

ЭКСПЕРИМЕНТАЛЬНОЕ ИССЛЕДОВАНИЕ МЕТОДА СИНТЕЗА НЕЙРО-НЕЧЕТКИХ МОДЕЛЕЙ В ПАРАЛЛЕЛЬНОЙ КОМПЬЮТЕРНОЙ СИСТЕМЕ

Решена задача разработки нелинейной модели, описывающей зависимости между характеристиками системы, в которой осуществляется синтез нейро-нечетких сетей, параметрами исследуемого метода и временем, затраченным системой на выполнение синтеза моделей. Объект исследования – процесс синтеза нейро-нечетких моделей для индивидуального прогнозирования состояния больного гипертонической болезнью. Предметом исследования является параллельная компьютерная система, выполняющая метод синтеза нейро-нечетких сетей. Цель работы заключается в повышении эффективности применения параллельных компьютерных систем для решения задач медицинского направления. Предложена нелинейная модель, позволяющая прогнозировать затраченное параллельной системой время на выполнение метода синтеза нейро-нечетких сетей и, таким образом, осуществлять рациональный выбор ресурсов компьютерной системы. Разработано программное обеспечение, которое реализует предложенную модель. Выполнены эксперименты, подтверждающие адекватность предложенной модели. Результаты экспериментов позволяют рекомендовать применение разработанной модели на практике.

Ключевые слова: синтез модели, параллельная система, планирование ресурсов, нейронная сеть, среднеквадратичная ошибка.

НОМЕНКЛАТУРА

CPU – Central Processing Unit;

GPU – Graphical Processing Unit;

G – критерий качества сети;

N_χ – число возможных решений на этапе инициализации метода;

$R^{(i)}$ – множество решений на i -й итерации метода;

$G^{(i)}$ – множество значений целевой функции для решений $\chi_k^{(i)}$ на i -й итерации метода;

$R^{(i,j)}$ – j -е подмножество множества $R^{(i)}$;

$\chi_k^{(i)}$ – k -е решение во множестве $R^{(i)}$;

$G_k^{(i)}$ – значение целевой функции k -го решения множества $R^{(i)}$;

D – обучающая выборка;

X – множество входных признаков, описывающих время выполнения метода синтеза нейро-нечетких сетей в параллельной системе;

x_i – множество значений i -го признака в обучающей выборке D ;

x_{ij} – значение i -го признака для j -го экземпляра, соответствующее значению i -й характеристики j -го эксперимента;

N – количество экземпляров в выборке D ;

Y – множество значений выходного параметра;

x_1 – тип системы (0 – кластер CPU, 1 – GPU);

x_2 – число процессов, на которых выполняется метод;

x_3 – пропускная способность сети параллельной системы, Гб/с;

x_4 – число возможных решений, с которыми работает метод;

y – время, затраченное системой на синтез нейро-нечеткой сети, с;

x_{jn} – нормированное значение i -го признака j -го экземпляра;

x_{\min} и x_{\max} – соответственно, минимальное и максимальное значения i -го признака в обучающей выборке D ;

φ – аргумент функции активации, представляющий собой дискриминантную функцию;

w – матрица весовых коэффициентов;

x – множество аргументов дискриминантной функции;

w_0 – значение смещения функции $\varphi(w;x)$

$|x|$ – количество аргументов функции $\varphi(w;x)$

$\Psi_{(\mu,\rho)}$ – функция активации ρ -го нейрона μ -го слоя

$\Phi_{(\mu,\rho)}$ – дискриминантная функция ρ -го нейрона μ -го слоя.

ВВЕДЕНИЕ

Артериальная гипертония является распространенным заболеванием в Украине и в мире. При этом широкой причиной смертности является несвоевременное выявление заболевания, особенно среди жителей сельской местности [1]. Для предотвращения опасных последствий важно своевременно выявлять и прогнозировать развитие гипертонии для каждого пациента. Такое прогнозирование успешно выполняется при помощи соответствующих нейро-нечетких моделей [2–4].

Для учета динамики изменения состояния здоровья пациента необходимо с течением времени синтезировать новые модели на основе увеличения выборки наблюдений за показателями заболевания. Это требует больших затрат временных и вычислительных ресурсов. Поэтому в данной сфере нашли применение методы параллельных вычислений [5], которые реализуются при помощи кластеров вычислительных узлов [6] и графических процессоров CUDA [7]. Поскольку использование кластерных ресурсов является дорогостоящим, то важно рационально планировать выбор вычислительных ресурсов для достижения желаемой производительности.

Целью данной работы является повышение эффективности применения параллельных компьютерных систем

для синтеза нейро-нечетких сетей и решения задачи индивидуального прогнозирования состояния больного гипертонической болезнью.

