

Особое внимание уделено вопросам анализа методов синтеза и оценки решений, представляющих практический интерес, для разработки алгоритмов автоматизированного синтеза аппаратных схем с применением вероятностных генетических алгоритмов.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Яблонский С.В. Введение в дискретную математику. – М.: Наука, 1979. – 272 с.
2. Сигорский В.П. Математический аппарат инженера. – Киев: Изд-во Техника, 1975. – 768 с.
3. В.П. Корячко, В.М. Курейчик, И.П. Норенков. Теоретические основы САПР. – М.: Энергоатомиздат, 1987. – 400 с.
4. Курейчик В.М. Генетические алгоритмы. – Таганрог: Изд-во ТРТУ, 1998.
5. Koza J. R. Genetic Programming III// San Francisco, CA: Morgan Kaufmann Publishers, 1999.
6. Koza J. R., Genetic Programming: On the Programming of Computers by means of Natural Selection// Cambridge, MA: MIT Press, 1992.
7. H. Mühlenbein. The Equation for Response to Selection and its Use for Prediction// Evolutionary Computation, May 1998, pp. 303-346.
8. В.В. Гудиллов, Л. А. Зинченко. Аппаратная реализация вероятностных генетических алгоритмов с параллельным формированием хромосомы // Перспективные информационные технологии и интеллектуальные системы, №4, 2003. – С. 34-38.
9. Л.А. Гладков, В.В. Курейчик, В.М. Курейчик. Дискретная математика // Учебное пособие. – Таганрог: Изд-во ТРТУ, 2005.

Ю.А. Кравченко

ЭКСТРАПОЛЯЦИЯ ИЗМЕНЕНИЙ ПАРАМЕТРОВ СЛОЖНЫХ СИСТЕМ НА ОСНОВЕ ПЕРИОДИЧЕСКОЙ НЕЧЕТКОЙ КЛЕТочНОЙ НЕЙРОННОЙ СЕТИ*

Введение. Для множества технических систем процесс изменения параметров комплектующих изделий является монотонным по мере накопления энергии внешних воздействующих факторов. Это позволяет обычно линеаризовать зависимость параметра или функции параметра от величины внешней нагрузки. Используя связь между нагрузкой и плотностью потока воздействующего фактора, а также, зная время воздействия, можно получить оценку параметров системы на определенное время при данном воздействующем факторе [1]. Проблемы оценки прочностных характеристик сложного объекта возникают в случае неоднородности информации при разнотипности данных, что является следствием событий разной физической природы. Кроме того, следует учитывать отсутствие необходимого количества априорной информации для осуществления прогноза с требуемой достоверностью. Непредставительность обучающей выборки обусловлена тем, что исходная для прогнозирования информация о закономерностях изменения параметров объекта не всегда достаточна [2]. Вследствие этого, вероятностные методы прогнозирования событий, использующие классический аппарат математической статистики и теории случайных функций, могут быть неэффективными.

1. Преимущества применения нейронных сетей для прогнозирования свойств технических систем. Целесообразность использования нейроподобных систем в целях экстраполяции технических свойств сложных динамических объек-

* Работа выполнена при поддержке РФФИ, грант № 05-08-18115, РНП.2.1.2.3193.

тов обусловлена специфическими свойствами нейронных сетей (НС). К числу таких свойств НС относятся:

- ◆ способность оперативного многопараметрического анализа;
- ◆ нечувствительность к недостатку априорной информации о динамике прогнозируемого объекта;
- ◆ возможность обработки данных, представленных в разнотипных шкалах;
- ◆ способность выявления неявных аналогий прецедентов протокола наблюдений;
- ◆ сохранение своих свойств при разрушении случайно выбранной части НС, что обуславливает высокую надежность сети;
- ◆ способность к дообучению;
- ◆ возможность прогнозирования скачков и событий, не наблюдавшихся ранее в обучающей выборке.

