

ТЕОРИЯ И МОДЕЛИРОВАНИЕ ГЕТЕРОГЕННЫХ ПОЛИНОМИАЛЬНЫХ НЕЙРОННЫХ СЕТЕЙ

А.В.ТИМОФЕЕВ

Санкт-Петербургский институт информатики и автоматизации РАН

СПИИРАН, 14-я линия ВО, д.39, Санкт-Петербург, 199178

<tav@iias.spb.su>

УДК 62.50

Тимофеев А. В. Теория и моделирование гетерогенных полиномиальных нейронных сетей // Труды СПИИРАН. Вып. 4. — СПб.: Наука, 2007.

Аннотация. Рассмотрены различные математические модели, архитектуры и методы обучения, самоорганизации и минимизации сложности гетерогенных полиномиальных нейронных сетей (ПНС) в задачах векторного (расширенного) распознавания образов, классификации данных и диагностики состояний. Получены конструктивные оценки степени гетерогенности и параллелизма в процессе автономного принятия классифицирующих решений с помощью ПНС различных типов. Показано, что параллелизм, самоорганизация и робастность гетерогенных ПНС могут значительно возрасти при коллективном (мульти-агентном) решении сложных задач распознавания образов, анализа изображений, развернутой (векторной) диагностики состояний и адаптивной маршрутизации информационных потоков. — Библ. 14 назв.

UDC 62.50

Timofeev A. V. Theory and modeling for heterogeneous polynomial neural networks // SPIIRAS Proceedings. Issue 4. — SPb.: Nauka, 2007.

Abstract. We consider different mathematical models, architectures and methods for learning, self-organization and minimization of complexity for heterogeneous polynomial neural networks (PNN) in problems of vector (widened) pattern recognition, data classification and diagnostics of states. Constructive estimates for the heterogeneity index and parallelism in the process of autonomous classifying decision making with the use of PNNs of different kinds are obtained. It is shown that the parallelism, self-organization, and robustness of heterogeneous PNNs can significantly increase in group (multiagent) solutions of difficult problems in pattern recognition, image analysis, large-scale (vector) diagnostics of states, and adaptive routing of data flows. — Bibl. 14 items.

1. Введение

Нейронные сети (НС) и нейросетевые технологии являются одним из наиболее эффективных средств массового распараллеливания и ускорения процессов обработки и передачи потоков данных в задачах распознавания образов, классификации данных и диагностики состояний. Естественным прототипом искусственных НС является биологический мозг и центральная нервная система человека и животных как сложная гетерогенная нейронная сеть, обеспечивающая высокую степень параллелизма, адаптации, самоорганизации и робастности при решении различных интеллектуальных задач (представление знаний, распознавание образов, классификация данных, поиск закономерностей, анализ изображений, диагностика состояний, прогнозирование явлений и т.п.). Возможности искусственных и биологических НС могут значительно расширяться при коллективном (мультиагентном) решении сложных интеллектуальных задач.

2. Архитектура и принципы построения гетерогенных полиномиальных нейронных сетей

Высокая сложность и размерность многих задач распознавания образов, классификации данных, анализа изображений и диагностики состояний, а также часто возникающая необходимость их решения в реальном времени требуют массового параллелизма и самоорганизации распределённых вычислений на базе НС. С этой точки зрения особый интерес и дополнительные возможности представляют гетерогенные полиномиальные нейронные сети (ПНС) с самоорганизующейся архитектурой и их разновидности, предложенные в работах [1–9].

Основные идеи, математические модели, методы оптимизации, алгоритмы обучения и принципы самоорганизации гетерогенных ПНС были предложены сначала в [1–3], а затем развиты в [4–9]. К ним прежде всего относятся следующие:

- архитектура ПНС гетерогенна и многослойна;
- наличие слоя полиномиальных нейронных элементов (П-нейронов);
- возможность обучения и адаптации ПНС к обучающим базам данных (БД);
- целесообразность самоорганизации архитектуры ПНС различных типов в процессе обучения;
- детерминированные, логические и вероятностные методы обучения и самоорганизации гетерогенных ПНС;
- принцип высокой экстраполяции (экстраполирующей силы) гетерогенных ПНС;
- алгебраическое требование диофантовости (целочисленность синаптических весов) гетерогенных ПНС.

