

ПРОГНОЗИРОВАНИЕ ТЕМПЕРАТУРНОГО ПОЛЯ ЗАМЕДЛИТЕЛЯ В ТЯЖЕЛОВОДНОМ РЕАКТОРЕ НА ОСНОВЕ КЛЕТОЧНОЙ НЕЙРОННОЙ СЕТИ

С.О. Старков*, Ю.Н. Лавренков**

** Обнинский институт атомной энергетики НИЯУ МИФИ*

249040, Калужская обл., г. Обнинск, Студгородок, д. 1

*** Калужский филиал МГТУ им. Н.Э. Баумана*

248000, г. Калуга, ул. Баженова, д. 2.



Реакторы, в которых тяжелая вода используется в качестве теплоносителя и замедлителя, получили широкое распространение в современной энергетике. Контроль состояния замедлителя играет важную роль в обеспечении нормальной работы энергетической установки. Предлагается применение клеточной нейронной сети, архитектура которой адаптирована для аппаратной реализации, в системе прогнозирования температуры тяжеловодного замедлителя. Формирование обучающей выборки и контроль правильности функционирования нейросетевой структуры осуществлялись с помощью модели реактора, скомпонованного в соответствии со структурой тяжеловодного реактора CANDU Darlington. В состав элементов выборки для настройки и конфигурирования топологии сети входят основные параметры, характеризующие процесс получения энергии в активной зоне. В статье рассматривается возможность выполнения температурного прогноза только по центральному сечению каландра. Для решения этой задачи спроектирована архитектура клеточной нейронной сети, а также разработаны основные составные части цифрового вычислительного элемента и методы их реализации на ПЛИС. Описывается способ организации оптической связи между отдельными нейронными модулями в составе сети, который обеспечивает не только возможность перестройки топологии в процессе обучения, но и распределение приоритетов распространения информационных сигналов нейронов в зависимости от активности при оценке ситуации на входе нейросетевой структуры. Применен способ асинхронной активации клеток, основанный на использовании фрактальной осциллирующей сети, базовый элемент которой выполнен на модифицированном кольцевом осцилляторе. Оценивается эффективность обучения предложенной архитектуры с помощью алгоритмов стохастического диффузионного поиска. Сравнительный анализ поведения модели и результатов работы нейронной сети показал, что применение нейросетевого подхода оказывается эффективным в системах обеспечения безопасности энергетических установок.

Ключевые слова: клеточные нейронные сети, реактор с тяжелой водой под давлением, фрактальная осциллирующая сеть, оптические нейроны, прогнозирование температурных полей, разогрев среды замедлителя нейтронов, стохастические алгоритмы обучения нейронных сетей.

ВВЕДЕНИЕ

Рассматривается применение клеточных нейронных сетей для прогнозирования температуры замедлителя в тяжеловодных реакторах. Поддержание оптимальной температуры замедлителя необходимо для предотвращения критических ситуаций, связанных с перегревом топливных каналов [1]. Измерение температурных параметров внутри рабочего реактора, необходимых для формирования обучающей выборки и проверки правильности получаемых расчетов, является сложной задачей, которая может быть решена с применением физической модели, имитирующей процессы тепловыделения, распределения энергии и отвода тепла по тем же принципам, что и в действующем реакторе [2]. В качестве источника тепловой энергии применялся металлооксидный резистор МО-200, нагревающий стальную трубку, которая является аналогом топливного канала реактора. В этом заключается главное отличие от действующего реактора – получение энергии, часть которой идет на разогрев замедлителя, происходит не в результате ядерной реакции, а с помощью нагрева резистивного элемента. Нагрев резисторов осуществлялся при помощи CCFL-инверторов, выполненных на микросхеме DF6109A и двойного транзистора МТ4606. Преимуществом такого способа получения тепловой энергии в модели является то, что способ построения инверторов подобного типа базируется на применении цепи обратной связи для контроля генерируемой мощности. При изменении сопротивления резистора с помощью последовательного с ним включения группы кенотронов 1Ц21П становится возможным изменять количество выделяемого тепла. Данная особенность позволяет учесть в модели процесс выгорания ядерного топлива в тепловыделяющих сборках.




Рис. 1. Сечение каландра, в 32-х точках которого производится измерение температуры

Модель комплектуется в соответствии с конструкцией реактора CANDU Darlington [3]. На основе наблюдения за работой модели формируются наборы векторов обучающей выборки, которые в дальнейшем применяются для обучения и настройки клеточной нейронной сети. Для упрощения процедуры построения нейросетевой системы прогноз температуры делается только по центральному диаметральному сечению реактора (рис. 1). Получить одновременно прогноз для нескольких сечений реактора возможно с применением параллельного комплекса предложенной клеточной нейросетевой вычислительной структуры. Входной вектор параметров формировался из следующих величин: температура теплоносителя на входе и выходе топливного канала, глубина выгорания топлива в ТВС, величина активности систем жидкого регулирования, положение регулиру-

ющих стержней. Измерение температуры по центральному сечению модели производится с помощью 32-х температурных датчиков DS18B20, показания которых являются желаемыми значениями для обучаемой нейронной сети.