1 ПОСТАНОВКА ЗАДАЧИ

Рассмотрим метод синтеза нейро-нечетких сетей для прогнозирования состояния больного гипертонической болезнью [2]. Пусть имеем выборку $D = \langle X, Y \rangle$ данных о состоянии здоровья пациентов, полученную в г. Запорожье. Задача синтеза нейро-нечеткой модели заключается в идентификации ее параметров таким образом, чтобы обеспечивалось приемлемое значение критерия качества G , например, значения среднеквадратичной ошибки. На рис. 1 показан граф параметрического синтеза нейро-нечетких моделей в ярусно-параллельной форме [2]. Как видно, процесс параметрического синте-

за нейро-нечетких моделей начинается с этапа инициализации, на котором создается начальное множество решений $R^{(0)} = \{\chi_1^{(0)}, \chi_2^{(0)}, \dots, \chi_{N_{\chi}}^{(0)}\}$, затем это множество разбивается на подмножества $R^{(0,j)}$, каждое из которых оценивается на отдельном процессе параллельной системы. В ходе работы метода поиск решений происходит с помощью стохастического подхода, используя операторы отбора, скрещивания и мутации. При этом элементы подмножества $R^{(i,j)}$ обрабатываются на j -м процессе параллельной системы. Каждая итерация случайного поиска $RS(R^{(i)})$, продемонстрированная в виде графа на рис. 2 [2], требует существенных вычислительных затрат и поэтому распараллеливается по процессам компьютерной системы. Основным параметром метода, влияющим на скорость работы, является количество итераций.