В процессе дальнейшего развития теории гетерогенных ПНС были предложены модели многозначных нейронных элементов (М-нейронов) и связанных с ними конъюнктивных, полиномиальных, дизъюнктивных и суммирующих нейронных элементов (МК-, МП-, МД- и МΣ-нейронов), а также новые разновидности гетерогенных ПНС (генно-нейронные сети, квантовые нейронные сети, мульти-агентные ПНС и т.п.), описанные в [4–14].

В настоящей статье анализируются гетерогенность архитектуры, возможности самоорганизации распределённых вычислений и степень параллелизма ПНС различных типов, предназначенных для распознавания образов, диагностики состояний и решения других интеллектуальных задач (data mining, knowledge discovery и т.п.). Полученные теоретические (априорные) оценки степени параллелизма и самоорганизации гетерогенных ПНС подтверждаются экспериментальными результатами решения прикладных задач. Значительный интерес представляют также новые проблемы алгоритмы принятия коллективных (мульти-агентных) решений на базе гетерогенных ПНС.

3. Обобщенная постановка задач распознавания, классификации и идентификации образов

ПНС с гетерогенной архитектурой предназначены для решения сложных интеллектуальных задач. Примерами таких задач могут служить задачи распознавания образов, классификации данных, диагностики состояний, идентификации объектов, поиска и представления знаний и т.п. Обычно эти задачи формулируются следующим образом.

Пусть задано конечное множество объектов $\{\omega\} = \Omega$ и существует (но неизвестно) его разбиение на K непустых подмножеств (классов) вида

$$\Omega = \bigcup_{k=1}^K \Omega_k, \Omega_k \neq \emptyset, \Omega_k \cap \Omega_j = \emptyset \text{ при } k \neq j. \quad (1)$$

Это означает, что существует неизвестная классифицирующая функция $R(\omega)$, ставящая в соответствие каждому объекту $\omega \in \Omega$ номер класса k , к которому он принадлежит, т.е.

$$R(\omega) = k, \omega \in \Omega_k, k = 1, 2, \dots, K. \quad (2)$$

Кроме того, существует множество неизвестных идентифицирующих функций вида

$$R_k(\omega) = \begin{cases} 1, & \text{если } \omega \in \Omega_k, \\ 0 & \text{– в противном случае,} \end{cases} \quad (3)$$

являющихся характеристическими функциями классов $\Omega_k, k = 1, 2, \dots, m, K$, которые отделяют все объекты $\omega \in \Omega_k$ от остальных.

Предположим, что имеется некоторая измерительная система (датчики информации, сенсоры, измерительные приборы и т.п.), которая в результате измерения свойств или определения характеристик любого объекта $\omega \in \Omega$ однозначно ставит в соответствие объекту ω его информационное описание в виде вектора исходных признаков $x(\omega) = |x_i(\omega)|_{i=1}^n$. Тогда векторная функция

$$x : \Omega \rightarrow R^n$$

определяет отображение множества объектов Ω в n -мерное пространство признаков R^n . Это отображение порождает разбиение описаний объектов в пространстве признаков R^n на классы (образы) вида $X_k = x(\Omega_k), k = 1, 2, \dots, K$.

Отображение $x : \Omega \rightarrow R^n$ будем называть корректным или информативным, если выполняются следующие условия:

$$1) \quad \text{если } x(\omega_i) = x(\omega_j), \text{ то } R(\omega_i) = R(\omega_j), \quad (4)$$

т.е. объекты ω_i и ω_j с одинаковым описанием принадлежат одному классу,

$$2) \quad \text{если } R(\omega_i) \neq R(\omega_j), \text{ то } x(\omega_i) \neq x(\omega_j), \quad (5)$$

т.е. объектам ω_i и ω_j из разных классов соответствуют различные описания.

Таким образом, корректное отображение объектов в пространство признаков не приводит к потере информации о классах (образах). Это информативное отображение определяет следующее разбиение описаний объектов на классы (образы)

$$X = \bigcup_{k=1}^K X_k, X = x(\Omega_k) \neq \emptyset \quad (6)$$

Из соотношений (1) – (6) следует, что если $\omega \in \Omega_k$, то $x(\omega) \in X_k$, и наоборот. В том случае, когда $|\Omega| > |X|$, корректное (информативное) отображение $x(\omega) \in X_k$ является сжимающим.

Будем считать, что отображение $x: \Omega \rightarrow R^n$ является информативным и, возможно, сжимающим. Тогда задачи классификации и идентификации образов сводятся к восстановлению (определению) неизвестных решающих функций вида (2) и (3). При этом единственной доступной информацией о классах (1) являются табличные базы данных вида

$$\{x(\omega_h), R(\omega_h)\}_{h=1}^m \text{ или } \{x(\omega_h), R_1(\omega_h), R_2(\omega_h), \dots, R_K(\omega_h)\}_{h=1}^m, \quad (7)$$

называемые обучающей выборкой.

