

Нейрочипы и нейроморфные ЭВМ: проблемы моделирования

Представлен комплекс моделей, необходимых для разработки современных и перспективных нейрочипов и нейроморфных ЭВМ на их основе. В состав комплекса моделей входят модели, связанные с разработкой нейросетевых алгоритмов решения задач, технологические модели, связанные с построением базовых элементов схмотехники, а также схмотехнические модели принципиальных схем, реализующих нейрочипы и их функциональные элементы.

Ключевые слова: нейронные сети, настройка коэффициентов, элементы нейрочипов, схмотехнические модели

Введение

Сложность современных и перспективных нейрочипов и нейроморфных ЭВМ делает необходимым разработку комплекса моделей для проверки их основных свойств и функционирования. Сочетание в современных и перспективных нейрочипах и нейроморфных ЭВМ различных технологий (мемристорной; аналоговой КМОП; цифровой КМОП; оптической, а также различных технологий изготовления нейроплат, нейроблоков, нейростоек и супернейрокомпьютеров) делает необходимым разработку и использование комплекса моделей, систем проектирования и библиотек элементов, а именно моделей:

- входного сигнала нейронных сетей;
- функционалов первичной оптимизации;
- нейронных сетей;
- процессов настройки коэффициентов нейронных сетей в нейроморфных ЭВМ;
- процессов настройки коэффициентов нейронной сети с переменной структурой;
- процессов настройки коэффициентов нейронных сетей в нейроморфных ЭВМ с ограничениями на настраиваемые коэффициенты;
- типовых входных сигналов нейронных сетей;
- планов экспериментов и визуализации результатов для проверки качества работы нейронных сетей;
- решения формализуемых и неформализуемых задач с применением больших нейронных сетей для перспективных нейроморфных ЭВМ;
- распараллеливания нейросетевых алгоритмов в соответствии с реальной структурой физических моделей перспективных нейроморфных ЭВМ;
- технологических;
- архитектуры нейроморфных ЭВМ;
- схмотехнических для нейроморфных ЭВМ;
- нейрофизиологических, для исследования на нейроморфных ЭВМ.

В статье рассмотрены эти модели.

1. Модели входного сигнала нейронных сетей

Основная аксиоматика нейронных сетей основана на вероятностной модели внешнего мира.

Внешний мир представлен в виде набора случайных сигналов. Практический опыт с применением классических методов математической статистики показал их основные ограничения — априорную необходимость формального описания функций распределения входных многомерных случайных сигналов. В реальных задачах начала — середины 60-х годов прошлого века была реальная необходимость в отказе от подобного, характерного для методов математической статистики, представления функций распределения случайных сигналов в виде известных функций. Считалось, что функция распределения неизвестна и может быть очень сложной, многомодальной.

Канонически входной сигнал нейронных сетей может быть представлен как входной сигнал в виде непосредственно случайного процесса и как указание учителя нейронной сети, формирующего отношение каждого входного образа (элемента случайного процесса) к тому или иному классу. Указания учителя могут быть двоичными и вещественными, одномерными и многомерными.

Постановка задачи обработки таких сигналов подобна задаче математической статистики. Рассматривались в основном задачи классификации (распознавания) и задачи кластеризации (распознавание с учителем, имеющим нулевую квалификацию).

С развитием теории нейронных сетей и ее применений при решении ряда практических проблем в 60-е годы прошлого века появились следующие модификации данных задач:

- обучение с учителем, имеющим конечную квалификацию, когда учитель не может с единичной вероятностью (полной уверенностью) указать принадлежность образов к тому или иному классу (например, в задачах медицинской диагностики);
- режим "вредительства", когда учитель заведомо ложно или приблизительно ложно сообщает нейронной сети информацию о принадлежности входных образов к тому или иному классу.

Количественной характеристикой входного сигнала нейронной сети является также априорная вероятность появления образов того или иного класса. Например, при решении задачи оптического рас-

познавания букв печатного текста необходимо учитывать, что априори известна вероятность появления каждой буквы в тексте. Эта вероятность может быть получена обработкой текста достаточно большого объема.

2. Модели функционалов первичной оптимизации в системах обработки информации с применением нейросетевых технологий

Функционал первичной оптимизации определяет основную цель, достигаемую при работе нейронной сети. Вероятностная модель внешнего мира и рассмотренные выше модели входного сигнала делают необходимым рассмотрение критериев первичной оптимизации, связанных с понятием средней функции риска, известной из классической математической статистики.