ПРОЕКТИРОВАНИЕ НЕЙРОСЕТЕВОГО КОМПЛЕКСА ДЛЯ РАСЧЕТА ТЕМПЕРАТУРНЫХ ПОЛЕЙ

Клеточные нейронные сети относятся к информационным системам обработки сигналов, состоящим из большого количества простых вычислительных элементов (клеток) [4]. Способ организации локальных связей между элементами в такой структуре определяет развитие параллельного процесса решения вычислительной задачи (рис. 2).

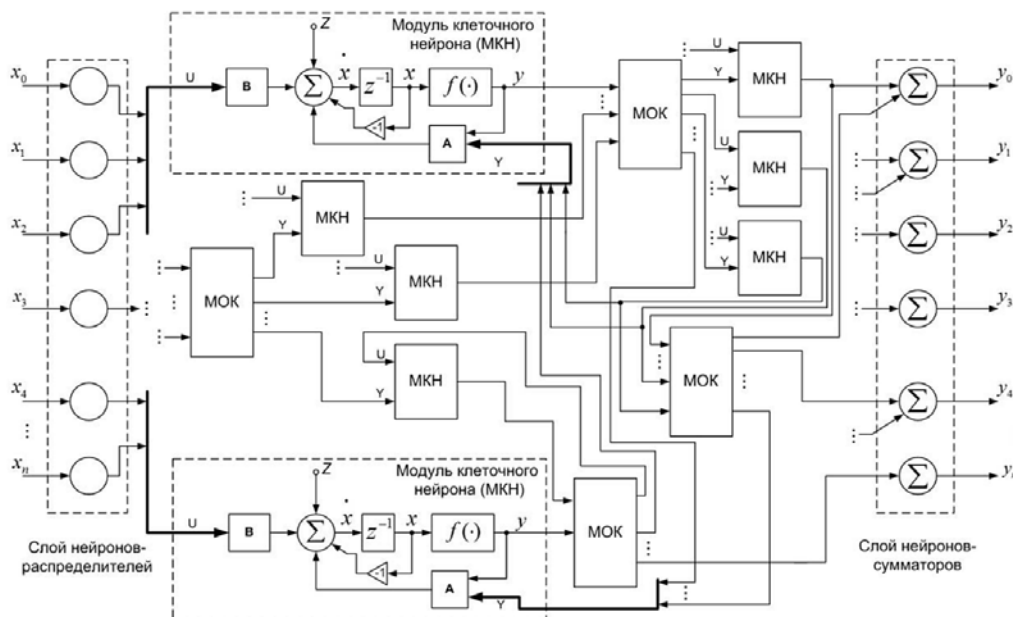


Рис. 2. Архитектура клеточной нейронной сети: МОК – модуль оптической коммутации

Ключевой проблемой при синтезе нейронных сетей подобного типа является не только организация топологии связей между нейронами, но и способ конструирования минимального процессорного элемента, обеспечивающего работу клеточного нейрона. Каждая клетка представляет собой развивающуюся во времени динамическую систему. Перед началом процедуры разработки клеточной архитектуры необходимо определить внутренние структуры и переменные параметры клеточного нейрона. В общем случае структура ячейки имеет много общего с искусственными нейронами, применяемыми для построения сетей прямого распространения. Динамика изменения внутреннего состояния описывается следующим выражением:

$$\dot{x} = -x + \sum_{h \in M} a_h y_h + \sum_{h \in M} b_h u_h + z, \quad (1)$$

где x – внутреннее текущее состояние ячейки; y_h – выходной сигнал, полученный от соседних нейронов в соответствии с топологией связей; z – пороговое значение; M – количество нейронов, с которыми клетка непосредственно соединена; u_h – входной сигнал; a_h, b_h – весовые коэффициенты, настраиваемые с помощью процедуры обучения и предназначенные для изменения входных и выходных сигналов соседних клеток, входящих в сферу влияния.

В качестве функции активации применяются нелинейные функции [5]. Как следует из выражения (1), нейрон способен воспринимать входные и выходные данные от яче-

ек, которые расположены непосредственно рядом с ним, а способ обмена информацией будет зависеть от организации топологии связей.

Устройство системы предполагает наличие в клеточном нейроне запоминающей структуры для хранения весовых коэффициентов и внутреннего состояния нейрона. Для реализации этой возможности предлагается использовать банк памяти из восьми микросхем последовательной памяти EEPROM 24LC512 [6]. Совокупный объем банка памяти будет равен $512\text{K} \times 8$, что обеспечивает возможность хранения $128\text{K} \times 32$ весовых коэффициентов и показателей внутреннего состояния нейрона. Такая архитектура памяти ячейки позволяет строить клеточные нейронные сети с развитой топологией связей, позволяющей выполнять конструирование 3D-сетей. Структура памяти обеспечивает возможность сохранения как положительных значений весовых коэффициентов (возбуждающие синапсы), так и отрицательных (тормозящие синапсы), что позволяет реализовывать полноценную возбуждающе-тормозящую динамику. Для обеспечения защищенности внутреннего состояния клетки в состав ячейки был введен зеркальный банк памяти, выполненный на микросхемах памяти EEPROM W27C512. Выбор именно этого типа микросхем обусловлен тем, что при эквивалентной информационной емкости у данного класса микросхем алгоритм записи информации существенно отличается от 24LC512. Информация в двух банках полностью дублируется, а ее целостность в каждом банке контролируется циклическим избыточным кодом CRC-32. Координация работы банков памяти и контроль целостности осуществляются с помощью микроконтроллера STM32F407VGT, архитектура которого имеет встроенный блок вычисления CRC. В случае преднамеренного или случайного разрушения информации в одном из банков производится процедура ее восстановления из другого. Повреждение двух банков приводит к исключению клеточного нейрона из всего процесса функционирования сети. Банк памяти имеет структуру, представленную на рис. 3.