Мощность этой выборки $m \geq K$ должна быть достаточно большой, т.е. множество (7) должно быть репрезентативным. Поэтому будем предполагать, что множество (7) содержит достаточную информацию об априорном разбиении объектов (1) и их описании (6) на классы (образы). В частности, важно, чтобы обучающее множество (7) было полным, т.е. содержало хотя бы по одному объекту из каждого класса, и непротиворечивым, т.е. не содержало одинаковых описаний, относящихся к объектам из разных классов.

Наряду с классическими задачами классификации и идентификации образов с помощью скалярных решающих функций вида (2) и (3), значительный интерес для практики представляет их обобщение на случай векторного распознавания образов и расширенной диагностики состояний. Примером таких задач могут служить сложные задачи медицинской диагностики, когда требуется для каждого больного $\omega \in \Omega$ с вектором симптомов признаков $x(\omega)$ определить не только диагноз, т.е. класс заболеваний Ω_k , к которому он относится, но и дать его «расшифровку», т.е. найти ряд уточняющих и детализирующих характеристик в виде вектора

$$z(\omega) = |z_j(\omega)|_{j=1}^q, \quad (8)$$

где $z_j(\omega)$ — многозначные предикаты, принимающие целочисленные значения в интервале $[0, p_j]$.

Формально развернутый (детализирующий) диагноз можно представить в виде $(q+1)$ -мерного вектора

$$L(\omega) = |R(\omega), z_1(\omega), z_2(\omega), \dots, z_q(\omega)|, \quad (9)$$

Компонентами этого вектора является классифицирующий предикат $R(\omega)$ с целочисленными значениями (кодами) основного диагноза из интервала $[1, \dots, K]$ и детализирующие этот диагноз дополнительные многозначные предикаты $z_j(\omega)$, $j = 1, 2, \dots, q$, каждому из которых можно поставить в соответствие локальную «расшифровку» основного диагноза на естественном языке.

При обобщенном векторном распознавании образов главный предикат $R(\omega)$ описывает априорное разбиение множества Ω на классы (1), а дополнительные предикаты $z_j(\omega)$ определяют разбиение каждого класса Ω_k на подклассы вида

$$\Omega_k = \bigcup_{j=1}^q \Omega_{k,j}, k = 1, 2, \dots, K.. \quad (10)$$

Предикаты $R(\omega)$ и $z_j(\omega)$ заранее неизвестны. Однако известны из значения на обучающей выборке вида

$$\{x(\omega_h), R(\omega_h), z_1(\omega_h), z_2(\omega_h), \dots, z_q(\omega_h)\}_{h=1}^m. \quad (11)$$

По этим данным требуется восстановить (определить) неизвестную вектор-функцию (9) и ее компоненты (2) и (8).

Некоторые методы решения этой обобщенной задачи векторного (расширенного) распознавания образов на базе обучения и самоорганизации гетерогенных ПНС предложено в работах [11–13].

4. Нейросетевые архитектуры и алгоритмы

В настоящее время известно много математических и эвристических подходов к решению сформулированных задач скалярного распознавания, классификации и идентификации образов. Среди них важную роль играют нейросетевые подходы, основанные на синтезе различных моделей (архитектур) и алгоритмов обучения НС для распознавания образов и диагностики состояний.

Однако во многих случаях эти НС (например, перцептроны) имеют гомогенную архитектуру. При этом заранее не известно, какое число слоёв и нейроэлементов необходимо для решения задачи. Алгоритмы обучения таких гомогенных НС не всегда сходятся к решению задачи за конечное число шагов.

Примерами гомогенных НС могут служить однослойные НС Хопфилда или Хемминга или многослойные перцептроны, использующие пороговые или сигмоидальные нейроэлементы. Популярными сегодня градиентные алгоритмы обучения гомогенных НС типа Backpropagation и его модификации (Quick propagation, Rpro и т.п.) медленно сходятся или вообще не приводят к решению задачи за конечное время.

Описываемые ниже гетерогенные ПНС различных типов являются эффективным средством восстановления (определения) неизвестных классифицирующих и идентифицирующих функций (2) и (3) по обучающим базам данных (7) и их реализации на базе ПНС с самоорганизующейся архитектурой минимальной сложности. В основе теории этих гетерогенных ПНС лежат идеи и принципы, сформулированные выше, а также ранее в работах [1–9].