Простейшим таким критерием является критерий минимума средней функции риска, который при равных априорных вероятностях появления классов и при диагональной матрице потерь [1] преобразуется в более простой — критерий минимума среднеквадратичной ошибки.

На практике формируются различные модели функционала первичной оптимизации:

- функционал, связанный с критерием минимума средней функции риска;
- функционал для критерия минимума средней функции риска при заданном значении условной функции риска для каждого из классов;
- функционал для критерия минимума средней функции риска при равных значениях условной функции риска для различных классов;
- другие возможные на практике функционалы.

Рассмотренные модели функционала первичной оптимизации формируются, в свою очередь, своеобразно для указанных выше моделей входного сигнала в режимах классификации, кластеризации, обучения с учителем, имеющего конечную квалификацию, вредительства и других, имеющих место на практике.

При построении моделей функционала первичной оптимизации необходимо в них в обязательном порядке учитывать свойства матрицы потерь. Как правило, она по умолчанию принимается симметричной. При этом при решении задачи распознавания двух классов образов потери при принятии образов первого класса за образы второго класса считаются равными потерям при принятии образов второго класса за образы первого. Такая постановка является некорректной во многих практических задачах, например, в системах обнаружения мин с помощью геолокатора, задачах медицинской диагностики и др. Именно это требует учета недиагональности матрицы потерь при построении модели функционала первичной оптимизации в системах обработки информации с применением нейросетевых технологий и на последующих этапах построения моделей для нейроморфных ЭВМ.

3. Модели нейронных сетей

Буквально через несколько лет после выхода основополагающей книги Ф. Розенблатта "Принципы нейродинамики" [5] в России сформировалась научная школа в области теории нейронных сетей [1—4]. Именно в России, еще в 60-е годы прошлого столетия рассматривались в качестве канонических многослойные нейронные сети:

- с полными последовательными связями (настраиваемые связи от каждого предыдущего слоя нейронов к последующему);
- с полными обратными связями (с выхода последующих слоев нейронов на входы предыдущих);
- с полными перекрестными связями (с выхода предыдущих на входы всех последующих, включая полные последовательные).

Одним из важных моментов построения моделей нейронных сетей является выбор типа функций активации первого, последующих и, что особенно важно, последнего слоя нейронов.

На протяжении последних 50 лет основной идеей формирования структуры нейронной сети, решающей ту или иную задачу, была идея формирования структуры, адекватной решаемой задаче, с возможностью изменения некоторых параметров структуры в целях оптимизации выбора варианта с точки зрения качества решения задачи.

На протяжении последних 50 лет для моделирования нейронных сетей использовались наиболее производительные ЭВМ и при соответствующем росте требований к размерам и быстродействию нейронных сетей всегда не хватало производительности моделирующих ЭВМ и памяти для хранения массивов перестраиваемых коэффициентов. Последний такой эксперимент был проведен с суперЭВМ IBM BlueGene.

Вполне естественным в этом плане выглядит формируемая в последние годы идея так называемого глубокого (глубинного) обучения (*deep learning*), в которой делается попытка введения в структуру нейронных сетей ограниченных связей, специфических для данной решаемой задачи, с естественным увеличением числа слоев нейронной сети. Причем основное внимание на первом этапе развития глубокого обучения уделяется задаче обработки изображений.

По сути, эта идея не нова и родилась вовсе не в 2006—2009 гг. Еще в своей классической монографии [5] Фрэнк Розенблатт предложил для сокращения числа настраиваемых связей ретины размером $N \times N$ с первым слоем из H_1 нейронов использовать случайным образом формируемые $A(H_1)$ связи (причем $A(H_1) \ll N$) каждого нейрона первого слоя с элементами ретины размером $N \times N$. Тогда число настраиваемых коэффициентов сокращается с $N \times N \times H_1$ до $N \times A(H_1) \times H_1$.

В 60-е годы прошлого столетия это была достаточно эффективная методика уменьшения числа настраиваемых связей при решении задач обработки,

в частности распознавания, изображений. В работе [6] известного ученого — профессора университета Беркли — отмечено, что идеи глубокого обучения во многом повторяют работы 60-х и 80-х годов прошлого века в области многослойных нейронных сетей.

На вопрос корреспондента: "Из Вашей статьи я сделал вывод, будто Вы считаете, что в темах глубинного обучения, больших данных, машинного зрения и им подобных, присутствует огромное количество дезинформации" Майкл Джордан ответил следующее: "В частности тематика глубинного обучения — это, в значительной степени, просто переработанная информация о нейронных сетях с 1980-х годов. А в те годы они повторяли то, что было известно в 1960-е годы, такое чувство, что каждые 20 лет проходит волна, затрагивающая одни и те же темы. В волне, которая идет сейчас, главной идеей является сверточная нейронная сеть, о которой уже говорили 20 лет назад.