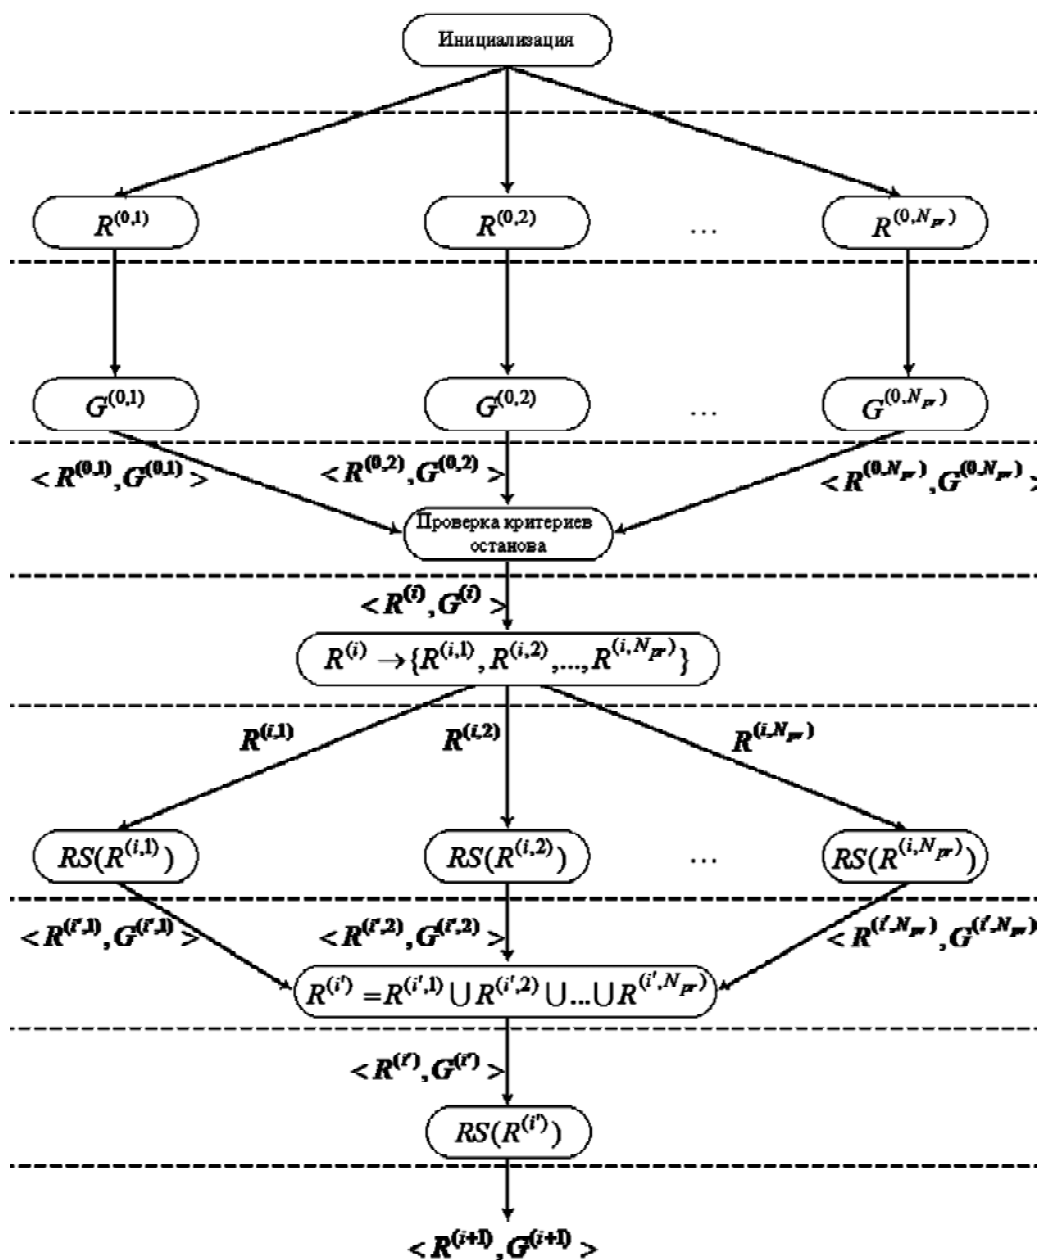


Рисунок 1 – Граф параметрического синтеза нейро-нечетких моделей в ярусно-параллельной форме




Рисунок 2 – Граф одной итерации случайного поиска

яющим как на точность синтезированных моделей, так и на время, затрачиваемое параллельной системой на выполнение метода, является число возможных решений N_{χ} на этапе инициализации метода. Чем больше значение N_{χ} , тем больше вычислительного времени требуется системе, но и тем выше точность синтезированных системой моделей.

В данной работе ставится задача экспериментально исследовать рассмотренный метод в параллельной компьютерной системе и разработать нелинейную модель, описывающую зависимости между характеристиками системы, в которой осуществляется синтез нейро-нечетких сетей, а так же параметрами исследуемого метода и временем, затраченным системой на выполнение синтеза моделей. Это позволит рассчитывать время, необходимое компьютерной системе для индивидуального прогнозирования состояния больного гипертонической болезнью, и таким образом, рационально планировать выбор ресурсов компьютерной системы для достижения желаемой производительности.

2 ОБЗОР ЛИТЕРАТУРЫ

Планирование ресурсов компьютерных систем выполняется на основе специфики параметров решаемых задач и характеристик компьютерных систем. Основным мето-

дом, при помощи которого можно выполнить такое планирование, является моделирование поведения компьютерной системы в решении определенной задачи [8–10].

Методы регрессионного и имитационного моделирования позволяют с приемлемой точностью строить модели планирования ресурсов компьютерных систем, в которых между параметрами такой модели существует хорошая линейная корреляционная зависимость [11]. При отсутствии такой зависимости существенно снижается точность модели, поэтому предпочтительнее применять метод нейросетевого моделирования [12], позволяющий описать нелинейные зависимости между характеристиками компьютерной системы, параметрами задачи, решаемой в такой системе, и временем, затраченным на решение задачи.

Известный инструментарий GridSim [13], применяемый для моделирования поведения компьютерных систем, в процессе построения модели требует ввести оценочные значения временных затрат на выполнения каждого элемента решаемой задачи. В задаче индивидуального прогнозирования состояния больного гипертонической болезнью такие значения отсутствуют для отдельно взятой компьютерной системы, поэтому в данной работе разработано собственное программное обеспечение, на основе которого применен метод нейросетевого моделирования.

3 МАТЕРИАЛЫ И МЕТОДЫ

Основными характеристиками параллельной системы, влияющими на время выполнения метода синтеза нейро-нечетких сетей, являются тип системы (кластер CPU или GPU), число процессов, на которых выполняется задача, и пропускная способность сети. Число возможных решений N_χ как параметр исследуемого метода так же оказывает существенное влияние на затраченное системой время. Рассмотренный метод был применен на кластере CPU и на GPU, в результате чего была сформирована обучающая выборка (1), содержащая, 174 результата выполнения метода, каждый из которых характеризовался четырьмя признаками:

$$D = \langle X, Y \rangle, \quad (1)$$

где $X = \{x_1, x_2, x_3, x_4\}$, $x_i = \{x_{i1}, x_{i2}, \dots, x_{iN}\}$, $N=174$, $Y = \{y_1, y_2, \dots, y_N\}$.

В результате обучающая выборка представляла собой таблицу чисел, состоящую из 174 строк и пяти столбцов, содержащих значения четырех входных признаков и одного выходного для каждого случая применения рассмотренного метода в параллельной системе. Фрагмент обучающей выборки приведен в табл. 1.

Для исключения влияния различного порядка значений признаков на синтезируемую модель выполнялось нормирование признаков, т.е. приведение диапазона их значений к единому интервалу $x_{in} \in [0;1]$ по формуле (2):

$$x_{ijn} = \frac{x_{ij} - x_{i \min}}{x_{i \max} - x_{i \min}}, \quad (2)$$

где $i = \overline{1;4}$, $j = \overline{1;174}$.