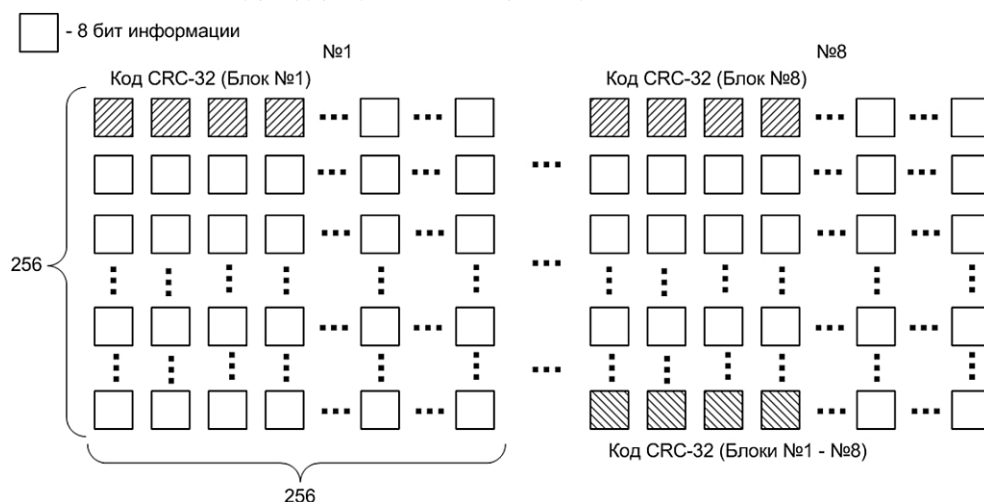


Рис. 3. Структура банка памяти

Основу вычислительного модуля нейрона составляет умножитель-сумматор, выполненный из четырех умножителей с двумя портами ввода данных и одного сумматора. Входные данные имеют разрядность 16 бит, а выходная шина данных – 34 бита. Вычислительные блоки нейронов реализованы на ПЛИС Cyclone III EP3C10E144C8. Выбор способа реализации цифрового блока нейрона обусловлен широкими возможностями определения разрядности данных, что делает возможным обработку данных большой размерности без потерь.

Конструкция клеточных нейросетевых элементов должна обладать возможностью воспринимать большое количество сигналов от нейронов, расположенных в сфере вли-

нения [7]. В качестве способа взаимодействия нейронов применялась перестраиваемая оптическая сеть (рис. 4).

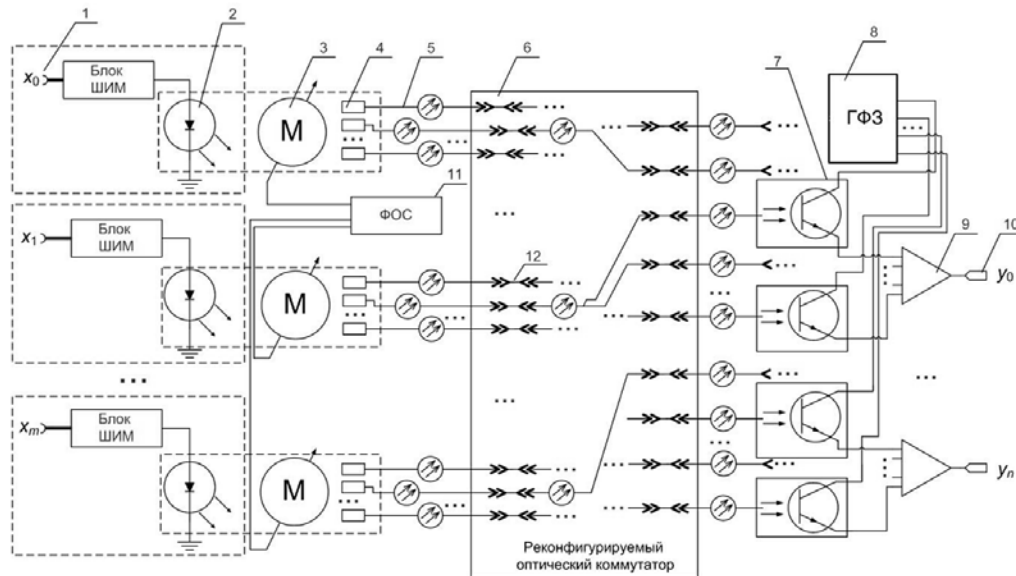


Рис. 4. Структура коммутационной системы клеточной сети: 1 – входные цифровые сигналы от соседних клеточных нейронов; 2 – лазерный диод; 3 – вращающееся многогранное зеркало, управляемое контроллером LB11870; 4 – вилка оптического соединителя; 5 – оптический кабель; 6 – группа оптических коммутаторов; 7 – фототранзистор L-7113P3C; 8 – генератор функциональной зависимости; 9 – интегратор-сумматор, реализованный на базе LM358; 10 – выходные сигналы нейронов; 11 – фрактальная опцирующая сеть; 12 – оптический соединитель