Одна из проблем, связанных с обеими предыдущими волнами, и которая упорно продолжит присутствовать в нынешней волне, заключается в том, что люди продолжают считать, будто секрет как-то связан с неврологией. Они считают, что для глубинного обучения нужно понимание того, как мозг обрабатывает информацию, учится, принимает решения или справляется с огромным количеством информации. Это откровенная ложь".

4. Модели процессов настройки коэффициентов нейронных сетей в нейроморфных ЭВМ

С самого начала работ в 60-е годы прошлого столетия при построении моделей процессов настройки коэффициентов нейронной сети использовались результаты работ советской научной школы под руководством д-ра техн. наук, профессора В. В. Солодовникова в области так называемых аналитических самонастраивающихся систем [7]. В этих системах градиент функционала оптимизации процесса функционирования вычисляется не введением искусственных поисковых колебаний и детектированием выходных сигналов, а путем специальной обработки промежуточных (внутренних) и выходных сигналов. При этом в работах [1, 3, 4] нейронная сеть рассматривается как частный случай объекта управления в аналитической самонастраивающейся системе. Данный объект является многомерным, многосвязным и нелинейным. Именно в этом была отмечена основная специфика нейронных сетей как объектов управления, определившая в том числе и специфику построения моделей процессов настройки коэффициентов нейронных сетей на нейроморфных ЭВМ.

Первым этапом построения моделей процессов настройки коэффициентов нейронных сетей является формирование функционала *вторичной оптимизации* с помощью внутренних и выходных сигналов нейронных сетей той или иной структуры. Вид

функционала вторичной оптимизации в значительной степени зависит от решаемой задачи. В задачах аппроксимации и экстраполяции функций и их модификациях (расознавания образов), как правило, применяется простейший вид функционала вторичной оптимизации — среднеквадратическая ошибка, вычисляемая на некотором интервале функционирования системы.

Вторым этапом построения моделей процессов настройки коэффициентов нейронных сетей является построение моделей (разработка алгоритмов) поиска экстремума функционала вторичной оптимизации в нейронных сетях. Причем основная проблема заключается в том, что данный функционал является многомерным (размерность — число настраиваемых коэффициентов нейронной сети) и многоэкстремальным с достаточно большим числом локальных экстремумов, в том числе и глобального.

В зависимости от решаемой задачи здесь возможны различные варианты постановки задачи:

- найти глобальный экстремум функционала вторичной оптимизации;
- найти все локальные и глобальные экстремумы функционала вторичной оптимизации;
- найти любой локальный экстремум функционала вторичной оптимизации, как это имеет место при решении больших систем линейных неравенств [8].

Третьим этапом построения моделей процессов настройки коэффициентов нейронных сетей является выбор коэффициента усиления в алгоритме поиска экстремума. В большинстве случаев он выбирается эмпирически при анализе процесса сходимости процедуры обучения. Иногда прибегают к некоторым модификациям, выбирая этот коэффициент уменьшающимся во времени в процессе настройки, что зачастую приводит к резкому увеличению времени настройки. К подобным модификациям относится известный метод стохастической аппроксимации.

Четвертым этапом построения модели процесса настройки коэффициентов нейронной сети является выбор размера памяти фильтра обработки потока ошибок в контуре настройки. Как правило, эта память по умолчанию выбирается равной единице, что не всегда является оптимальным с точки зрения результирующего времени настройки, а, во-вторых, справедливо только для случаев стационарных входных сигналов (образов) на входе (сигналов с априори постоянной во времени сложной функцией распределения). Отсутствие или малая память фильтра сигнала ошибки может привести к внесению дополнительных шумов в контур настройки коэффициентов нейронной сети.

Пятым этапом построения моделей процессов настройки коэффициентов нейронной сети является выбор начальных значений настраиваемых коэффициентов. Как правило, во многих работах выбор начальных условий проводится случайным

образом. Это осуществляется по умолчанию либо вследствие слабой профессиональной подготовки разработчика и приводит к резкому увеличению как времени настройки, так и требований к вычислительным ресурсам.