Предлагаемые гетерогенные ПНС позволяют также решать обобщенные задачи векторного распознавания и описания образов, т.е. восстанавливать (определять) неизвестные векторные решающие функции (9) по расширенным обучающим выборкам вида (11).

Кроме того, они могут успешно использоваться в качестве нейросетевых агентов при коллективном (мультиагентном) решении сложных (глобальных) задач распознавания образов, расширенной (векторной) диагностики состояний и адаптивной маршрутизации информационных потоков [7 –14].

5. Гетерогенность, параллелизм и самоорганизация порогово-полиномиальных нейронных сетей

Архитектура ПНС гетерогенна и представляет собой последовательность нескольких однородных слоев параллельно работающих нейроэлементов (НЭ) различных типов. В различных слоях гетерогенной ППС могут использоваться разные НЭ, но каждый слой (подмножество НЭ) является однородным (гомогенным). При этом обработка информации в каждом слое НЭ осуществляется параллельно.

Каналы связи между предыдущим и последующим слоями гетерогенной ПНС являются однонаправленными (односторонними) и имеют регулируемые веса (синаптические параметры). Эти веса каналов связи настраиваются в процессе обучения и самоорганизации архитектуры ПНС по имеющимся экспериментальным данным или прецедентам вида (7), называемым обучающей базой данных (ОБД).

Опишем формально гетерогенную архитектуру трёхслойной порогово-полиномиальной нейронной сети (ППНС) [1-4] и рассмотрим принципы ее самоорганизации.

Первый слой ППНС состоит из n пороговых нейроэлементов (НЭ), на вход которых параллельно поступают сигналы $y_1(\omega), \dots, y_n(\omega)$, характеризующие различные свойства объекта ω , а на выходе формируется вектор двоичных сигналов (бинарный код) $x(\omega) = \{x_i\}_{i=1}^n$, где $x_i = x_i(y_1, \dots, y_n)$. Этот бинарный код является выходом НЭ первого слоя ППНС.

На входы каждого «ассоциативного» НЭ второго слоя поступает вектор $x(\omega)$ бинарных сигналов с «рецепторных» (кодирующих) пороговых НЭ первого слоя. Эти «ассоциативные» НЭ реализуют полиномиальные преобразования $a_j(x)$ входных сигналов и называются П-нейронами или мультипликативными НЭ. Выходом второго слоя ППНС является вектор двоичных сигналов

$$a(x) = \{a_j(x)\}_{j=1}^N, \quad a_j(x) = \prod_{i=1}^n x_i^{x_i(y_j)}, \quad j = 1, \dots, m. \quad (12)$$

Здесь m – число элементов (мощность) ОБД, определяющее оценку сверху на число N необходимых полиномиальных НЭ второго слоя ППНС, т.е. $m \geq N \geq K$.

Третий слой ППНС состоит из «решающих» пороговых НЭ, на вход которых поступает вектор выходных сигналов $a_j(x)$ полиномиальных НЭ второго слоя. Затем эти сигналы умножаются на синаптические веса u_j , суммируются и преобразуются в выходные сигналы НЭ третьего слоя в виде суперпозиций функций

$$R_k(\omega) = \text{sign} \left(\sum_{j=1}^N u_{k,j} a_j(x(y(\omega))), \quad k = 1, \dots, K, \quad (13)$$

где $u_{k,j}$ – настраиваемые синаптические параметры, а K — число непересекающихся классов (образов).

Каждая решающая (идентифицирующая) функция $R_k(\omega)$ вида (8) является характеристической функцией k -го класса. Поэтому она отделяет объекты k -го класса от остальных. Множество таких идентифицирующих функций (8) решает задачу классификации образов.

Принцип самоорганизации ППНС с гетерогенной архитектурой заключается в построении «ассоциативных» полиномов $a_i(x)$ непосредственно по обучающей базе данных (ОБД) (7) в виде одночленов [1–3]

Чтобы минимизировать сложность ППНС, нужно найти в идентифицирующих функциях вида (8) векторы синаптических параметров $u_k = |u_{k,j}|_{j=1}^N$ с максимальным числом нулевых компонент. Это приводит к автоматической ликвидации неинформативных (избыточных) синаптических связей в гетерогенной ППНС без потери точности принимаемых решений на ОБД (7).