Выходной цифровой сигнал клеточной ячейки с помощью модуля широтно-импульсной модуляции (ШИМ), выполненный на базе микроконтроллера STM32F407VGT, управлял мощностью излучения лазерного диода. Искусственные входные рецепторы каждой ячейки были выполнены на базе фототранзистора L-7113P3C, применяемого в качестве аналогового перемножителя для функционального преобразования входных сигналов нейрона [8].

Для прогнозирования температуры замедлителя не требуется полноценное четырехквadrантное перемножение двух сигналов. Получаемая результирующая составляющая пригодна для дальнейшей обработки. Первым из двух перемножаемых сигналов является модулированный сигнал от лазерного диода, которым непосредственно облучается фототранзистор. Второй сигнал подается на коллектор фототранзистора, заданный в виде функциональной зависимости

$$f(x) = 1.3\sin(1.58\pi x) + 1.2(\cos(18.5\pi x))^3 + 1.1((\cos(8.5\pi x))^{1.5} + \sin(14.5\pi x))^2, \quad (2)$$

которая позволяет выделить приоритетные сигналы от соответствующих клеточных ячеек. Для изменения приоритета требуется изменение коэффициентов в (2), которые могут быть включены в стратегию обучения.

Для распределения светового потока от выходного лазерного диода в конструкции нейронного элемента применялось вращающееся многогранное зеркало, управление приводом которого осуществлялось с помощью контроллера LB11870. В отличие от оптических ответвителей, выполненных на основе линз или волноводов, данная конструкция позволяет регулировать размножение светового потока на основе изменения частоты вращения многогранного зеркала с помощью изменения частоты входного управляющего сигнала контроллера (УСК), что позволяет управлять активностью клеточных нейронов в сети. Взаимодействие нейронов происходит не только посредством

прямых связей с соседними элементами, но и за счет организации асинхронного функционирования нейронных элементов в каждом слое. Сигнал управления для LB11870 генерируется фрактальной осциллирующей сетью (ФОС). ФОС составлена из модулей модифицированного кольцевого осциллятора [8] (рис. 5). Каждый модуль находился в ветке фрактальной структуры – треугольнике Серпинского [9]. Фрактальная организация осциллятора делает возможным добавление новых модулей в уже существующую структуру без значительной перестройки внутренних связей. Теоретически, увеличение ФОС может производиться в широком диапазоне, ограниченном только физическими ограничениями ПЛИС, что дает широкие возможности для изменения выходных характеристик генерируемого сигнала.

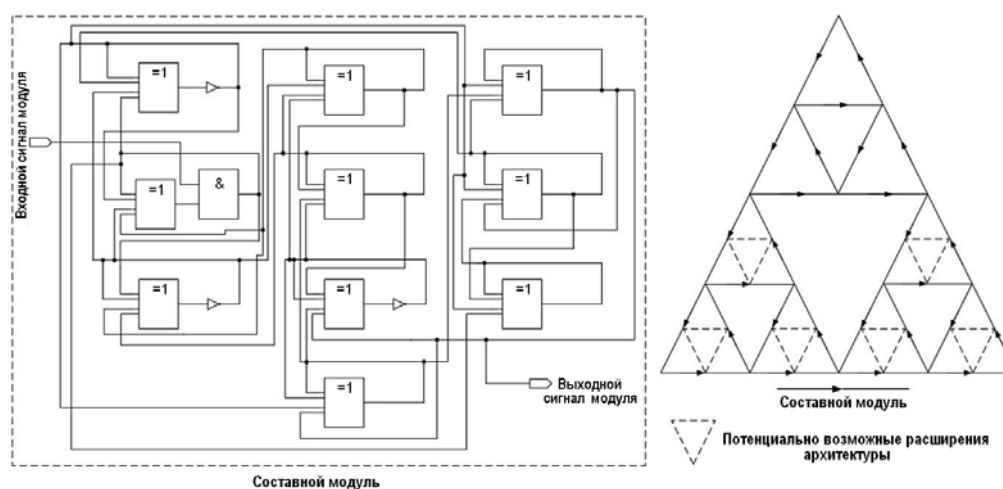


Рис. 5. Архитектура фрактальной осциллирующей сети

Пример выходного сигнала ФОС, регистрируемый с помощью цифрового осциллографа Hantek DS06022BE, показан на рис. 6а. Сигнал А – выход осциллирующей сети, сигнал В – это сигнал А, преобразованный с помощью D-триггера в бинарную последовательность. Полученные битовые комбинации задают частоту периодического сигнала, который является управляющим для контроллера LB11870. Процедура управления процессом активации клеточных ячеек осуществляется путем изменения во времени скорости вращения многогранного зеркала.