Этот один из основных недостатков моделей нейронных сетей с фиксированной до этапа настройки структурой можно ликвидировать, выбирая начальные условия настройки для каждой задачи. Еще в работе [1] были представлены такие подходы к решению задач классификации и кластеризации, а в [4] — дополнительно для задач нейрорегулирования. Качественный, адекватный решаемой задаче, выбор начальных условий настройки коэффициентов нейронных сетей является важным условием резкого уменьшения времени настройки для нахождения необходимых локальных и глобальных экстремумов функционала вторичной оптимизации.

5. Модели процессов настройки коэффициентов нейронной сети с переменной структурой

Отказавшись на первом этапе построения моделей и алгоритмов настройки нейронных сетей от информации о параметрах фиксированной структуры, возможно для настройки коэффициентов использовать модели с переменной структурой, предложенные в работе [2] и успешно применяемые при решении практических задач в течение многих лет. Модели настройки нейронных сетей с переменной структурой реализуют последовательную итерационную процедуру наращивания числа нейронов первого слоя сети до достижения необходимого качества решения задачи. Последующие за первым слоем нейронной сети реализуют функцию в пространстве выходных сигналов нейронов первого слоя. Модель с переменной структурой может быть использована также для выбора начальных условий при дальнейшей подстройке коэффициентов нейронной сети с фиксированной структурой.

6. Модели процессов настройки коэффициентов нейронных сетей в нейроморфных ЭВМ с ограничениями на настраиваемые коэффициенты

Вполне естественным является желание учета в математической модели управляемого объекта ограничений физической модели в целях их максимального соответствия.

Именно с этой целью в 60-е годы прошлого века, в рамках развиваемой в СССР научной школы нейроморфных ЭВМ, были разработаны модели настройки нейронных сетей с учетом реальных ограничений на настраиваемые коэффициенты, присутствовавшие в физических реализациях нейроморфных ЭВМ. Были разработаны [1] модели настройки коэффициентов нейронных сетей для нескольких видов ограничений с возможностью расширения методики на возможные перспективные ограничения. Основными, применяемыми на практике, моделями

настройки были модели для ограничений на коэффициенты типа насыщения, так как в реальных разработанных физических моделях настраиваемые коэффициенты реализовывались на потенциометрах [9].

В перспективных нейроморфных ЭВМ с применением мемристоров [10] необходимо разработать модели настройки коэффициентов нейронных сетей с учетом реальных нелинейных передаточных функций мемристоров как элементов физической реализации настраиваемых коэффициентов. При этом нейроморфный компьютер будет многоуровневой аналогово-цифровой ЭВМ с распределением нейросетевых алгоритмов решения задачи по различным уровням, включая аналоговый, реализуемый на мемристорах. Именно поэтому разработка моделей мемристорных матриц (см. п. 11) представляет особый интерес.

7. Модели типовых входных сигналов нейронных сетей

Как и в классической теории управления, типовые входные сигналы необходимы как для проверки качества функционирования разработанной системы, так и для регулярного тестирования (проверки правильности функционирования) в процессе эксплуатации. Для линейных одномерных систем такими типовыми входными сигналами являются дельта-функция, единичная ступенька, линейный сигнал, сигналы большего порядка, которыми проверяется астатизм системы и проводится проверка работы в процессе функционирования. Для линейных многомерных систем и нелинейных объектов, как правило, типовые входные сигналы формируются специфическим образом для каждой решаемой задачи. То же самое делается для нейронных сетей, которые являются многомерными многосвязными нелинейными динамическими системами. В большинстве работ по нейросетевым алгоритмам решения задач реализуется некоторое, достаточно субъективное, разделение обучающей выборки на обучающую и контрольную, по результатам работы на которых делаются выводы о качестве работы системы.

Стремление к повышению объективности сравнения работы таких сложных систем, которыми являются нейронные сети, привело еще в 60—70-е годы прошлого века к формированию типовых тестовых входных сигналов, специфических для данной решаемой задачи [1]. Для задач классификации и кластеризации это были многомерные (N) случайные выборки с изменяемым числом мод (M) и среднеквадратичным отклонением (δ) для каждой моды. Подобные типовые сигналы, в принципе, позволяют достаточно объективно сравнивать разрабатываемые алгоритмы классификации и кластеризации, варьируя параметры в пространстве $[M, \delta]$. Были сделаны попытки [1, 4] сформировать типовые входные сигналы для задач экстраполяции функций и нейрорегулирования сложными нелинейными динамическими системами.