Быстрые рекуррентные алгоритмы обучения и минимизации сложности гетерогенной ППНС были предложены в [1–4]. Они осуществляют отображение ОБД вида (7) на множество синаптических параметров пороговых НЭ третьего слоя ППНС, причём число шагов алгоритма обучения $r \leq m$.

Степень параллелизма при распознавании и идентификации образов определяется тем, что принятие решений осуществляется ППНС за 3 такта одновременных вычислений в каждом слое НЭ независимо от размерности решаемой задачи $D = n \times m \times k$.

Самоорганизация ППНС обеспечивается тем, что НЭ второго слоя формируются, согласно (9), непосредственно по ОБД (7).

Гетерогенность архитектуры ППНС определяется тем, что первый и третий слои состоят из пороговых НЭ, а второй слой – только из полиномиальных НЭ.

6. Гетерогенность, параллелизм и самоорганизация диофантовых и сплайновых нейронных сетей

Гетерогенные ПНС с многозначными входами-предикатами и целочисленными синаптическими параметрами называются диофантовыми НС [1,5]. Примерами диофантовых НС с самоорганизующейся архитектурой, могут служить гетерогенные ПНС, предложенные в [1–3].

Рассмотрим другой класс диофантовых НС. Гетерогенность их архитектуры определяется использованием слоёв, состоящих из полиномиальных или сплайновых НЭ.

Первый слой диофантовой НС состоит из пороговых НЭ. Выходом первого слоя НЭ является двоичный образ (описание) $x(\omega)$ объекта ω .

НЭ второго слоя кодируют двоичные образы $x(\omega)$ натуральными числами вида

$$d(\omega) = \sum_{i=1}^n x_i(\omega) \cdot 2^{n-i}. \quad (14)$$

Для упрощения алгоритмов обучения и самоорганизации гетерогенной архитектуры диофантовой НС построим НЭ третьего слоя в виде ортогональных полиномов (одночленов) вида

$$a_j(d(\omega)) = \prod_{\substack{h=1 \\ j \neq h}}^{m_k} (d(\omega) - d(\omega_h))(d(\omega_j) - d(\omega_h))^{-1}. \quad (15)$$

Другие способы построения НЭ третьего слоя предложены в [5].

Четвёртый слой гетерогенной диофантовой НС состоит из «решающих» пороговых НЭ с синаптическими параметрами, настраиваемыми по ОБД (7) согласно быстрым алгоритмам обучения, предложенным в [5].

Описанные диофантовые НС целесообразно применять на сравнительно коротких ОБД вида (7). Чтобы ослабить это ограничение, рассмотрим гетерогенные сплайновые НС.

Сплайновые НС основаны на кусочно-полиномиальной или сплайновой аппроксимации решающих (идентифицирующих) функций вида (8). Идея состоит в синтезе НЭ по ОБД (7) в виде независимых друг от друга полиномов или сплайнов на каждой паре натуральных чисел $\{d(\omega_i), d(\omega_{i+1})\}$ и их коммутации по определённым правилам в четвертом слое НС, состоящем из пороговых НЭ с настраиваемыми по ОБД (7) синаптическими параметрами [5].

Синтезированные диофантовые и сплайновые НС имеют четырёхслойную гетерогенную архитектуру, описываемую суперпозицией параллельных преобразований в каждом слое НЭ.

Самоорганизация и минимизация сложности гетерогенной архитектуры таких НС обеспечиваются самонастройкой полиномиальных и сплайновых НЭ второго и третьего слоев (например, вида (10) и (11)) и быстрыми алгоритмами обучения пороговых НЭ четвертого слоя, требующими только однократного использования ОБД вида (7), т.е. $r \leq m$.

При распознавании образов и диагностике состояний принятие решений с помощью описанных диофантовой или сплайновой ПНС осуществляется за 4 такта параллельных вычислений в каждом слое НЭ независимо от размерности задачи $D = n \times m \times K$.

Гетерогенность архитектуры диофантовых и сплайновых НС определяется тем, что первый и четвертый слой состоят из пороговых НЭ, а второй и третий слой включают полиномиальные или сплайновые НЭ.

7. Гетерогенность, параллелизм и самоорганизация распознающих полиномиальных нейронных сетей

Рассмотрим четырёхслойную ПНС, предназначенную для распознавания образов или решения подобных интеллектуальных задач.

Первый слой этой ПНС состоит из функциональных НЭ (F -элементов) $F_i(y(\omega), \gamma_i)$ с синаптическими параметрами γ_i .

