зайцев А.В., Суханов Н.В. Инверсно-адаптивная схема управления сложным динамическим объектом. *Нейрокомпьютеры*, 2010, № 1, с. 34–39.
- [4] Хайкин С. *Нейронные сети: полный курс*. Москва, Издательский дом Вильямс, 2006, 1104 с.
- [5] Ермоленко А.В., Корлякова М.О. Применение виртуальных моделей объектов для обучения нейросетей. *12-я Нац. конф. по искусственному интеллекту с международным участием КИИ-2010*. Тверь, Россия, 2010. Москва, Физматлит, 2010, т. 2, с. 107–115.
- [6] Каримов Р.Р., Косицын В.В., Рубан В.И., Блинов В.Н., Валеев С.С., Исламгулов Т.В. Система информационной поддержки жизненного цикла малого научно-образовательного космического аппарата. *Сб. тр. 11-й Междунар. конф. CSIT*, 2009, т. 3, с. 22–28.
- [7] Севастьянов Н.Н., Бранец В.Н., Панченко В.А., Казинский Н.В., Кондранин Т.В., Негодяев С.С. Анализ современных возможностей создания малых космических аппаратов для дистанционного зондирования

- Земли. Труды МФТИ, 2009, т. 1, № 3. URL: http://www.gazprom-spacesystems.ru/ru/innovation_and_science/science/index.php (дата обращения 21.08.2011).
- [8] Блинов В.Н., Валеев С.С., Исламгулов Т.В., Каримов Р.Р., Косицын В.В., Рубан В.И. Информационная поддержка жизненного цикла микро-спутника на основе сквозных интеллектуальных моделей. *Вестник УГАТУ. Сер. Управление, вычислительная техника и информатика*. Уфа, УГАТУ, 2010, т. 14, № 4 (39), с. 97–103.
- [9] Шахнов В.А., Власов А.И., Кузнецов А.С. Поляков Ю.А. Нейрокомпьютеры — архитектура и реализация. URL: <http://www.citforum.idknet.com/hardware/neurocomp/index.shtml> (дата обращения 30.11.2013).
- [10] Алюшин М.В. Аппаратная реализация быстродействующих нейросетей на основе программируемой логики фирм AMD, ALTERA, XILINX. *Нейроинформатика — 99*. Москва, МИФИ, 1999, ч. 2, с. 18–24.
- [11] Комарцова Л.Г., Максимов А.В., *Нейрокомпьютеры*. Москва, МГТУ им. Н.Э. Баумана, 2004, 400 с.
- [12] Черников В.М., Виксне П.Е., Фомин Д.В., Шевченко П.А., Яфраков М.Ф. *Нейропроцессор, устройство для вычисления функций насыщения, вычислительное устройство и сумматор*. Пат. RU 2131145. URL: <http://www.findpatent.ru/patent/213/2131145.html> (дата обращения 25.06.2013).
- [13] COESA Atmosphere Model. URL: <http://www.mathworks.com/help/aeroblks/coesaatmospheremodel.html> (дата обращения 25.06.2013).
- [14] Aerospace BlockSet. For use with Simulink. User's Guide. URL: http://www.mathworks.com/help/releases/R13sp2/pdf_doc/aeroblks/aeroblks.pdf (дата обращения 12.12.2013)

Статья поступила в редакцию 05.05.2014

Ссылку на эту статью просим оформлять следующим образом:

Коновалов В.Н., Корлякова М.О. Подход к разработке систем управления малыми космическими аппаратами в нейросетевом базисе. *Инженерный журнал: наука и инновации*, 2014, вып. 5. URL: <http://engjournal.ru/catalog/it/nav/1271.html>

Коновалов Владимир Николаевич родился в 1960 г., окончил КФ МГТУ им. Н.Э. Баумана в 1983 г. Старший преподаватель кафедры «Системы автоматического управления» КФ МГТУ им. Н.Э. Баумана. Область научных интересов: цифровые системы управления. e-mail: v.konov@list.ru

Корлякова Мария Олеговна родилась в 1969 г., окончила КФ МГТУ им. Н.Э. Баумана в 1992 г. Канд. техн. наук, доцент кафедры «Системы автоматического управления» КФ МГТУ им. Н.Э. Баумана. Область научных интересов: нейронные сети, интеллектуальные системы управления. e-mail: mkorlyakova@yandex.ru

Approach to developing control systems of micro spacecraft in neuronetwork basis

© V.N. Konovalov, M.O. Korlyakova

Kaluga Branch of Bauman Moscow State Technical University, Kaluga, 248000, Russia

The article reviews the main directions in hardware implementation of neural networks and examines their opportunities for using onboard micro spacecraft. The main requirements to onboard control systems and approaches to their neuronetwork realization are considered. The findings of this research illustrate restrictions and requirements to the resources necessary for onboard systems of micro spacecraft. We show that it is possible to find the effective solution in simple networks. We modeled separate blocks of a neuronetwork control system in the conditions of limited resources and presented the neuronetwork model of approximating the tabular model of the atmosphere. We provide the sample task solution in float and discrete formats of synapse. The article delves into approximation errors in networks of different architecture and shows, that even for options with the discrete form of inputs and a short format of representing the synapses, the task solution quality is sufficient.