Иногда в реальных практических задачах, а также в случае применения методов разделения выборки на обучающую и контрольную выборка бывает недостаточно большой, а иногда весьма малой, чтобы нейронная сеть путем обработки восприняла ее статистические свойства. В этом случае применяется процедура рандомизации конечной выборки, когда элементы конечной выборки считаются математическим ожиданием случайных выборок, искусственно генерируемых добавлением к ним случайной выборки с нормальным распределением и некоторым среднеквадратичным отклонением δ_k . При этом предметом исследования разработанных нейросетевых алгоритмов решения задач является исследование зависимости качества решения от величины δ_k .

8. Модели планов экспериментов и визуализации результатов для проверки качества работы нейронных сетей

План эксперимента по проверке качества работы нейронных сетей на типовых и реальных входных сигналах разрабатывается так, чтобы максимально покрыть исследуемое пространство параметров входного сигнала и структуры нейронной сети. Диапазон изменения этих параметров выбирается с учетом того, что сложность решаемой задачи в процессе настройки косвенно отображается в сложности настроенной нейронной сети.

Построение модели визуализации результатов настройки нейронных сетей является важным результатом работы. В настоящее время основным методом построения моделей визуализации результатов настройки нейронных сетей на типовых и реальных входных сигналах является представление зависимости от времени в процессе настройки значения функционала вторичной оптимизации и, в частности, среднеквадратичной ошибки решения задачи.

Главная трудность решения задачи визуализации результатов настройки нейронных сетей заключается в многомерности пространства входных сигналов и указаний учителя. Для демонстрации эффективности моделей и алгоритмов настройки иногда, начиная с 60-х годов прошлого века, применялись 2D-модели, а в последнее время и 3D-модели, но они являются весьма косвенным, начальным аргументом эффективности. Основным же аргументом эффективности остается отмеченная выше зависимость в процессе настройки функционала вторичной оптимизации.

9. Модели решения формализуемых и неформализуемых задач с применением больших нейронных сетей для перспективных нейроморфных ЭВМ

Раздел разработки моделей решения формализуемых задач является прямым развитием работ, начатых во всем мире в конце 80-х годов прошлого

века, впервые интегрированных в коллективной монографии [8], которые посвящены решению классических математических задач повышенной сложности в нейросетевом логическом базисе. Если формализуемые задачи требуют перехода в нейросетевой логический базис при достижении и превышении определенного уровня сложности, то для неформализуемых задач нейросетевые технологии являются основным, если не единственным, методом решения.

Основная задача здесь должна заключаться в возможности использования программно-аппаратных эмуляторов с большим и очень большим числом нейронов и связей и в оптимизации нейросетевых алгоритмов решения формализуемых и неформализованных задач под многоуровневую архитектуру перспективных аналого-цифровых нейроморфных ЭВМ с применением мемристоров.

10. Модели распараллеливания нейросетевых алгоритмов в соответствии с реальной структурой физических моделей перспективных нейроморфных ЭВМ

Проблема распараллеливания нейросетевых алгоритмов стояла в течение последних десятилетий развития вычислительной техники. Она была актуальной для малопроецессорных ЭВМ, многопроецессорных, в частности транспьютерных [11], систем, для суперЭВМ на базе графических процессоров. Каждый раз с изменением архитектуры ЭВМ модели и методы распараллеливания нейросетевых алгоритмов менялись.

Важно отметить, что распараллеливание на логические элементы физической модели необходимо проводить не только для настраиваемой нейронной сети, но и для алгоритма, реализующего контур настройки коэффициентов.

В случае нейрокомпьютеров с применением мемристоров модель распараллеливания нейросетевых алгоритмов будет специфической вследствие особенностей архитектуры, содержащей несколько слоев обработки информации:

- внешний слой аналоговой обработки системой на базе мемристоров;
- слой обработки на базе аналоговых КМОП схем, стыкованный с мемристорным блоком;
- слой ЦАП и АЦП;
- слой цифровой обработки на базе цифровых КМОП-схем (ПЛИС, GPU и др.);
- слой узловых ЭВМ, соединяемых в некоторый кластер;
- хост ЭВМ.

11. Технологические модели

В состав технологических моделей, необходимых для построения перспективных нейроморфных ЭВМ должны входить, в первую очередь, модели мемристоров и мемристорных матриц большой

размерности, адекватные архитектуре разрабатываемых нейрочипов с применением мемристоров. Данные модели должны разрабатываться в тесном контакте с технологиями на базе ПЭВМ, ПЛИС и GPU и использоваться для отработки технологических процессов, а в будущем — для разработки моделей и алгоритмов настройки нейронных сетей в нейроморфных ЭВМ.