Второй слой этой гетерогенной ПНС состоит из полиномиальных НЭ (P -элементов) вида

$$a_j(\omega) = \prod_{i \in I_j} F_i(y(\omega), \gamma_i), \quad (16)$$

где $F(y, \gamma) = 0$ при $y < \gamma$ и $F(\gamma, \gamma) \neq 0$ [6,9].

Третий слой ПНС состоит из одного суммирующего НЭ (Σ -нейрона).

Четвёртый слой ПНС состоит из одного многозначного НЭ (M -нейрона), описываемого K -значным предикатом M , принимающим значения $1, 2, \dots, K$ и определяющим принадлежность объекта ω к одному из классов Ω_k .

Четырёхслойная архитектура ПНС реализует следующее последовательно-параллельное преобразование вектора входных сигналов $y(\omega)$ в выходной целочисленный сигнал $R(\omega, u, \gamma)$ вида

$$R(\omega, u, \gamma) = M(u_0 + \sum_{j=1}^N u_j \prod_{i \in J_j} F_i(y(\omega); \gamma_i)), \quad (17)$$

определяющий номер класса k , к которому будет отнесён распознанный объект ω .

Задачи обучения, минимизации сложности и самоорганизации гетерогенных классифицирующих ПНС с аналитическим описанием вида (16), (17) заключаются в определении скалярных функций y, F_i и векторов синаптических параметров $\gamma = |\gamma_i|_{i=1}^J$ и $u = |u_i|_{i=1}^N$ по ОБД (7) таким образом, чтобы обеспечивалась не только безошибочная классификация объектов из ОБД (7), но и других распознаваемых (контрольных) объектов.

Для решения этой задачи нужно конструктивно задать функциональные НЭ $F_i(y, \gamma_j)$ и векторы синаптических параметров γ и u с возможно меньшим числом ненулевых компонент [5–7].

Степень параллелизма в классифицирующих ПНС, описываемых многозначным предикатом (17) определяется тем, что распознавание образов, классификация данных или диагностика состояний осуществляются за 4 такта параллельных вычислений в НЭ разных слоев независимо от сложности решаемой задачи $D = n \times m \times K$.

Гетерогенность архитектуры этих ПНС характеризуется тем, что первый слой состоит из функциональных НЭ, второй слой включает полиномиальные НЭ, а третий и четвертый слои содержат по одному суммирующему и многозначному НЭ.

8. Гетерогенность и параллелизм в геннонейронных сетях с самоорганизующейся архитектурой

Пусть имеется популяция $\{\omega\} = \Omega$ особей ω , каждая из которых может принадлежать одному из K образов (классов) согласно разбиению (1). Особь ω характеризуется набором признаков $x(\omega)$, которые принимают значения, соответствующие одному из дискретных состояний генов $x_j(\omega)$. При этом состояния каждого гена описываются многозначным предикатом.

Вектор $x(\omega) = |x_j(\omega)|_{j=1}^n$ состояний генов назовём хромосомой (локальное описание) особи ω . Будем говорить, что две особи имеют одинаковый генотип, если у них совпадают состояния всех генов, т.е.

$$x_j(\omega_j) = x_j(\omega_h), \quad \forall i = 1, 2, \dots, n, j \neq h. \quad (18)$$

Множество хромосом образует класс генотипов, соответствующих некоторому генетическому образу с характеристической функцией $R_k(\omega)$ вида (3).

Задачи генетического описания и распознавания образов сводятся к аппроксимации неизвестных функций $R(\omega), R_k(\omega)$ по генетическим (целочисленным) ОБД вида (7). Для решения этих задач можно использовать трёхслойную гетерогенную геннонейронную сеть (ГНС) полиномиального типа, описанную в [7].

Обученные ГНС обеспечивают массовый параллелизм при обработке генетических данных, а именно принятие оптимальных решений при распознавании образов или диагностике состояний осуществляется в ГНС за 3 такта параллельных вычислений в НЭ каждого слоя независимо от размерности задачи $D = n \times m \times K$.

Гетерогенность архитектуры ГНС проявляется в том, что первый и третий слои состоят из пороговых НЭ, а второй слой содержит полиномиальные НЭ.

Другой метод обучения и самоорганизации многослойных ГНС основан на логико-вероятностных генетических алгоритмах селекции информативных генов и конъюнктивных НЭ (K -нейронов) вида

$$a_j^n(\omega) = \bigwedge_{i=1}^n \xi_i^{\xi_j(\omega_j)}, j = 1, \dots, m, \quad (19)$$

а также на логико-вероятностных решающих (идентифицирующих) правилах импликативного типа

$$\{a_j^r(\omega) \rightarrow P_k(\omega)\}_{j=1}^N, 1 \leq r_1 \leq \dots \leq r_N < n. \quad (20)$$

Здесь P_k — максимальная апостериорная вероятность принадлежности особи ω k -му классу Ω_k , оцененная по ОБД вида (7).