НС выступает как система обработки входной информации, ее хранения, воспроизведения и логического вывода на ее основе. Свойства НС определяются ее архитектурой, а также совокупностью синаптических связей и характеристик нейронов. Прогнозная нейросетевая модель должна быть способна не только непрерывно обрабатывать большое количество параметров технической системы, факторов прогнозного фона, но и учитывать разнородную информацию о текущих и планируемых режимах функционирования объекта. Нейросетевая система прогнозирования, в свою очередь, должна учитывать информацию о логике работы системы, надежности ее элементов, а также экспертную информацию.

Решение проблем прогнозирования в исходной ситуации требует параллельного решения следующих локальных задач:

1. Распознавание образов в условиях большого числа их признаков.
2. Ассоциативное запоминание и восстановление информации полученной при испытаниях.
3. Логический вывод относительно не наблюдавшихся ранее причин.

Вполне изученными возможностями по моделированию интеллектуальных функций обладают динамические НС. Системы распознавания на основе статических НС способны аппроксимировать сложные разделяющие поверхности в пространстве признаков и распознавать скрытые зависимости.

Для эффективного использования НС прямого распространения необходима достаточно представительская выборка, которая имеется лишь при прогнозировании на участках длительной эксплуатации объектов [3]. На этапе предварительной, экспериментальной отработки опытных образцов и в начале применения серийных объектов по целевому назначению необходимо использовать НС с более явно выраженными и с более широким спектром способностей моделировать функции искусственного интеллекта, в частности, функции индуктивного и дедуктивного вывода.

Таким образом, в основе нейросетевого метода оперативного прогнозирования для формирования прототипа необходимо использовать способности комплексированных НС, в качестве основного инструмента экстраполяции в пространстве признаков не наблюдаемой ранее ситуации.

В качестве математической модели исследуемого процесса выберем детерминированный конечный автомат, представляющий собой стационарную динамическую систему с дискретным временем. Конечные множества X , Y , Z определяют входной, выходной алфавит и алфавит состояний:

$$A = \{ X, Y, Z, \alpha, \beta \}, \quad (1)$$

где $\alpha: X \times Z \rightarrow Z$ – функция переходов; $\beta: Z \rightarrow Y$ – функция выходов.

Значениями функции переходов являются состояния $g(t+1)=\alpha(g(t),x(t))$, в которых оказывается автомат в момент времени $t+1$, если в предыдущий момент времени t он находился в состоянии $g(t)$ и подвергался воздействию $x(t)$. Значениями функции выходов являются выходы $y(t)=\beta(g(t))$, определяемые только текущим состоянием.

Входной алфавит X задается множеством управляющих воздействий, определенных для моделируемого объекта. Управляющим воздействием $x_i \in X$ является пара $(x_i, \Delta t_i)$, где x_i – имя i -й команды, а Δt_i – максимальное время задержки смены меток в исправной сети. Выходной алфавит Z задается множеством значений выходных параметров.

Представление модели графом переходов в пространстве его состояний позволяет использовать математический аппарат оптимизации на основе параллельной обработки данных (нейронные сети).

Высокая степень распараллеливания обработки данных позволяет обеспечить выигрыш во времени решения поставленной задачи, следовательно, повышается оперативность и достоверность принятия решений в процессе испытаний при большом числе состояний модели [4].

2. Принципы построения периодических нечетких клеточных нейронных сетей. Использование клеточных нейронных сетей (КНС) в параллели может помочь достичь более высокого уровня информационной обработки, и обоснованном функционировании, как в применении, так и с биологической точки зрения. Данная концепция стала основой построения сложной структуры КНС, интегрирующих нейронную систему в форме периодической нечеткой сети. Эта система названа периодической нечеткой КНС (ПНКНС). Она может автоматически узнать свою сетевую структуру и параметры одновременно. Структурное обучение включает нечеткое деление проблемной области, создание нечетких правил и КНС. Параметрическое обучение включает настройку нечетких функций принадлежности (в нечётких множествах) и шаблонах КНС. В ПНКНС нечеткие правила соответствуют КНС. Следовательно, каждая КНС заботится о периодически разделенной проблемной области, также функции всех КНС интегрированы через нечеткий механизм логического вывода.