В состав технологических моделей должны быть включены модели анализа и выбора технологий изготовления мемристоров с точки зрения производительности будущих вычислительных систем с применением мемристоров и, непосредственно, методики оценки производительности совокупной вычислительной системы.

Ряд технологических моделей должен быть уточнен разработчиками, работающими с технологическими процессами изготовления мемристоров и мемристормных матриц.

Необходимым разделом технологических моделей должны явиться модели памяти и коммутационных систем на базе мемристоров как намного более массовых изделий в производстве в будущем и, по сути дела, обеспечивающих жизнеспособность мемристормного направления развития нейроморфных ЭВМ.

12. Модели архитектуры нейроморфных ЭВМ

До этапа разработки схмотехники нейроморфных ЭВМ с применением мемристоров необходимо пройти этап разработки и моделирования архитектуры нейроморфных ЭВМ.

Нижним уровнем подобных работ является создание модели архитектуры перспективных СБИС-нейрочипов с применением мемристоров. Основными принципами построения подобных СБИС по сравнению с классическими микропроцессорами являются следующие:

- реализация нейросетевого логического базиса на программно-аппаратном уровне обработки информации, т. е. переход от последовательных к высокопараллельным архитектурам обработки информации [9];
- переход в нейросетевой программно-аппаратной реализации от представления сигналов в виде уровней токов и напряжений к представлению сигналов в виде частоты последовательности узких импульсов, что приводит к резкому (в десятки и сотни тысяч раз) понижению энергопотребления в реальных разработках даже без применения мемристоров (цифровых и аналоговых). Этот важный шаг в развитии вычислительной техники не должен сейчас приводить к спекуляциям типа "мы создаем модели мозга", так как принцип функционирования мозга и технологии его реализации принципиально отличны от того, что предлагается создать в нейроморфных ЭВМ, в том числе с применением мемристоров [6];

- переход от чисто цифровой к аналого-цифровой программно-аппаратной реализации нейроморфных ЭВМ вследствие технологических особенностей мемристоров и мемристормных матриц, что приводит к резкому повышению технической производительности при соответствующем контроле точности обработки. Этот переход идет сейчас, на этапе создания специализированных нейроморфных ЭВМ без применения мемристоров, для того чтобы сформировать достаточно широкую сферу применения [12].

Архитектура перспективных СБИС-нейрочипов с применением мемристоров должна включать в себя кроме элементов слоев обработки, перечисленных выше в п. 10, также и коммутационные среду и интерфейс, специализированные на реализацию нейросетевых алгоритмов.

При разработке моделей нейроплат также следует учитывать необходимость размещения на плате нейрочипов, элементов памяти, специализированной для платы коммутационной среды и интерфейсов.

По аналогичным принципам необходимо строить модели нейроблоков путем соединения нескольких моделей нейроплат, модели нейростоек — путем соединения нескольких моделей нейроблоков.

Необходимо отметить, что в настоящее время активно ведутся разработки ряда специализированных нейроморфных систем с реализацией указанных выше трех принципов. В некоторых разработках реализуются только первые два принципа. Однако во всех случаях это приводит к достаточно большому эффекту. Именно поэтому при разработке модели архитектуры специализированных нейроморфных ЭВМ с соблюдением всех трех принципов реализации необходимо создание следующих моделей:

- архитектуры перспективного аналогового кардиостимулятора с резким понижением энергопотребления на базе нейрочипа с частотно-импульсным представлением обрабатываемых сигналов [12];
- архитектуры перспективного кохлеаимпланта;
- модели архитектуры перспективного зрительного импланта;
- архитектуры перспективного интерфейса "мозг-компьютер";
- архитектуры перспективной видеокамеры с применением мемристоров [13].

Наверняка перечень специализированных нейроморфных ЭВМ будет в дальнейшем расширяться в целях формирования конкретных разработок и подготовки рынка будущих систем с применением мемристоров.

13. Схмотехнические модели нейроморфных ЭВМ

Все представленные схмотехнические модели нейроморфных ЭВМ можно условно разделить на две части:

- схмотехнические модели сегодняшнего дня, которые можно использовать при создании

нейроморфных ЭВМ до появления мемристорных систем в серийном производстве;

- схемотехнические модели нейроморфных ЭВМ с применением мемристоров.

Основная задача разработчиков схемотехнических моделей нейроморфных ЭВМ заключается в том, чтобы разработать схемотехнические модели сегодняшнего дня, которые в будущем будут максимально использованы при разработке схемотехнических моделей нейроморфных ЭВМ с применением мемристоров.