Синтезированные генетические решающие (идентифицирующие) правила в случае, когда i -й ген может иметь только два состояния, можно представить в виде многослойной ГНС минимальной сложности, представляющей собой бинарное «дерево решений». Ветвям этого дерева соответствует K -нейроны вида (19), а листьям — номера классов генотипов [3,7].

В работах [7–9] представлено обобщение описанных ГНС на случай, когда каждый ген имеет не два, а произвольное число дискретных состояний, т.е. ген описывается многозначным предикатом вида

$$x(\omega) \in \{0, 1, \dots, l_j\}, l_j \geq 2. \quad (21)$$

Для увеличения параллелизма и быстродействия в процессе принятия оптимальных (в смысле критерия Байеса) решений описанные многослойные ГНС с древовидной архитектурой можно преобразовать в трёхслойные диофантовые ГНС с целочисленными синаптическими весами с помощью методов, описанных в [3,7]. В этом случае распознавание образов или диагностика состояний произойдет не за $r \leq r_N$ шагов, согласно (19) и (20), а за 3 такта параллельных целочисленных вычислений в каждом слое НЭ независимо от размерности задачи $D = n \times m \times K$.

Гетерогенность архитектуры синтезированной диофантовой ГНС характеризуется тем, что первый и третий слои состоят из пороговых НЭ, а второй слой включает конъюнктивные НЭ вида (19).

9. Параллелизм и самоорганизация в мультиагентных нейронных сетях с гомогенной или гетерогенной архитектурой

Традиционно гомогенные или гетерогенные НС используются для автономного принятия решений в задачах распознавания образов, представления знаний, диагностики состояний, классификации данных и т.п. По существу эти НС являются обучаемыми интеллектуальными агентами, которые настраиваются на индивидуальное (одно-агентное) решение конкретных задач по локальной ОБД вида (7).

В то же время существует большой класс интеллектуальных задач, требующих не только индивидуальных (одно-агентных), но и коллективных (мультиагентных) решений. Классическим примером этого могут служить особенно сложные и ответственные задачи медицинской диагностики, когда врачи вынуждены прибегать к помощи своих коллег для совместной постановки окончательного диагноза. При этом формируется «консилиум», т.е. профессиональная группа врачей, интегрирующая знания и опыт входящих в нее членов, для коллективного принятия наиболее правильных и сбалансированных диагностических решений.

Другим примером сложных задач, требующих коллективных решений, являются глобальные задачи, допускающие естественную (например, иерархическую или мультифрактальную) декомпозицию на множество локальных задач. В этом случае решение сложной (глобальной) задачи может быть распределено между интеллектуальными НС-агентами, специализирующимися на решении M частных (локальных) задач. Параллельная работа M таких НС-агентов может значительно ускорить обработку информации и повысить надежность решения общей (глобальной) задачи.

В роли интеллектуальных агентов могут выступать гомогенные или гетерогенные НС различных типов. Однако они должны быть взаимосвязаны с помощью каналов обмена информацией в процессе принятия коллективных решений. В этом случае можно создать мультиагентную (глобальную) систему обработки и передачи информации, интегрирующую в себе возможности входящих в неё локальных НС как агентов.

Архитектура таких мультиагентных НС может быть гомогенной или гетерогенной. В гомогенной архитектуре в качестве агентов используется гомогенные НС одного типа. Например, это могут быть гомогенные НС-агенты типа «перцептрон» или гетерогенные диофантовые ПНС.

В гетерогенной архитектуре используются НС-агенты различных (смешанных) типов. Например, они могут содержать разные типы гетерогенных ПНС или могут иметь специальных агентов-координаторов, организующих целенаправленную работу локальных НС-агентов.

Агенты-координаторы могут принимать коллективные (мульти-агентные) решения на основе локальных (одно-агентных) решений остальных НС как автономных агентов с помощью мажоритарных принципов или процедур голосования (например, по «большинству голосов») [11 – 14]. При этом все локальные решения принимаются M НС-агентами параллельно, что ускоряет принятие глобального (коллективного) решения в M раз.