КНС – это локально взаимосвязанная аналоговая матрица процессоров, систематизированная в регулярную двумерную сеть (2-D). 2-D система ввода и вывода информации делают эту матрицу пригодной для обработки образов. Это обладает некоторыми важными характеристиками такими, например, как эффективная способность обработки в реальном времени и допустимая сверхбольшая степень интеграции (СБИС) разработки. КНС имеют инвариантную, локальную структуру с 19-ю свободными параметрами (в пределах радиуса = 1). Этот параметр установки был назван как шаблонные исключительные установки динамического поведения. КНС используются для имитации локальной функции биологических нейронных цепей, главным образом, человеческих визуальных систем наблюдения. Согласно текущему биологическому анализу [5], визуальные системы млекопитающих обрабатывают мир через набор отдельных параллельных каналов. Каждый подканал может считаться уникальной КНС. Выход этих подканалов затем комбинирует в формы новые каналы ответов. В результате, широко применяется использование установки КНС в параллели, что помогает достичь более высокого уровня информационной обработки и обоснования результатов, как с биологической точки зрения, так и с точки зрения применения. Такая интегрированная система КНС может решить более сложные интеллектуальные проблемы.

Для проектирования встроенной системы КНС, в дополнение к определению набора шаблонов, появляется другая существенная проблема – это путь интеграции. Рассмотрим нечеткую систему логического вывода (НСЛВ). НСЛВ – это популярная вычислительная структура, основанная на понятии теории нечеткого множества, нечетких правил ЕСЛИ-ТОГДА и нечеткой аргументации. С четкими вводами и выводами НСЛВ осуществляет нелинейное построение соответствий от входного до выходного пространства при помощи множества правил ЕСЛИ-ТОГДА. Это очень полезно при обработке изображений, когда трудно определить в четкой математической форме операцию, которая должна дать удовлетворительный результат из комплексной картины происходящего. Следовательно, НСЛВ может сыграть важную роль при внедрении набора КНС в систему [8].

Для создания структуры КНС в параллели предлагаются несколько интегрированных систем КНС, достигших более высокого уровня информационной обработки, которые являются клеточными нейро-нечеткими сетями (КННС), предложенными Колодро и Торальба [6], и нечеткий тип КНС, предложенных Рекецким и др. [7], и Сзатмари и др. [5]. Общие недостатки этих методов заключаются в том, что соответствующие шаблоны не могут быть обучены, и нечеткие правила должны быть получены специалистами по данной проблемной области.

Результаты научных наблюдений из работ Колодро и др. [6], Рекецкого и др. [7], и Сзатмари и др. [5], имеют две общих характеристики. Сначала они все использовали множество КНС в параллели, чтобы решить сложную проблему такие как, например, выделение (обнаружение) краёв с импульсными помехами, обнаружение нечеткой границы, и выделением признаков, и т.п.

Далее, все они используют НСЛВ, для принятия решений. Для построения НСЛВ необходимо определить нечеткие множества нечетких операторов и базу знаний. Тем не менее, специалистам по проблемной области нужно вручную собрать все существующие методы [5-7] в нечеткие правила. Даже для специалистов по проблемной области трудно проверить все входные и выходные данные комплексной системы, чтобы найти множество соответствующих нечетких правил. Кроме того, им всем нужно определить соответствующие шаблоны КНС заранее. Чтобы справиться с этими недостатками, Лин и др. [8] предложили новую структура для автоматического создания множественных интегрированных КНС нейронной системы в форме периодической нечеткой нейронной сети (ННС). Эта структура, называемая периодической нечеткой КНС (ПНКНС), автоматически распознающая свою соответствующую сетевую структуру и параметры одновременно. Изучение структуры включает в себя нечеткое деление проблемной области и создание нечетких правил и КНС. Изучение параметра включает в себя настройку нечетких функций принадлежности (в нечетких множествах) и шаблонов КНС. В ПНКНС каждое нечеткое правило соответствует КНС. Следовательно, каждая КНС заботится о нечетко разделенной проблемной области, и функция всех КНС интегрированных через нечеткий механизм логического вывода.