Каждый клеточный нейрон получал группу сигналов от непосредственных соседних элементов, входящих в его сферу влияния [10]. Интегратор-сумматор, выполненный на операционном усилителе LM358, осуществлял интегрирование совокупности сигналов с различными постоянными. Пример полученного аналогового сигнала, являющегося откликом всех нейронов-соседей, приведен на рис. 6б. Сигнал А – является выходом клеточного нейрона, у которого активность определялась УСК с частотой 10 кГц, а сигнал В – отклик нейрона при тех же условиях, но УСК имел частоту 230 Гц. Приведенные зависимости показывают, что при одинаковых условиях функционирования получены различные формы активности клеточных нейронов, наблюдаемые посредством изменения порядка активизации клеток в сети [11]. Клеточная сеть, в которой наблюдается данная особенность, способна одновременно хранить несколько возможных сценариев решения проблем, на которых происходило обучение. Применение скоростной оптической связи между нейронами, а также возможность изменения этих связей позволяют в процессе функционирования получать результат, являющийся гибридом нескольких возможных решений данной задачи.




Рис. 6. Выходные сигналы осциллирующей сети (а) и клеточных нейронов (б), полученные на осциллографе Hantek DS06022BE

Оптическая связь между элементами нейронной сети и переменные значения интегрирования интеграторов-сумматоров вводят в алгоритм обучения дополнительные параметры, управляющие передачей оптического сигнала между клеточными нейронами. Во время процедуры настройки и обучения нейронной сети также выполняется изменение топологии соседства между отдельными нейронными ячейками. Для реализации возможности управления оптической связью между элементами сигналы передаются с помощью оптических волокон, коммутируемых оптомеханическими переключателями.

КОНФИГУРИРОВАНИЕ И ОБУЧЕНИЕ КЛЕТочНОЙ НЕЙРОСЕТЕВОЙ СИСТЕМЫ

Первоначальная инициализация всех структур клетки осуществлялась случайными числами, генерируемыми фрактальной осциллирующей сетью. Поведением каждой нейронной ячейки управляет микроконтроллер STM32F407VGT, вычислительная мощность которого делает возможным не только выполнение операций, связанных с контролем целостности памяти ячейки, но и выполнение оптимизации параметров нейрона, настрой-

ку постоянных интегрирования в интеграторе-сумматоре нейронной ячейки, установке параметров оптомеханических переключателей для формирования топологии связей. При большом количестве оптимизируемых параметров для каждой ячейки требуется применение алгоритмов распределенной оптимизации, позволяющих с помощью локальных вычислителей каждого нейрона выполнить обучение всей нейронной сети [7, 12]. Рассмотрим модифицированный алгоритм стохастического диффузионного поиска для обучения предложенной нейросетевой системы.

1. Каждая ячейка представляется в роли агента популяции s_i , $i \in [1, \dots, S]$, S – количество нейронных ячеек в сети. Поскольку все параметры инициализированы случайным образом, то уже на этом этапе все агенты обладают начальной гипотезой, которая представляет лучшую совокупность переменных параметров для достижения цели обучения нейронной сети [13, 14]. Вычисляем значение функции пригодности $\varphi(s_i) = \varphi_i$ – общую для всех агентов ошибку обучения клеточной сети.

2. Каждый агент s_i проверяет свою гипотезу по оценке степени вклада ячейки в финальное результирующее решение. Степень вклада определяется процентом активности нейрона в течение периода активности нейронной сети. Если степень активности $s_i > \varphi_{\min}$ (φ_{\min} в данной работе 20%), то нейрон s_i считается активным.

3. Путем прямых контактов между агентами [15, 16], находящимися в одной сфере влияния, происходит обмен гипотезами (диффузия) и результатами их проверки.

а). Если нейрон s_i активен, то изменяем его гипотезу по следующему правилу:

$$s_{i,k} = s_{i,k} + \eta \alpha_k, \quad (3)$$

где $s_{i,k}$ – k -й оптимизируемый параметр s_i -го нейрона; η – свободный параметр, значение которого лежит в интервале (0;1); α_k – элемент случайного вектора направления перемещения решения в поисковом пространстве.

б). Если нейрон s_i неактивен, то выбираем из сферы влияния оптимизируемого агента активный нейрон s_j и производим замену гипотезы нейрона s_i на случайную гипотезу из некоторой окрестности нейрона s_j :

$$\begin{aligned} s_{i,k} &= x_k, \quad x^a \leq x_k \leq x^b, \\ x^a &= \max(s_{j,k} - \eta((s_{j,k}^+ - s_{j,k}^-) + (s_{i,k}^+ - s_{i,k}^-)), s_{i,k}^-), \\ x^b &= \min(s_{j,k} + \eta((s_{j,k}^+ - s_{j,k}^-) + (s_{i,k}^+ - s_{i,k}^-)), s_{i,k}^+), \end{aligned} \quad (4)$$

где $s_{j,k}^+$ – максимально допустимое значение параметра k нейрона j ; $s_{j,k}^-$ – минимально допустимое значение параметра k нейрона j .

4. Оценивая свою гипотезу по сравнению с другими, каждый агент формирует новое решение, тестирует его и производит обмен с соседями.

5. Процесс продолжается до получения удовлетворительной ошибки обучения.