Моделирование решения задачи индивидуального прогнозирования состояния больного гипертонической болезнью в параллельной системе осуществлялось на основе построенной обучающей выборки с помощью трехслойного персептрона [14, 15], первый слой которого содержал четыре нейрона, второй слой – три нейрона, третий слой – один нейрон. Все нейроны имели сигмоидную функцию активации (3):

$$\psi(\varphi) = \frac{1}{1 + e^{-\varphi}}, \quad (3)$$

где $\varphi = \varphi(w; x)$.

Таблица 1 – Фрагмент обучающей выборки

Номер эксперимента	Значения признаков				Y
	x_1	x_2	x_3	x_4	
1	0	1	20	50	101,18
2	0	2	20	50	57,67
3	0	3	20	50	40,02
4	0	4	20	50	30,61
5	0	5	20	50	26,23
6	0	6	20	50	23,17
7	0	7	20	50	21,09
8	0	8	20	50	18,09
9	0	9	20	50	16,84
10	0	10	20	50	15,79
...
174	1	260	64	100	62,81

При синтезе нейромодели в качестве дискриминантной функции [16] использовалась взвешенная сумма (4):

$$\varphi(w; x) = w_0 + \sum_{i=1}^{|x|} w_i x_i, \quad (4)$$

где w_i определяет вес i -го входного параметра x_i в функции $\varphi(w; x)$.

Таким образом, структура синтезируемой трехслойной нейромодели Y_{NN} может быть представлена следующим образом (5):

$$\begin{cases} Y_{NN} = \psi_{(3,1)}(\varphi_{(3,1)}(w_{(3,1)}; \psi_{(2)})); \\ \psi_{(2)} = \{\psi_{(2,1)}; \psi_{(2,2)}; \psi_{(2,3)}\}; \\ \psi_{(2,k)} = \psi_{(2,k)}(\varphi_{(2,k)}(w_{(2,k)}; \psi_{(1)})), k = 1,2,3; \\ \psi_{(1)} = \{\psi_{(1,1)}; \psi_{(1,2)}; \psi_{(1,3)}; \psi_{(1,4)}\}; \\ \psi_{(1,l)} = \psi_{(1,l)}(\varphi_{(1,l)}(w_{(1,l)}; X)), l = 1,2,3,4. \end{cases} \quad (5)$$

Для построения нейромодели и определения значений ее параметров (весовых коэффициентов и смещений каждого нейрона) на ее входы подавались значения пронормированных признаков, на выход – значение времени выполнения метода синтеза нейро-нечетких сетей в параллельной системе. В качестве целевой функции при обучении нейромодели использовался минимум среднеквадратичной ошибки.

Обучение нейронной сети выполнялось на основе метода обратного распространения ошибки [17]. Приемлемым считалось достижение среднеквадратичной ошибки, не превышающей 10^{-4} . Фрагмент матрицы весовых коэффициентов w построенной модели приведен в табл. 2.

После подстановки значений весовых коэффициентов и смещений в (5) с учетом функции активации (3) и дискриминантной функции (4) получаем математическое описание синтезированной нейросетевой модели (6), описывающей зависимости между характеристиками системы, в которой осуществляется синтез нейро-нечетких сетей, параметрами исследуемого метода и временем, затраченным системой на выполнение синтеза сетей. Графическая интерпретация синтезированной нейромодели приведена на рис. 3.

$$\begin{cases} Y_{NN} = \psi_{(3,1)} \left(1 + e^{-(-2,873 + 5,42\psi_{(2,1)} - 10,94\psi_{(2,2)} + 28,35\psi_{(2,3)})} \right)^{-1}; \\ \psi_{(2,1)} = \left(1 + e^{-(-8,65 - 5,2\psi_{(1,1)} - 4,17\psi_{(1,2)} - 4,95\psi_{(1,3)} - 1,74\psi_{(1,4)})} \right)^{-1}; \\ \psi_{(2,2)} = \left(1 + e^{-(-0,43 - 3,63\psi_{(1,1)} + 1,57\psi_{(1,2)} - 4,44\psi_{(1,3)} - 2,46\psi_{(1,4)})} \right)^{-1}; \\ \psi_{(2,3)} = \left(1 + e^{-(-5,37 - 9,56\psi_{(1,1)} - 24,6\psi_{(1,2)} + 2,94\psi_{(1,3)} + 33,79\psi_{(1,4)})} \right)^{-1}; \\ \psi_{(1,1)} = \left(1 + e^{-(-2,38 + 7,7x_1 - 5,1x_2 + 2,2x_3 - 6,85x_4)} \right)^{-1}; \\ \psi_{(1,2)} = \left(1 + e^{-(-6,22 - 5,06x_1 + 22,21x_2 + 18,14x_3 + 6,49x_4)} \right)^{-1}; \\ \psi_{(1,3)} = \left(1 + e^{-(-10,35 - 0,07x_1 + 11,12x_2 - 1,84x_3 + 9,29x_4)} \right)^{-1}; \\ \psi_{(1,4)} = \left(1 + e^{-(-2,07 + 5,13x_1 - 35,66x_2 + 4,49x_3 + 2,06x_4)} \right)^{-1}. \end{cases} \quad (6)$$

