

Исследование применимости нейронных сетей прямого распространения в задачах самодиагностики распределённых вычислительных систем¹

К. Е. Крамаренко, О. В. Молдованова

В статье приведены результаты применения нейронных сетей прямого распространения к решению задачи самодиагностики распределённых вычислительных систем с использованием диагностической модели сравнения без применения дополнительных эвристик.

Ключевые слова: самодиагностика, распределённые вычислительные системы, искусственные нейронные сети.

1. Введение

Одной из основных задач построения распределённых вычислительных систем (ВС) является обеспечение их продолжительного надёжного функционирования. Её решение предполагает в первую очередь борьбу с неисправностями системы, порождаемыми отказами и сбоями в работе. Основная функционально-структурная единица вычислительных ресурсов в таких системах – элементарная машина (ЭМ). В качестве ЭМ могут быть использованы ЭВМ, вычислительные ядра, многоядерные процессоры, вычислительные узлы, оснащённые средствами межмашинной коммутации.

Отказом называется событие, при котором ЭМ теряет способность выполнять заданные функции по переработке информации [1]. Отказ одной элементарной машины, участвующей в вычислительном процессе, может привести к некорректному результату вычислений и иметь разрушительные последствия в дальнейшем. Следовательно, организация отказоустойчивого функционирования распределённых ВС требует создания программных средств, обеспечивающих контроль и диагностику их функционирования. В вычислительной системе как совокупности из N элементарных машин, взаимодействующих между собой через сеть связи, может быть применён нетрадиционный подход к контролю и диагностике. Учитывая встроенный параллелизм и программируемость структуры, в пределах ВС можно организовывать топологически различные схемы из ЭМ, которые обеспечат полноту контроля работоспособности всей системы и диагностики неисправностей. Поэтому по отношению к таким ВС допустимо применение терминов «самоконтроль» и «самодиагностика» [1].

При этом система рассматривается как граф, вершинам которого соответствуют ЭМ системы. Каждый тест формирует дугу графа, направленную от тестирующего к тестируемому. Результату теста соответствует 0 (1), если тестируемая элементарная машина определена как исправная (неисправная). Это значение используется как вес соответствующей дуги в диагностическом графе. Предполагается, что либо одна из ЭМ, либо обе могут быть неисправными. Неисправная тестирующая элементарная машина может сгенерировать любой тесто-

¹ Работа выполнена при поддержке Совета по грантам Президента РФ (грант МД-2620.2014.9), Российского фонда фундаментальных исследований (гранты 15-07-00048-а, 15-07-00653-а, 15-37-20113-мол_а_вед).

вый результат, и его интерпретация тоже может быть различной. Набор всех тестовых результатов, называемый синдромом, дешифрируется для идентификации исправных и неисправных ЭМ.

Для интерпретации результатов тестирования были предложены различные диагностические модели [2-6], позволяющие идентифицировать исправные и неисправные элементарные машины. К ним относятся модели, основанные на тестировании ЭМ друг друга, такие как: модель Препараты-Метца-Чиена [2] (Preparata-Metze-Chien) и модель Барси-Грандони-Маестрини [3] (Barsi-Grandoni-Maestrini). Диагностическая модель, описанная в [4-6], называется моделью сравнения и предполагает, что парам ЭМ назначаются некоторые тесты, результаты выполнения которых затем сравниваются.

Определение полного и корректного подмножества неисправных элементарных машин (образа неисправности) в системе является NP -трудной задачей [7]. Но эта задача может быть решена за полиномиальное время при введении ограничения количества неисправных ЭМ в системе. Такие системы получили название t -диагностируемых [2], где t – максимальное количество неисправных элементарных машин, при котором возможно определение образа неисправности.

В настоящее время при решении задачи самодиагностики распределённых вычислительных систем широко используются генетические алгоритмы [8, 9], искусственные нейронные сети [10-12] и даже алгоритмы, в основе которых лежит функционирование искусственной иммунной системы [13]. Главным недостатком существующих решений для нейронных сетей является использование в дополнение к основным алгоритмам эвристик, позволяющих улучшить результат самодиагностики.