Для реализации процедуры обучения применялся не один вычислительный блок, контролирующий оптимизацию всех параметров нейронной сети [17], а группа микроконтроллеров STM32F407VGT. Для повышения эффективности работы распределенного алгоритма обучения необходимо правильно выбрать топологию сети связи между вычислительными модулями. Поскольку информационные сигналы между нейронами образуют динамическую сеть связи, в которой возможно изменение топологии соседства каждой ячейки в процессе функционирования, то выбор способа для соединения микроконтроллеров является важным фактором эффективности работы системы [18]. Для организации информационного обмена использовалась топология неблокирующей Clos-сети с дуплексными каналами связи между микроконтроллерами [6].

Предложенный алгоритм обучения и архитектура вычислительной системы, на которой он реализуется, позволяют успешно выполнить процедуру настройки сети для решения поставленной задачи. Усредненная ошибка обучения показана на рис. 7.

Несмотря на то, что процесс обучения сопровождается значительными колебаниями значений квадратичной ошибки во времени, предложенный распределенный алгоритм

успешно выполняет конфигурацию клеточной сети для решения задачи прогнозирования температуры замедлителя.




Рис. 7. Усредненная кривая обучения

ОЦЕНКА РЕЗУЛЬТАТОВ ПРОГНОЗИРОВАНИЯ

Приведенная выше нейросетевая структура применялась для прогнозирования температуры замедлителя по объему центрального сечения реактора. Выполнение прогноза делает возможным оценивание колебаний температуры замедлителя. Значительные температурные колебания возникают в объемах, где возможны сильные турбулентные течения [1]. На рисунке 8 показаны температурные контуры, полученные для физической модели (слева) и температурный прогноз нейронной сети (справа) в различные моменты времени работы реакторной установки, а также температурная шкала (в градусах Цельсия).

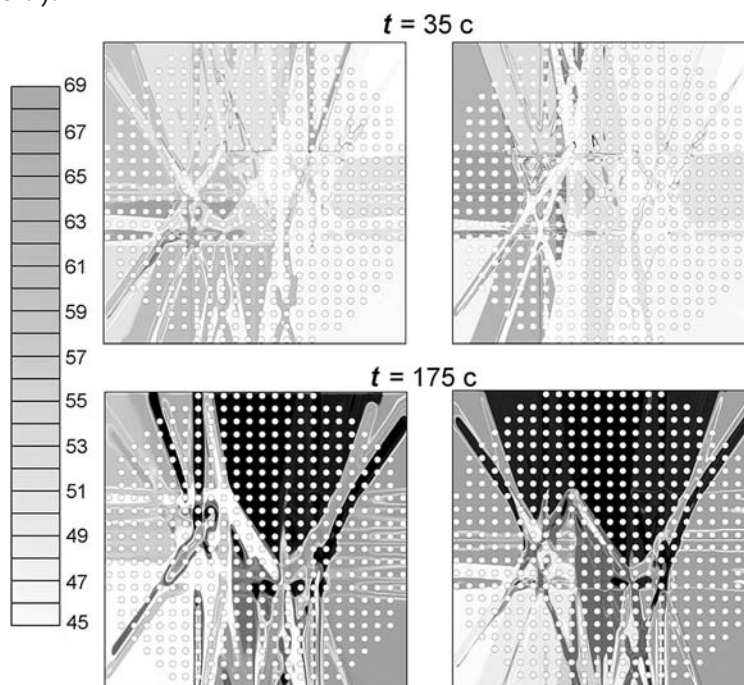


Рис. 8. Температурные контуры модели и результаты работы нейронной сети в различные моменты времени

Полученные результаты свидетельствуют об оптимальном выборе архитектуры нейросетевого комплекса для прогнозирования. Результаты могут быть использованы для

анализа температурных аномалий и мест их возникновения. Для построения подобной температурной карты в другом сечении реактора необходимо выполнить обучение клеточной сети на основе данных, соответствующих требуемой ситуации. Параллельное обучение комитета сетей, выполняющих прогноз по различным сечениям, позволит получить детальную картину распределения температуры замедлителя по объему реактора.

ЗАКЛЮЧЕНИЕ

Применение клеточных нейронных сетей для прогнозирования температуры замедлителя в определенных точках пространства реактора дает возможность выполнить оценку безопасности эксплуатации силовой установки без выполнения трудоемких экспериментов. Одновременная оценка 32-х точек в сечении модели реактора позволяет собрать информацию об изменении температуры замедлителя, которая происходит вследствие передачи тепла как от поверхности ТВС, так и от объемного нагревания. Оценка результатов работы нейронной сети и поведения модели показала, что клеточная сеть применима для оценки распределения температуры в различных сечениях реактора, что делает возможным выполнение анализа событий внутри каландра и оценку асимметричности нагрева объемов тяжелой воды. Выполнение анализа температурных колебаний в наблюдаемых точках, а также учет отклонения температуры от средних значений позволяют оценить направления движения и смешивания потоков замедлителя. Оценка температурных аномалий по всему объему реактора возможна с применением комитета разработанной клеточной структуры, что может стать основой для полноценного 3D-моделирования состояния замедлителя в каландре.