Таблица 2 – Фрагмент матрицы весовых коэффициентов w

Номер слоя, μ	Номер нейрона в слое, ρ	Значение смещения w_0	Связи (соединения)	
			узел, от которого идет соединение	значение весового коэффициента
1	1	-2,38	признак x_1	7,7
			признак x_2	-5,1
			признак x_3	2,2
			признак x_4	-6,85
	2	-6,22	признак x_1	-5,06
			признак x_2	22,21
			признак x_3	18,14
			признак x_4	6,49
	3	-10,35	признак x_1	-0,07
			признак x_2	11,12
			признак x_3	-1,84
			признак x_4	9,29
	4	-2,07	признак x_1	5,13
			признак x_2	-35,66
			признак x_3	4,49
			признак x_4	2,06
...
3	1	-2,873	нейрон (2, 1)	5,54
			нейрон (2, 2)	-10,94
			нейрон (2, 3)	28,35




Рисунок 3 – Синтезированная нейросетевая модель

Таким образом, построенная нейросетевая модель представляет собой иерархическую структуру, содержащую нейроны, и позволяет рассчитывать время, необходимое компьютерной системе для индивидуального прогнозирования состояния больного гипертонической болезнью. При этом значение среднеквадратичной ошибки модели составило $2,95 \cdot 10^{-5}$, что является приемлемым для подобного рода задач, решаемых при помощи синтезированной модели.

4 ЭКСПЕРИМЕНТЫ

Для выполнения экспериментального исследования рассмотренного метода и предложенной нейросетевой модели использованы следующие компьютерные системы:

- кластер Института проблем моделирования в энергетике имени Г.Е. Пухова НАН Украины (ИПМЭ) г. Киев: процессоры Intel Xeon 5405, оперативная память – 4×2 Гб DDR-2 на каждый узел, коммуникационная среда InfiniBand 20Гб/с, middleware Torque и OMPI;

- кластер Запорожского национального технического университета (ЗНТУ) г. Запорожье: процессоры Intel E3200, оперативная память 1 Гб DDR-2 на каждый узел, коммуникационная среда Gigabit Ethernet 1 Гб/с, middleware Torque и MPICH;

- GPU NVIDIA GTX 285+ 240 ядер CUDA;
- GPU NVIDIA GTX 960 1024 ядра CUDA.

В экспериментах число процессов x_2 , на которых выполнялся метод, варьировалось от 1 до 32 для кластеров и от 60 до 260 для GPU. Пропускная способность сети x_3 – от 1 до 20 Гб/с, число возможных решений на этапе инициализации метода N_χ – от 50 до 100. Для проведения экспериментов было разработано программное обеспечение на языке Си с применением библиотеки MPI [18].

5 РЕЗУЛЬТАТЫ

Результаты экспериментов на кластерах ЗНТУ ($N_\chi=50$) и ИПМЭ ($N_\chi=100$) приведены на рис. 4 и рис. 5, соответственно. Рис. 6 демонстрирует экспериментальную проверку предложенной модели на GPU NVIDIA GTX 285+, при этом $N_\chi=50$. Рис. 7 демонстрирует результаты экспериментов на GPU NVIDIA GTX 960 с $N_\chi=100$. Сплошной линией показано время, фактически затраченное системой на выполнение метода синтеза нейро-нечетких сетей, а пунктирной линией – расчетное время при помощи предложенной модели.

6 ОБСУЖДЕНИЕ

Тестовая выборка, состоящая из результатов 53х экспериментов, включала экземпляры решений задачи в параллельной системе, не входящие в обучающую выборку. При проведении экспериментов на более производительном оборудовании число возможных решений задавалось $N_\chi=100$, а на более слабом – $N_\chi=50$. Это было сделано для соблюдения адекватности сложности решаемых задач используемым ресурсам.

Как видно из рис. 4–7, время решения задачи на кластере и на GPU, рассчитанное при помощи предложенной модели, почти всегда несколько меньше, чем фактическое время. Это можно объяснить тем, что время, затраченное на синхронизацию и на пересылки данных между процессами кластера и между потоками GPU, значительно варьируется в зависимости от применяемой среды передачи данных и от числа возможных решений N_χ на этапе инициализации рассмотренного метода. При этом, чем больше задействовано процессов кластера или потоков GPU, тем существеннее влияние синхронизаций и пересылок и тем больше отклонение между фактическим и предсказанным временем решения задачи.