В состав схемотехнических моделей нейроморфных ЭВМ должны входить следующие модели:

- интеграции технологий изготовления мемристорных матриц большого размера в КМОП-схемы;
- аналогового фрагмента схемотехники перспективного СБИС-нейрочипа с применением мемристоров, включая ЦАП и АЦП;
- цифрового фрагмента перспективного СБИС-нейрочипа с применением мемристоров;
- схемотехники СБИС-нейрочипа с применением мемристоров с использованием библиотеки конкретного производства;
- схемотехники нейроплат, нейроблоков, нейростоек.

В состав схемотехнических моделей кроме вышеперечисленных должны входить схемотехнические модели специализированных нейроморфных ЭВМ:

- кардиостимулятора;
- кохлеаимпланта;
- интерфейса "мозг-компьютер";
- зрительного импланта;
- перспективной видеокамеры с применением мемристоров.

14. Нейрофизиологические модели для исследования на нейроморфных ЭВМ

Нейроморфные ЭВМ являются наиболее адекватным средством построения нейрофизиологических моделей различных разделов мозга. Однако исследование нейрофизиологических моделей разделов мозга не является основной задачей, определяющей необходимость разработки нейроморфных ЭВМ, так как не являются задачей массового применения. Основными задачами здесь является широкий круг практических задач обработки сигналов, изображений, управления динамическими объектами, в первую очередь роботами наземного, воздушного, морского, подводного базирования. Не умаляя значимости создания и исследования нейрофизиологических моделей на базе будущих нейроморфных ЭВМ, необходимо проводить эти работы для различных разделов мозга. При этом разработчики нейроморфных ЭВМ будут участвовать в этой работе в качестве реализаторов, подобно тому, как это делалось в течение последних десятилетий, в том числе на последних вариантах суперЭВМ: транспьютер-

ных и транспьютероподобных, на базе графических процессоров и классических кластерных. Каждый раз оказывалось, что реально достигнутая производительность суперЭВМ крайне далека от требуемой для построения нейрофизиологических моделей в реальном времени. В этом плане разрабатываемые и перспективные нейроморфные ЭВМ в ближайшие годы могут, по нашему мнению, только слегка раздвинуть границы исследований нейрофизиологических моделей разделов мозга.

Заключение

Данная статья посвящена одной из многих трудных проблем, стоящих перед разработчиками нейроморфных ЭВМ — разработке систем моделей для современных и перспективных нейрочипов и нейроморфных ЭВМ. Автор ставил своей целью показать необходимость органического единства разработок моделей различного уровня и опасается, что текущий уровень организации науки и промышленных разработок может привести к раздробленности рассматриваемого раздела работ. Представленная структура разработки системы моделей является основой для будущей многолетней работы в области создания нейроморфных ЭВМ. Основой этой работы должен быть научно-технический задел советской и российской науки в области нейросетевых технологий, о приоритете которой было указано в предисловиях к монографиям [3, 4] ведущих мировых ученых Лотфи Заде, Роберта Хехт-Нильсена и Амари.

Список литературы

1. **Галушкин А. И.** Синтез многослойных систем распознавания образов. М.: Энергия, 1974.
2. **Галушкин А. И.** Многослойные системы распознавания образов. М.: Изд. МИЭМ, 1968.
3. **Galushkin A. I.** Neural networks theory. Springer, 2007.
4. **Галушкин А. И.** Нейронные сети: основы теории. М.: Горячая линия — Телеком, 2010.
5. **Розенблатт Ф.** Принципы нейродинамики. М.: Мир, 1963.
6. **Джордан М.** Искусственный интеллект, большие данные и дезинформация технологий. ICloud.ru
7. **Аналитические** самонастраивающиеся системы / Под ред. В. В. Солодовникова. М.: Машиностроение, 1965.
8. **Нейроматематика.** Сер. "Нейрокомпьютеры и их применение". Кн. 6. М.: ИПРЖР, 2002.
9. **Галушкин А. И.** Нейрокомпьютеры. Сер. "Нейрокомпьютеры и их применение". Кн. 3. М.: ИПРЖР, 2000.
10. **Галушкин А. И.** На пути к нейрокомпьютерам с использованием мемристоров // Информационные технологии. 2014. № 4. Приложение. 32 с.
11. **Галушкин А. И.** Транспьютерные системы — начало становления в России ЭВМ с массовым параллелизмом // Нейрокомпьютеры. 2005. № 3.
12. **Qing Sun and all.** Implementation Study of an Analog Spiking Neural Network for Assisting Cardiac Delay Prediction in Cardiac Resynchronization Therapy Device // IEEE Trans. on Neural Networks. June 2011. Vol. 22, N. 6.
13. **Новый** чип ускорит обработку видео в 1000 раз. Системы видеонаблюдения. Продолжение эволюции. М., 4 декабря 2013 г. URL: <http://www.cnews.ru>, 16.08.2013.