Keywords: *neuronetworks, micro spacecraft, control system*

REFERENCES

- [1] Proletarsky A.V. *Nauka i obrazovanie. Elektronnoe nauchno-tehnicheskoe izdanie — Science and education. Electronic scientific and technical periodical*, 2007, no. 3. Available at: <http://cactus.stack.net/doc/64655.html> (accessed 12 December 2013).
- [2] Efimov V.V. *Mekhatronika, avtomatizatsiya, upravlenie — Mechatronics, Automation, Control*, 2003, no. 5, pp. 26–32.
- [3] Nikishov A.N., Oleinik A.A., Talimanchuk L.L., Zaitsev A.V., Sukhanov N.V. *Neirokompyutery — Neurocomputers*, 2010, no. 1, pp. 34–39.
- [4] Khaikin S. *Neironnye seti: polnyi kurs* [Neural networks: a complete course]. 2nd ed., transl. from Engl. Moscow, «Izd. dom Vil'iams, Ltd » Publ., 2006, 1104 p.
- [5] Ermolenko A.V., Korlyakova M.O. Primenenie virtual'nykh modelei ob"ektov dlia obucheniia neurosetei. [Applying virtual models of objects for training neural networks]. *12-ya Nats. konf. po iskusstvennomu intellektu s mezhdunarodnym uchastiem KII–2010, Tver', Rossiya, 2010: Trudy konferentsii*. [Twelfth National Conference on Artificial Intelligence with CAI 2010, Tver, Russia, 2010: Proceedings]. Moscow, Fizmatlit Publ., 2010, vol. 2, pp. 107–115.
- [6] Karimov R.R., Kositsyn V.V., Ruban V.I., Blinov V.N., Valeev S.S., Islamgulov T.V. Sistema informatsionnoi podderzhki zhiznennogo tsikla malogo nauchno-obrazovatel'nogo kosmicheskogo apparata [System of informational life cycle support of small scientific and educational spacecraft]. *Sbornik trudov 11-i mezhdunar. konf. CSIT* [Proceedings of the 11th Int. conf. CSIT], 2009, vol. 3, pp. 22–28.

- [7] Sevastyanov N.N., Branets V.N., Panchenko V.A., Kazinsky N.V., Kondranin T.V., Negodyaev S.S. Analiz sovremennykh vozmozhnostei sozdaniya malykh kosmicheskikh apparatov dlya distantsionnogo zondirovaniya Zemli [Analysis of modern possibilities of creating small spacecraft for remote Earth sensing]. *Trudy MFTI* [MIPT Proceedings], 2009, vol. 1, no. 3. Available at: http://www.gazprom-spacesystems.ru/ru/innovation_and_science/science/index.php (accessed 21 August, 2011).
- [8] Blinov V.N., Valeev S.S., Islamgulov T.V., Karimov R.R., Kositsyn V.V., Ruban V.I. *Vestnik UGATU, Seriya «Upravlenie, vychislitel'naia tekhnika i informatika» — Bulletin of ASTU, Series "Management, computer science and informatics"*, 2010, vol. 14, no. 4 (39), pp. 97–103.
- [9] Shakhnov V.A., Vlasov A.I., Kuznetsov A.S., Polyakov Yu.A. *Neirokomp'yutery — arkhitektura i realizatsiya* [Neurocomputers — architecture and implementation]. Available at: <http://www.citforum.idknet.com/hardware/neurocomp/index.shtml> (accessed 30 November, 2013).
- [10] Alyushin M.V. Apparatsnaya realizatsiya bystrodeistvuyuschikh neurosetei na osnove programmiruemoy logiki firm AMD, ALTERA, XILINX [Hardware implementation of high-speed neural network based on programmable logic by the companies AMD, ALTERA, XILINX]. *Neiroinformatika — Neuroinformatics'99*. Moscow, Moscow Engineering Physical Institute, 1999, part 2, pp. 18–24.
- [11] Komartsova L.G., Maksimov A.V. *Neirokompyutery* [Neurocomputers]. Moscow, Bauman MSTU Publ., 2004, 400 p.
- [12] Chernikov V.M., Viksne P.E., Fomin D.V., Shevchenko P.A., Yafrakov M.F. *Neiroprotssor, ustroystvo dlya vychisleniya funktsiy nasyscheniya, vychislitel'noe ustroystvo i summator* [Neuroprocessor, a device for calculating the saturation function, the computing device and an adder]. Patent RU 2131145. Available at: <http://www.findpatent.ru/patent/213/2131145.html> (accessed 25 June 2013).
- [13] COESA Atmosphere Model. Available at: <http://www.mathworks.com/help/aeroblks/coesatmospheremodel.html> (accessed 25 June, 2013).
- [14] Aerospace BlockSet. For use with Simulink. User's Guide. Available at: http://www.mathworks.com/help/releases/R13sp2/pdf_doc/aeroblks/aeroblks.pdf (accessed 12 December, 2013)

Konovalev V.N. (b. 1960) graduated from Kaluga branch of Bauman Moscow Higher Technical School in 1983. Senior lecturer of the Automatic Control Systems Department at Kaluga Branch of Bauman Moscow State Technical University. Sphere of scientific interests: numerical control systems. e-mail: v.konovalev@list.ru

Korlyakova M.O. (b. 1969) graduated from Kaluga Branch of Bauman Moscow State Technical University in 1992. Ph.D., Assoc. Professor of the Automatic Control Systems Department at Kaluga Branch of Bauman Moscow State Technical University. Scientific interests include neuronets, intelligence control systems. e-mail: mkorlyakva@yandex.ru