Рисунок 4 – Результаты экспериментов на кластере ИПМЭ ($N_{\chi}=100$)




Рисунок 5 – Результаты экспериментов на кластере ЗНТУ ($N_{\chi}=50$)




Рисунок 6 – Результаты экспериментов на GPU NVIDIA GTX 960 ($N_{\chi}=100$)




Рисунок 7 – Результати експериментів на GPU NVIDIA GTX 285+ ($N_{\chi}=50$)

Значення середньоквадратичної помилки на тестовій вибірці складало $7,61 \times 10^{-4}$, що на порядок краще, ніж на навчаючій вибірці, але залишається в межах прийнятних значень і дозволяє рекомендувати запропоновану модель на практиці для раціонального вибору ресурсів комп'ютерної системи в розв'язанні задачі індивідуального прогнозування стану великої гіпертонічної хвороби.

ВИВОДИ

В роботі підвищена ефективність застосування паралельних комп'ютерних систем для синтезу нейро-нечітких мереж і розв'язання задачі індивідуального прогнозування стану великої гіпертонічної хвороби.

Наукова новизна полягає в тому, що запропонована нейро-мережева модель, яка враховує тип комп'ютерної системи, кількість процесорів, на яких виконується задача, пропускну здатність мережі передачі даних і кількість можливих рішень на етапі ініціалізації методу. Модель дає можливість прогнозувати витрачене паралельною системою час на виконання методу синтезу нейро-нечітких мереж.

Практична цінність отриманих результатів полягає в розробленому програмному забезпеченні, яке реалізує запропоновану модель і дозволяє раціонально планувати вибір ресурсів комп'ютерної системи для розв'язання розглянутої задачі.

БЛАГОДАРНОСТІ

Робота виконана в межах науково-дослідницької роботи «Дослідження і розробка методів підвищення ефективності комп'ютерних систем та мереж, пошук шляхів удосконалення навчального процесу» кафедри комп'ютерних систем і мереж Запорізького національного технічного університету. Вибірка для проведення експериментального дослідження на кластері надана професором Запорізького національного технічного університету С. А. Субботиним.

СПИСОК ЛІТЕРАТУРИ

1. Лашкул З. В. Особливості епідеміології артеріальної гіпертензії та її ускладнень на регіональному рівні з 1999 по 2013 роки / З. В. Лашкул // Сучасні медичні технології. – 2014, № 2. – С. 134–141.
2. Sergey Subbotin Individual prediction of the hypertensive patient condition based on computational intelligence / Sergey Subbotin, Andrii Oliinyk, Stepan Skrupsky – Information and Digital Technologies 2015 ISBN 978-1-4673-7185-8, 7–9 July 2015, Zilina, Slovakia. – P. 336–344

3. Oliinyk A. O. Experimental Investigation with Analyzing the Training Method Complexity of Neuro-Fuzzy Networks Based on Parallel Random Search / Andrii Oliinyk, Stepan Skrupsky, Sergey Subbotin // Automatic Control and Computer Sciences ISSN 0146-4116. – 2015. Vol. 49, No. 1. – P. 11–20. DOI: 10.3103/S0146411615010071
4. Субботін С. О. Подання й обробка знань у системах штучного інтелекту та підтримки прийняття рішень : навч. посібник / С. О. Субботін. – Запоріжжя : ЗНТУ, 2008. – 341 с.
5. Oliinyk A. O. Using Parallel Random Search to Train Fuzzy Neural Networks / A. O. Oliinyk, S. Yu. Skrupsky, S. A. Subbotin // Automatic Control and Computer Sciences. – 2014. – Vol. 48, Issue 6. – P. 313–323. DOI: 10.3103/S0146411614060078
6. Характеристики ГРІД-вузла НАНУ. – Режим доступу: URL: http://www.ipme.kiev.ua/ukr/grid_vuzol/charakter-g.html. – Загл. з екрану.
7. Introduction to GPUs. – Режим доступу: URL: <https://www.cs.utexas.edu/~pingali/CS378/2015sp/lectures/IntroGPUs.pdf>. – Загл. з екрану.
8. Sulistio A. Simulation of Parallel and Distributed Systems: A Taxonomy - and Survey of Tools / A. Sulistio, C. S. Yeo, R. Buyya // International Journal of Software Practice and Experience. Wiley Press. – 2002. – P. 1–19.
9. Методи і моделі планування ресурсів в GRID-системах : монографія / [В. С. Пономаренко, С. В. Листрової, С. В. Минухін, С. В. Знахур]. – Х. : ІД «ИНЖЭК», 2008. – 408 с.
10. Петренко А. І. Комп'ютерне моделювання ГРІД-систем / А. І. Петренко // Електроніка і зв'язь 5' Тематичний випуск «Електроніка і нанотехнології». – 2010. – С. 40–48.
11. Скрупський С. Ю. Імітаційні моделі розподілених систем компресії відеоінформації / С. Ю. Скрупський, Р. К. Кудерметов // Наукові праці Донецького національного технічного університету. Серія: «Інформатика, кібернетика та обчислювальна техніка». – 2012. – № 15 (203). – С. 190–202.
12. Кучер В. О. Нейросетевая модель выбора эвристики предоставления ресурсов на уровне потока заданий в grid-системе / В. О. Кучер // 14-th International conference on System Analysis and Information Technologies SAIT 2012 Institute for Applied System Analysis, National Technical University of Ukraine «KPI», Kyiv, Ukraine, April 24, 2012 ISBN 978-966-2748-07-9. – P. 287–288.
13. Buyya R. Gridsim: a toolkit for the modeling and simulation of distributed resource management and scheduling for grid computing / R. Buyya, M. Murshed // Concurrency and computation: practice and experience. – 2002. – Vol. 14. – P. 1175–1220.
14. Руденко О. Г. Штучні нейронні мережі / О. Г. Руденко, Є. В. Бодяньський. – Х. : Компанія СМІТ, 2006. – 404 с.
15. Интеллектуальные информационные технологии проектирования автоматизированных систем диагностирования и распознавания об-