Литература

1. *Cacuci Dan Gabriel*. Handbook of Nuclear Engineering. Springer US, 2010. 3574 p. DOI: 10.1007/978-0-387-98149-9.
2. *Kok Kenneth D*. Nuclear Engineering Handbook. CRC Press, 2009. 786 p. DOI: 10.1201/9781420053913-p1.
3. The Essential CANDU, A Textbook on the CANDU Nuclear Power Plant Technology, Editor-in-Chief Wm. J. Garland, University Network of Excellence in Nuclear Engineering (UNENE), ISBN 0-9730040.
4. *Chua Leon O., Roska Tamas*. Cellular neural networks and visual computing: foundations and applications. Cambridge University Press New York, NY, USA, 2002. 396 p.
5. *Васильев А.Н., Тархов Д.А.* Принципы и техника нейросетевого моделирования. – СПб.: Нестор-История, 2014. – 218 с.
6. *Шустов М.А.* Схемотехника. 500 устройств на аналоговых микросхемах. – СПб.: Наука и техника, 2013. – 352 с.
7. *Rabunal Juan R., Dorado Julian*. Artificial Neural Networks in Real-Life Applications. IGI Global, 2005. 394 p. DOI: 10.4018/978-1-59140-902-1.
8. *Крекрафт Д., Джерджи С.* Аналоговая электроника. Схемы, системы, обработка сигнала. – М.: Техносфера, 2005 – 360 с.
9. *Дорогов А.Ю.* Теория и проектирование быстрых перестраиваемых преобразований и слабосвязанных нейронных сетей. – СПб.: Политехника, 2014. – 328 с.
10. *Хайкин С.* Нейронные сети: полный курс. – М.: Издательский дом «Вильямс», 2008. – 1104 с.
11. *Кащенко С.А., Майоров В.В.* Модели волновой памяти. – М.: Книжный дом «ЛИБРОКОМ», 2014. – 288 с.
12. *Graupe Daniel*. Principles of Artificial Neural Networks (Advanced Series in Circuits and Systems), 2-nd Edition, World Scientific Pub Co Inc, 2007. 238 p.
13. *Джон Н., Роберт М., Брюс В., Пол Ф.* От нейрона к мозгу. – М.: Едиториал УРСС, 2003. – 672 с.
14. *Барский А. Б.* Логические нейронные сети: учебное пособие. – М.: Интернет-универ-

ситет информационных технологий; БИНОМ. Лаборатория знаний, 2012. – 352 с.

15. *Осовский С.* Нейронные сети для обработки информации. – М.: Финансы и статистика, 2002. – 344 с.

16. *Madan M. Gupta, Liang Jin, and Noriyasu Homma.* Static and Dynamic Neural Networks: From Fundamentals to Advanced Theory. ISBN: 978-0-471-21948-4, 752 pages, April 2003, Wiley-IEEE Press.

17. *Терехов В. А.* Нейросетевые системы управления: учеб. пособие для вузов/В.А. Терехов, Д.В. Ефимов, И.Ю. Тюкин. – М.: Высш. шк. 2002. – 183 с.

18. *Грешилов А. А.* Математические методы принятия решений: учеб. пособие (с расчётными программами на оптическом диске). – М.: Изд-во МГТУ им. Н. Э. Баумана, 2014. – 647 с.

Поступила в редакцию 18.11.2016 г.

Авторы

Старков Сергей Олегович, профессор, доктор физ.-мат. наук

E-mail: sergeystarkov56@mail.ru

Лавренков Юрий Николаевич, кандидат техн. наук

E-mail: georglawr@yandex.ru

UDC 621.039.517.3

PREDICTION OF TEMPERATURE FIELD OF MODERATOR OF HEAVY-WATER REACTOR BASED ON CELLULAR NEURAL NETWORK

Starkov S.O.*, Lavrenkov Y.N.**

* Obninsk Institute for Nuclear Power Engineering,

National Research Nuclear University «MEPhI»

1 Studgorook, Obninsk, Kaluga reg., 249040 Russia

** Kaluga Branch of the Bauman Moscow State Technical University

2 Bazhenova str., Kaluga, Kaluga reg., 248000 Russia

ABSTRACT

Calculation of 2D temperature fields in structural elements of installations with internal sources of heat is the necessary condition required for maintaining their safe operation. Methodology is suggested for forecasting moderator temperature in heavy-water reactors with application of cellular neural network. Application of intellectual computational structure allows simplifying the procedure of calculation of moderator temperature in different cross-sections of calandria heating of which is achieved both directly from the surfaces of fuel channels and, as well, as the result of volume heating. The difficulty to apply numerical methods is explained by the computational difficulty of determination of temperature gradients and heat fluxes along the fuel channel, as well as by the complex geometry of fuel assemblies. Neural network modeling facilitates removing potential critical situations by implementing the control of variation of temperature fields during transients, emergency situations and in the estimation of thermal stresses. Application of the technique of cellular neural networks is justified by the specific features of the architecture allowing targeted limitation of communications between neurons. Specific features of cellular networks correspond to the principles of quick tunable transformations which can be efficiently realized on hardware level. Reduction of the number of synoptical communications increases computational efficiency and makes it possible to use this class of networks

for processing the high dimensionality data. Structural synthesis of cellular network with optical communications between neurons possessing high efficiency of data processing is examined. The suggested type of communications constitutes the basis for realization of modular intellectual structures consisting of homogeneous fragments. Training the neural network is accomplished using methods of local training with elements of co-evolutional interaction. Presence of powerful 32-bit microcontroller in each neural core justifies the above strategy despite associated high memory requirements. The suggested modular organization efficiently combines local training of neural cores with global training of the whole network. Comparison of results of forecasting with behavior of the reactor model demonstrated the efficiency of reconstructive analysis of complex systems with application of reconfigurable cellular neural networks, structure of which can be optimized for the specific calculational task. Modularity of the structure allows simultaneously constructing large number of networks on the same electronic chip which makes it possible to forecast moderator temperature fields in different sections of calandria and constitutes the basis for constructing 3D models.