Neurochips and Neuromorphic Computers: a Modelling Challenges

The complex of models needed for the development of current and future neurochips and neuromorphic computers based on them is presented. The complex of models includes models related to the development of neural network algorithms for solving problems, process models, associated with the construction of the basic elements of the circuitry, and circuit design model concepts realizing neurochips and functional elements.

Due to complexity of current and future neurochips and neuromorphic computers, it is necessary, before their creation, to develop their complex models for testing their basic features and functions. The combination in modern and future neurochips and neuromorphic computers such different technologies as memristors, analog CMOS, digital CMOS, optical, various techniques of development of neuroboards, neroblocks, neuroracks and superneurocomputers, makes it necessary to develop and use such complex models, CAD systems and elements libraries.

This article describes these models and give an explanation of the objective necessity of the implementation such software models on personal computers and GPU-supercomputers.

Keywords: neural networks, weights adjustment, neurochips, circuits design models

References

1. Galushkin A. I. *Sintez mnogosloynnykh sistem raspoznavaniya obrazov*. Moscow: Energiya, 1974.
2. Galushkin A. I. *Mnogosloynnyye sistemy raspoznavaniya obrazov*. Moscow: Izd. MIEM, 1968.
3. Galushkin A. I. *Neural networks theory*. Springer, 2007.
4. Galushkin A. I. *Neyronnyye seti: osnovy teorii*. Moscow: Goryachaya liniya — Telekom, 2010.
5. Rozenblatt F. *Printsiipy neyrodinamiki*. Moscow: Mir, 1963.
6. Dzhordan M. *Iskusstvennyy intellekt, bol'shiye dannyye i dezinformatsiya tekhnologiy*. ICloud.ru
7. *Analiticheskiye samonastrayayushchiyesya sistemy*. Pod red. V. V. Solodovnikova. Moscow: Mashinostroyeniye, 1965.
8. *Neyromatematika*. Ser. "Neyrokomp'yutery i ikh primeneniye". Kn. 6. Moscow: IPRZHR, 2002.
9. Galushkin A. I. *Neyrokomp'yutery*. Ser. "Neyrokomp'yutery i ikh primeneniye". Kn. 3. Moscow: IPRZHR, 2000.
10. Galushkin A. I. Na puti k neyrokomp'yuteram s ispol'zovaniyem memristorov, *Informatsionnyye tekhnologii*, 2014, no. 4, Prilozheniye, 32 p.
11. Galushkin A. I. Transp'yuternyye sistemy — nachalo stanovleniya v Rossii EVMs massovym paralelizmom, *Neyrokomp'yutery*, 2005, no. 3.
12. Qing Sun and all. Implementation Study of an Analog Spiking Neural Network for Assisting Cardiac Delay Prediction in Cardiac Resynchronization Therapy Device, *IEEE Trans. on Neural Networks*. June 2011, vol. 22, no. 6.
13. *Novyy chip uskorit obrabotku video v 1000 raz*. Sistemy videonablyudeniya. Prodolzheniye evolyutsii. Moscow, 4 dekabrya 2013 g. URL: <http://www.cnews.ru>, 16.08.2013.

УДК 338.27

С. А. Горбатков, доктор техн. наук, профессор, e-mail: sgorbatkov@mail.ru,
Финансовый университет при Правительстве РФ, Уфимский филиал, г. Уфа,
Л. И. Касимова, аспирант, клиентский менеджер, e-mail: liankakasimva@yandex.ru,
ОАО "Сбербанк России", Стерлитамакское отд., г. Стерлитамак

Нейросетевой итерационный метод построения динамических моделей вероятности риска банкротства при неполных данных

Предложен нейросетевой итерационный метод оценки вероятности развивающегося во времени риска банкротства экономических объектов применительно к сложным условиям моделирования (неполнота данных, их сильной зашумленности с неизвестным законом распределения шумов). Сделаны оценки сходимости метода для модели, полученной на реальных данных, на основе байесовского подхода к регуляризации модели.

Ключевые слова: диагностирование и прогнозирование банкротств, нейросеть, динамическая модель, логистическая трансформация вероятности