- разов : монографія / С. А. Субботін, Ан. А. Олейник, Е. А. Гофман, С. А. Зайцев, Ал. А. Олейник ; под ред. С. А. Субботіна. – Харків : ООО «Компанія Сміт», 2012. – 317 с.
16. Рассел С. Искусственный интеллект: современный подход / С. Рассел, П. Норвиг. – М. : Вильямс, 2006. – 1408 с.
17. Субботін С. О. Неітеративні, еволюційні та мультиагентні методи синтезу нечіткологічних і нейромережних моделей: монографія / С. Ю. Скрупський С. Ю.

- нографія / С. О. Субботін, А. О. Олійник, О. О. Олійник ; під заг. ред. С. О. Субботіна. – Запоріжжя : ЗНТУ, 2009. – 375 с.
18. Quinn M. J. Parallel Programming in C with MPI and OpenMP / M. J. Quinn. – New York, NY : McGraw-Hill, 2004. – 529 p.

Статья поступила в редакцию 01.02.2016.

Канд.техн.наук, доцент кафедри комп'ютерних систем та мереж, Запорізький національний технічний університет, Запоріжжя, Україна

ЕКСПЕРИМЕНТАЛЬНЕ ДОСЛІДЖЕННЯ МЕТОДУ СИНТЕЗУ НЕЙРО-НЕЧІТКИХ МОДЕЛЕЙ В ПАРАЛЕЛЬНІЙ КОМП'ЮТЕРНІЙ СИСТЕМІ

Вирішено задачу розробки нелінійної моделі, що описує залежність між характеристиками системи, в якій здійснюється синтез нейро-нечітких мереж, параметрами досліджуваного методу і часом, що витрачається системою на виконання синтезу моделей. Об'єкт дослідження – процес синтезу нейро-нечітких моделей для індивідуального прогнозування стану хворого гіпертонічною хворобою. Предметом дослідження є паралельна комп'ютерна система, що виконує метод синтезу нейро-нечітких мереж. Мета роботи полягає у підвищенні ефективності використання паралельних комп'ютерних систем для вирішення задач медичного призначення. Запропоновано нелінійну модель, що дозволяє прогнозувати витрачений паралельною системою час на виконання методу синтезу нейро-нечітких мереж і, таким чином, здійснювати раціональний вибір ресурсів комп'ютерної системи. Розроблено програмне забезпечення, що реалізує запропоновану модель. Виконано експерименти, що підтверджують адекватність запропонованої моделі. Результати експериментів дозволяють рекомендувати використання розробленої моделі на практиці.

Ключові слова: синтез моделі, паралельна система, планування ресурсів, нейронна мережа, середньоквадратична помилка.

Skrupsky S. Yu.

PhD, Associate Professor of Computer systems and networks department, Zaporizhzhia National Technical University, Zaporizhzhia, Ukraine

EXPERIMENTAL INVESTIGATION OF METHOD FOR THE SYNTHESIS OF NEURO-FUZZY MODELS IN A PARALLEL COMPUTER SYSTEM

The article deals with the problem of the development of the non-linear model describing dependences between the characteristics of a system, in which synthesis of neuro-fuzzy networks is realized, the parameters of the investigated method and the time spent on execution of the models synthesis. The object of research is a synthesis of neuro-fuzzy models for individual prediction of the hypertensive patient state. The subject of research is a parallel computer system that performs the method of neuro-fuzzy networks synthesis. The purpose of the work is to improve the efficiency of parallel computer systems solving the problems of medical direction. A non-linear model to predict the time used by a parallel system to perform the method of neuro-fuzzy network synthesis and thus to execute a rational choice of the computer system resources has been proposed. The software that implements the proposed model has been developed.

Experiments confirming the adequacy of the proposed model have been executed. The experimental results allow us to recommend the application of the developed model in practice.