В статье приведены результаты применения нейронных сетей прямого распространения к решению задачи самодиагностики распределённых вычислительных систем с использованием диагностической модели сравнения без применения дополнительных эвристик.

2. Диагностическая модель сравнения

Рассматривается распределённая вычислительная система, состоящая из N элементарных машин (в дальнейшем – узлов), соединённых каналами связи. Каждый узел может находиться в исправном или неисправном состоянии. Паре узлов назначается на выполнение задача. Сравнение полученных результатов её решения даёт информацию о состоянии узлов. Если результаты совпадают – оба узла исправны, иначе один или оба узла являются неисправными. Множество всех результатов сравнения называется синдромом [6].

Модель сравнения, предложенная в [4, 5], предполагает наличие центрального обозревателя (высоконадёжной ЭМ), который назначает задачи из множества $T = \{T_1, T_2, \dots, T_k, \dots, T_M\}$ парам узлов, затем собирает результаты выполнения этих задач и производит диагностику системы.

Диагностическая модель сравнения описывается двумя ненаправленными графами: графом связей и графом тестов, или сравнений [10]. Граф связей $G_1 = (V, E)$ представляет топологию вычислительной системы, где V – множество узлов, $|V| = N$; E – множество рёбер. Каждое ребро $e_{ij} = (v_i, v_j)$ представляет собой канал связи между парой (v_i, v_j) узлов ВС. Граф сравнений $G_2 = (V, C)$ показывает, какие пары узлов тестировались. Как и в случае с графом связей, V – множество узлов, $|V| = N$; а $C = \{c_{ij}\}$ – множество рёбер, соединяющих пары узлов (v_i, v_j) , выполняющих одну и ту же задачу $T_k \in T$. Обозначим множество узлов, с которым сравнивается узел v_i , как $\Gamma_i = \{v_j : c_{ij} \in C\}$. Сравнение узлов v_i и v_j даёт 0, если их результаты выполнения задачи T_k совпали; и 1 – в противном случае. Для двух исправных узлов результат сравнения всегда равен 0. Если только один из узлов является неисправным, результат сравнения всегда равен 1. А для двух неисправных узлов этот результат может принимать

значение как 0, так и 1. Синдром для диагностической модели сравнения представляет собой квадратную симметричную матрицу размером $N \times N$.

Для проведения корректной самодиагностики распределённой ВС введено ограничение на максимальное количество t неисправных узлов, называемое степенью диагностируемости системы [2]. В [6] было показано, что для системы с N узлами, сравниваемыми попарно, $t = N - 2$.

3. Нейронные сети

Основной причиной выбора нейронных сетей для решения задачи самодиагностики является их интенсивное изучение в настоящее время как механизмов классификации и распознавания. Задачу самодиагностики с использованием диагностической модели сравнения можно рассматривать как задачу классификации, которая направлена на разделение узлов системы на исправные и неисправные. В данной работе мы сфокусируемся на нейронной сети прямого распространения (многослойный персептрон), потому что этот класс сетей является одним из самых изученных и существует множество реальных реализаций, основанных на нём [14]. Пример структуры сети приведён на рисунке ниже. Сигналы в такой сети распространяются от нейронов входного слоя к нейронам выходного.




Рис. 1. Пример структуры нейронной сети прямого распространения

Выходной сигнал нейрона рассчитывается по следующей формуле:

$$y_i = f\left(\sum_{j=1}^N W_{ji} \cdot x_j\right), i = \overline{1, M},$$

где y_i – выходной сигнал, f – функция активации, x_j – j -й входной сигнал, W_{ij} – вес связи между i -м и j -м нейронами.