ПНКНС создана в форме повторной ННС. Две важных стороны изучения задач ННС – структурная идентификация и идентификация параметров [8]. Структурная идентификация является разделом входного-выходного пространства, которое влияет на число сгенерированных нечетких правил, соответствующих КНС. Целесообразной частью входных и выходных данных является быстрая сходимость и большая эффективность ННС. Для структурного обучения ПНКНС предложен адаптивный, независимый компонентный анализ (НКА). В основном, НКА находит направления поиска во входном пространстве, которое является причиной получения независимой составляющей взамен на некоррелированные по принципу

компонентного анализа (ПКА). Это уменьшает не только количество правил (например, КНС), но также и количество функций принадлежности согласно предварительно заданным требованиям динамической точности. В изучении параметров ПНКНС применяется упорядоченное производное исчисление для получения периодических правил обучения, благодаря которым достигается возвратная структура ПНКНС, унаследованная от КНС. Выведенные правила могут рационально запоминать шаблоны КНС и другие параметры ПНКНС. Предлагаемые ПНКНС обеспечивают решение текущей задачи при создании шаблонов и/или нечетких правил существующей встроенной (нечеткой) системы КНС. Это может найти широкое применение при построении прогнозных моделей поведения сложных динамических систем, содержащих многочисленные изменяющиеся во времени параметры при взаимодействии с различными характеристиками окружающей среды. Экспериментальные результаты демонстрируют, что предлагаемая схема является эффективной и перспективной [8].

Заключение. В результате можно сделать вывод, что для сокращения времени разработки новой технической системы, повышения достоверности и оперативности контроля механических свойств компонентов ее конструкции целесообразно решать задачи синтеза программ испытаний прогнозных моделей в нейросетевом базисе.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. *Прохорович В.Е.* Прогнозирование состояния сложных технических комплексов. – СПб.: Наука, 1999.
2. *Растринин Л.А., Пономорев Ю.П.* Экстраполяционные методы проектирования и управления. – М.: Машиностроение, 1986.
3. *Оссовский С.* Нейронные сети для обработки информации / Пер. с польского И.Д. Рудинского. – М.: Финансы и статистика, 2002.
4. *Назаров А.В., Лоскутов А.И.* Нейросетевые алгоритмы прогнозирования и оптимизации систем. – СПб.: Наука и Техника, 2003.
5. *I. Szatmari, D. Balya, G. Timar, C. Rekeczky, and T. Roska.* Multi-channel spatio-temporal topographic processing for visual search and navigation. in Proc. SPIE Microtechnologies for the New Millenium, Gran Canaria, Spain, May 2003, Paper 5119-38.
6. *F. Colodro and A. Torralba.* Cellular neuro-fuzzy networks (CNFNs), a new class of cellular networks. in Proc. 5th IEEE Int. Conf. Fuzzy Systems, vol. 1, Sept. 8-11, 1996, pp. 517-521.
7. *Cs. Rekeczky, T. Roska, and A. Ushida.* CNN-based difference-controlled adaptive nonlinear image filters. Int. J. Circuit Theory Applicat., vol. 26, 1998, pp. 375-423.
8. *C. T. Lin, C. L. Chang, and W. C. Cheng.* A recurrent fuzzy neural network system with automatic structure and template learning. IEEE Transactions on circuits and systems – I: Regular papers, vol. 51, no. 5, May 2004, pp. 1024-1035.

В.А. Литвиненко, С.А. Ховансков

ОРГАНИЗАЦИЯ РАСПРЕДЕЛЕННЫХ ВЫЧИСЛЕНИЙ НА ОСНОВЕ МУЛЬТИАГЕНТНОГО ПОДХОДА

При решении задач требующих обработки большого объема данных возникает проблема получения решения за приемлемое время. Одним из путей выполнения ограничения на временной ресурс является разделение всего объема вычислений между несколькими центрами обработки данных [1]. Обычно в качестве центров обработки используются работающие совместно персональные компьютеры.