Keywords: synthesis of model, parallel system, resource planning, neural network, mean-squared error.

REFERENCES

- Lashkul Z. V. Osoblyvosti epidemiologii arterialnoi hipertenzii ta yii uskladnen na rehionalnomu rivni z 1999 po 2013 roky, *Suchasni medychni tekhnologii*, 2014, No. 2, pp. 134–141.
- Sergey Subbotin, Andrii Oliinyk, Stepan Skrupsky Individual prediction of the hypertensive patient condition based on computational intelligence, *Information and Digital Technologies 2015 ISBN 978-1-4673-7185-8, 7–9 July 2015*. Zilina, Slovakia, pp. 336–344
- Andrii Oliinyk, Stepan Skrupsky, Sergey Subbotin Experimental Investigation with Analyzing the Training Method Complexity of Neuro-Fuzzy Networks Based on Parallel Random Search, *Automatic Control and Computer Sciences ISSN 0146-4116*, 2015, Vol. 49, No. 1, pp. 11–20. DOI: 10.3103/S0146411615010071
- Subbotin S.O. Podannia y obrobka znan u systemakh shtuchnoho intelektu ta pidtrymky pryiniattia rishen : navch. posibnyk. Zaporizhzhia, ZNTU, 2008, 341 p.
- Oliinyk A. O., Skrupsky S. Yu., Subbotin S. A. Using Parallel Random Search to Train Fuzzy Neural Networks, *Automatic Control and Computer Sciences*, 2014, Vol. 48, Issue 6, pp. 313–323. DOI: 10.3103/S0146411614060078
- Kharakterystyky HRID-vuzla NANU. Rezhym dostupa: URL: http://www.ipme.kiev.ua/ukr/grid_vuzol/charakter-g.html. – Zahl. z ekranu.
- Introduction to GPUs. Rezhym dostupa, URL: <https://www.cs.utexas.edu/~pingali/CS378/2015sp/lectures/IntroGPUs.pdf>. Zahl. z ekranu.
- Sulistio A., Yeo C. S., Buyya R. Simulation of Parallel and Distributed Systems: A Taxonomy – and Survey of Tools, *International Journal of Software Practice and Experience*. Wiley Press, 2002, pp. 1–19.
- Ponomarenko S., Listrovoj S. V., Minuxin S. V., Znaxur S. V. Metody i modeli planirovaniya resursov v GRIDsystemax, monografiya. Har'kov, ID «INZhE'K», 2008, 408 p.
- Petrenko A. I. Kompiuterne modeliuvannia HRID-system, *E'lektronika i svyaz' 5' Tematicheskij vypusk «E'lektronika i nanotekhnologii»*, 2010, pp. 40–48.
- Skrupskij S. Yu., Kudermetov R. K. Imitacionnye modeli raspredelennyx sistem kompressii videoinformacii, *Naukovi pratsi Donetskoho natsionalnoho tekhnichnoho universytetu. Seriya: «Informatyka, kibernetyka ta obchysliuvalna tekhnika»*, 2012, No. 15 (203), pp. 190–202.
- Kucher V. O. Nejrosetevaya model' vybora e'vristsiki predstavleniya resursov na urovne potoka zadaniy v grid-sisteme, *14-th International conference on System Analysis and Information Technologies SAIT 2012 Institute for Applied System Analysis, National Technical University of Ukraine «KPI»*. Kyiv, Ukraine, April 24, 2012 ISBN 978-966-2748-07-9, pp. 287–288.
- Buyya R., Murshed M. Gridsim: a toolkit for the modeling and simulation of distributed resource management and scheduling for grid computing, *Concurrency and computation: practice and experience*, 2002, Vol. 14, pp. 1175–1220.
- Rudenko O. H., Bodianskyi Ye. V. Shtuchni neuronni merezhi. Har'kov, Kompaniia SMIT, 2006, 404 p.
- Subbotin S. A., Olejnik An. A., Gofman E. A., Zajcev S. A., Olejnik Al. A.; pod red. S. A. Subbotina Intellektual'nye informacionnye tekhnologii proektirovaniya avtomatizirovannyx sistem diagnostirovaniya i raspoznavaniya obrazov : monografiya. Har'kov, ООО «Компанія Сміт», 2012, 317 p.
- Rassel S., Norvig P. Iskustvennyj intellekt: sovremennyy podhod. Moscow, Vil'yams, 2006, 1408 p.
- Subbotin S. O., Oliinyk A. O., Oliinyk O. O.; pid zah. red. S. O. Subbotina Neiteratyvni, evoliutsiini ta multyahentni metody syntezy nechitkolohichnykh i neiromerezhnykh modelei: monohrafiya. Zaporizhzhia, ZNTU, 2009, 375 p.
- Quinn M. J. Parallel Programming in C with MPI and OpenMP. New York, NY, McGraw-Hill, 2004, 529 p.