Обучение сети производится алгоритмом обратного распространения ошибки, который предполагает два прохода по всем слоям сети: прямой и обратный. Во время прямого прохода входной вектор подаётся на входной слой нейронной сети, после чего распространяется по сети до выходного слоя. В результате получаем набор выходных сигналов, который и является фактической реакцией сети на данный входной образ. Во время прямого прохода все синаптические веса сети остаются неизменными. Во время обратного прохода все синапти-

ческие веса настраиваются в соответствии с правилом коррекции ошибок, а именно: фактический выход сети вычитается из желаемого, в результате чего формируется сигнал ошибки. Этот сигнал впоследствии распространяется по сети в направлении от выходного слоя к входному. Для обучения этим алгоритмом требуется обучающая выборка с уже известными выходными значениями. Количество нейронов в слоях и число скрытых слоёв зависит от поставленной задачи.

3.1 Нейросетевая интерпретация задачи

Структуру нейронной сети, решающую задачу диагностирования, представим следующим образом:

- количество входных нейронов соответствует размерности синдрома;
- количество выходных нейронов равно числу узлов системы;
- количество скрытых слоёв равно трём (вычислено опытным путём);
- количество нейронов в скрытых слоях вычисляется по следующей формуле:

$$f(x) = \begin{cases} \text{round}(N + (\log_{10}(N/10 + N) \cdot N)), & \text{если } \text{mod}(N, 10) = 0 \\ \text{round}(N + (\log_{10}(\text{mod}(N, 10)) \cdot N)), & \text{если } \text{mod}(N, 10) \neq 0 \end{cases}$$

где N – количество узлов системы; round – округление до ближайшего целого; mod – остаток от деления.

4. Результаты

В данной работе было реализовано две версии диагностических алгоритмов. Первая (Алгоритм1) делит синдром на блоки длиной 8 и преобразует их в числа троичной системы исчисления и подаёт на вход полученную последовательность, а вторая версия (Алгоритм2) использует для входа сети нижний треугольник матрицы синдрома. При моделировании использовались случайно сгенерированные диагностические графы. И для каждого графа количество неисправных узлов составляло 10, 30, 50 и 70 процентов от общего количества узлов.

Алгоритмы самодиагностики распределённых вычислительных систем были реализованы и исследованы с помощью пакета Neural Network Toolbox™ интерактивной среды MATLAB (версия R2014b). Моделирование проводилось на следующих персональных компьютерах:

- 1) Intel Core i5, 3.20 GHz, RAM 8 GB DDR3;
- 2) Intel Core i7, 2.0 GHz, RAM 8 GB DDR3.

Эксперименты проводились с количеством узлов в системе 50, 100, 200 и выборками 100, 300 и 700 соответственно. Где 70% выборки составляла обучающая выборка, а 30% – тестовая выборка. Размеры выборок определены опытным путём. Для каждой размерности ВС генерировалось 5 различных диагностических графов. Результаты моделирования, приведённые на рис. 2-4, представляют собой средние значения.

Исходя из полученных результатов, можно сделать следующие выводы:

- 1) нейронные сети прямого распространения имеет смысл использовать для диагностирования вычислительных систем с процентом неисправных узлов не более 30;
- 2) несмотря на то, что Алгоритм1 и Алгоритм2 сокращают размер входных данных в 8 и 2 раза соответственно, сохраняется высокая обобщающая способность нейронной сети;
- 3) даже при небольшом размере обучающей выборки для каждой размерности вычислительной системы получается высокая точность диагностирования.




Рис. 2. Результаты диагностики ВС с 50 узлами
1 – Алгоритм1; 2 – Алгоритм2




Рис. 3. Результаты диагностики ВС со 100 узлами
1 – Алгоритм1; 2 – Алгоритм2




Рис. 4. Результаты диагностики ВС с 200 узлами
1 – Алгоритм1; 2 – Алгоритм2

5. Заключение

В статье приведены результаты применения нейронных сетей прямого распространения к решению задачи самодиагностики распределённых вычислительных систем с использованием диагностической модели сравнения без дополнительных эвристик. По полученным результатам даны рекомендации. В дальнейшем планируются эксперименты с большими размерностями вычислительных систем и другими классами искусственных нейронных сетей.