Key words: cellular neural networks, heavy water reactor, oscillating fractal network, optical neurons, forecasting temperature fields, the heating medium neutron moderator, stochastic algorithms for neural networks training.

REFERENCES

1. Cacuci Dan Gabriel. Handbook of Nuclear Engineering. Springer US, 2010. 3574 p. DOI: 10.1007/978-0-387-98149-9.
2. Kenneth D Kok. Nuclear Engineering Handbook. CRC Press, 2009. 786 p. DOI: 10.1201/9781420053913-p1.
3. The Essential CANDU, A Textbook on the CANDU Nuclear Power Plant Technology, Editor-in-Chief Wm. J. Garland, University Network of Excellence in Nuclear Engineering (UNENE), ISBN 0-9730040.
4. Leon O. Chua, Tamas Roska. Cellular neural networks and visual computing: foundations and applications. Cambridge University Press New York, NY, USA, 2002. 396 p.
5. Vasiliev A.N., Tarkhov D.A. Principy i tekhnika nejrosetevogo modelirovaniya [Principles and techniques of neural network modeling]. Saint Petersburg. Nestor-Istoriya Publ., 2014. 218 p. (in Russian).
6. Shustov M.A. Skhemotekhnika. 500 ustrojstv na analogovykh mikroskhemakh [Circuitry. 500 analog circuits devices]. Saint Petersburg. Nauka i Tekhnika Publ., 2013. 352 p. (in Russian).
7. Juan R. Rabunal, Julian Dorado. Artificial Neural Networks in Real-Life Applications. IGI Global, 2005. 394 p. DOI: 10.4018/978-1-59140-902-1.
8. David Crecraft, Stephen Gergely. Analog Electronics: Circuits, Systems and Signal Processing. 1st Edition. Butterworth-Heinemann, 2002. 425 p.
9. Dorogov A.Yu. Teoriya i proektirovanie bystrykh perestraivaemykh preobrazovanij i slabosvyazannykh nejronnykh setej [Theory and Design of quick tunable transformations and loosely coupled neural networks]. Saint Petersburg. Politehnika Publ., 2014. 328 p. (in Russian).
10. Simon Haykin. Neural networks. A Comprehensive Foundation. Second Edition. Prentice Hall, Inc., 1999. 1104 p.
11. Kashchenko S.A., Maiorov V.V. Modeli volnovoj pamyati [Wave memory models]. Moscow. Knizhnyi dom «LIBROKOM» Publ., 2014. 288 p. (in Russian).
12. Graupe Daniel. Principles of Artificial Neural Networks (Advanced Series in Circuits and Systems), 2-nd Edition, World Scientific Pub Co Inc, 2007. 238 p.
13. Nicholls John G., Martin A. Robert, Fuchs Paul A., Brown David A., Diamond Mathew E.,

Weisblat David. From Neuron to Brain, Fifth Edition. Sinauer Associates, Inc., 2011. 621 p.

14. Barsky A.B. Logicheskie nejronnye seti: uchebnoe posobie [Logical neural networks: schoolbook]. Moscow. Internet-Universitet Informatsionnykh Tekhnologiy; BINOM, Laboratoriya znaniy Publ., 2012. 352 p. (in Russian).

15. Osovsky S. Nejronnye seti dlya obrabotki informacii [Neural network for information processing]. Moscow. Finansy i statistika Publ., 2002. 344 p. (in Russian).

16. Madan M. Gupta, Liang Jin, and Noriyasu Homma. Static and Dynamic Neural Networks: From Fundamentals to Advanced Theory. ISBN: 978-0-471-21948-4, 752 pages, April 2003, Wiley-IEEE Press.

17. Terekhov V.A. Nejrosetevye sistemy upravleniya: uchebnoe posobie dlya vuzov [Neural network control systems: textbook for high schools]. Moscow. Vysshaya shkola Publ., 2002. 183 p. (in Russian).

18. Greshilov A.A. Matematicheskie metody prinyatiya reshenij: uchebnoe posobie s raschyotnymi programmami na opticheskom diske [Mathematical methods of decision-making: schoolbook. 2-nd iss., with modifications and amendments]. Moscow. MGTU im. N.E. Bauman Publ., 2014. 647 p. (in Russian).

Authors

Starkov Sergej Olegovich, Professor, Dr. Sci. (Phys.-Math.)

E-mail: sergeystarkov56@mail.ru

Lavrenkov Yuri Nikolaevich, Cand. Sci. (Engineering)

E-mail: georglawr@yandex.ru