Литература

1. Хорошевский В.Г. Архитектура вычислительных систем: Учеб. пособие. – 2-е изд., перераб. и доп. – М.: Изд-во МГТУ им. Н.Э. Баумана, 2008. – 520 с.
2. Preparata F.P., Metze G., Chien R.T. On the Connection Assignment Problem of Diagnosable Systems. // IEEE Trans. Electron. Comput. 1967. V. EC-16. N 6. – pp. 848-854.
3. Barsi F., Grandoni F., Maestrini P. A Theory of Diagnosability of Digital Systems. // IEEE Trans. Comput. 1976. V. 25. N 6. – pp. 585-593.
4. Chwa K.Y., Hakimi S.L. Schemes for fault tolerant computing: a comparison of modularly redundant and t-diagnosable systems. // Information and Control 49, 1981. – pp. 212-238.
5. Malek M. A comparison connection assignment for diagnosis of multiprocessor systems // Proc. 7th International symposium on computer architecture, New York, 1980. – pp. 31-35.
6. Duarte Jr., E.P., Ziwich, R.P., Albini, L.C.P. A survey of comparison-based system-level diagnosis // ACM Comput. Surv. 43, 3, Article 22, 2011. – 56 p.
7. Blough D., Sullivan G., Masson G. Intermittent fault diagnosis in multiprocessor systems // IEEE Trans. on computers, 41, 1992. – pp. 1430-1441.
8. Elhadef M., Das Sh., Nayak A. A parallel genetic algorithm for identifying faults in large diagnosable systems. // The international journal of parallel, emergent and distributed systems, Vol. 20, No.2, June 2005. – pp. 113-125.
9. Elhadef M., Romdhane L.B., Ayeb B. Performance analysis of an evolutionary algorithm for fault detection in t-diagnosable multi-processor systems // International Journal of Parallel Emergent and Distributed Systems 10/2007. – 22 (5). – pp. 387-404.

10. *Elhadeif M.* A modified Hopfield neural network for diagnosing comparison-based multiprocessor systems using partial syndromes // ICPADS, 2011, Parallel and Distributed Systems, International Conference on, Parallel and Distributed Systems, International Conference on 2011. – pp. 646-653.
11. *Elhadeif M., Nayak A.* Comparison-Based System-Level Fault Diagnosis: A Neural Network Approach // IEEE Transactions on Parallel & Distributed Systems, 2012. – vol.23. – no. 6. – pp. 1047-1059.
12. *Elhadeif M., Romdhane L.B.* Fault diagnosis using partial syndromes: a modified Hopfield neural network approach // International Journal of Parallel, Emergent and Distributed Systems, 2014. – Vol. 29. – No. 2. – pp. 119-146.
13. *Elhadeif M., Das Sh., Nayak A.* System-Level Fault Diagnosis Using Comparison Models: An Artificial-Immune-Systems-Based Approach. // Journal of networks, Vol. 1, No. 5, September/October 2006. – pp. 43-53.
14. *Осовский С.* Нейронные сети для обработки информации / Пер. с польского И.Д. Рудинского. – М.: Финансы и статистика, 2004. – 344 с.

Статья поступила в редакцию 10.08.2015

Крамаренко Константин Евгеньевич

старший преподаватель Кафедры вычислительных систем СибГУТИ (630102, Новосибирск, ул. Кирова, 86) тел. (383) 269-82-86, e-mail: kostya.kram@gmail.com.

Молдованова Ольга Владимировна

к.т.н., доцент Кафедры вычислительных систем СибГУТИ (630102, Новосибирск, ул. Кирова, 86) тел. (383) 269-82-75, e-mail: ovm@csc.sibsutis.ru.

Research of artificial neural networks applicability in self-diagnosis problems for distributed computer systems

K. Kramarenko, O. Moldovanova

The article contains the results of artificial neural networks applicability for solving the problem of distributed computer systems self-diagnosis with comparison diagnosis model without additional heuristics.

Keywords: self-diagnosis, distributed computer systems, artificial neural networks.