В ряде случаев глобальная самоорганизация НС-агентов обеспечивается иерархической, фрактальной или мультифрактальной декомпозицией общей задачи на M подзадач. При этом степень внешнего (глобального) параллелиз-

ма в мультиагентной нейросетевой системе определяется параметром M , характеризующим одновременную работу M локальных НС-агентов, каждый из которых обладает внутренним (локальным) параллелизмом при решении интеллектуальных задач, характеризующимся числом слоев НЭ.

Мультиагентное распознавание сложных 2D-изображений или 3D-сцен в ряде случаев основывается на их декомпозиции на самоподобные (фрактальные) компоненты и на обучении и самонастройке локальных гетерогенных ПНС на распознавание фрагментов по локальным ОБД, характеризующим эти фрагменты. В результате внутренней и внешней самоорганизации ПНС как НС-агентов достигается высокая степень параллелизма в процессе распознавания и анализа сложных изображений и сцен.

Необходимость в использовании НС-агентов и мультиагентных технологий возникает в глобальных телекоммуникационных и компьютерных сетях [10]. В этом случае НС-агенты обучаются и самоорганизуются по локальным ОБД вида (7) и передают по каналам связи накопленные «нейрознания» и «опыт» другим НС-агентам. Для эффективного (в частности, оптимального) управления потоками данных между удалёнными сетевыми пользователями как внешними агентами (клиентами) и локальными НС как внутренними агентами целесообразно использовать нейросетевые маршрутизаторы потоков данных [10], позволяющие адаптироваться к непредсказуемым изменениям структуры (топологии) и параметров глобальных телекоммуникационных и компьютерных сетей в процессе их функционирования в реальном времени.

10. Заключение

Описанные гетерогенные архитектуры и быстрые алгоритмы обучения ПНС разных типов обеспечивают высокий параллелизм и самоорганизацию нейровычислений в процессе решения многих интеллектуальных задач. Они успешно применялись для решения ряда прикладных задач распознавания образов (распознавание кораблей по отраженным радиолокационным сигналам, распознавание и адресация деталей на конвейере, классификация дорожных ситуаций и т.д.), медицинской диагностики (диагностика и оценка эффективности лечения артритов, векторная диагностика и расшифровка гастритов и т.д.), прогнозирования явлений (прогнозирование градоопасности облаков и исхода черепно-мозговых травм и т.д.) и нейросетевого представления генетического кода [1–9, 11, 12]. Модифицированные НС Хопфилда успешно использовались для решения задач мультиагентной маршрутизации параллельных потоков данных в глобальных телекоммуникационных и компьютерных сетях с переменной структурой [10].

Мультиагентные нейросетевые технологии на базе гетерогенных диофантовых НС и процедур голосования позволили значительно повысить точность и робастность векторной (расширенной) диагностики гастритов [12–14].

Важное значение для эффективного распознавания образов и диагностики состояний в реальном времени представляет тот факт, что аккумулируемые в гетерогенных ПНС с самоорганизующейся архитектурой «нейрообразы» и решающие (классифицирующие и идентифицирующие) правила обеспечивают массовый параллелизм, хорошую экстраполяцию (экстраполирующую силу) и высокое быстродействие при принятии оптимальных или субоптимальных решений.

Коллективное (мультиагентное) использование гетерогенных ПНС в качестве нейросетевых агентов позволяет дополнительно распараллелить и распределить между локальными НС-агентами процессы решения сложных (глобальных) задач распознавания образов, анализа изображений и сцен, расширенной (векторной) диагностики состояний и адаптивной маршрутизации информационных потоков.

Работа выполнена при частичной поддержке грантов по проекту 1.6. Программы фундаментальных исследований Президиума РАН № 15 “GRID”, проекту Целевой Программы Президиума РАН «Поддержка инноваций», проекту Программы Президиума РАН «Фундаментальные науки — медицине» и гранта РФФИ № 06-08-01612-а.

Литература

1. Тимофеев А.В. Об одном классе полиномиальных разделяющих функций в задачах опознавания и диагностики // Методы вычислений. Л.: Изд-во ЛГУ, 1971. Вып.7. С. 106–121.
2. Пшибихов В.Х., Тимофеев А.В. Алгоритмы обучения и минимизации сложности полиномиальной опознающей системы // Изв. АН СССР. Техническая кибернетика. 1974. № 5. С. 214–217.
3. Timofeev A.V. Intelligent control applied to non-linear systems and neural networks with adaptive architecture // International Journal on Intelligent Control, Neurocomputing and Fuzzy Logic, 1997, Vol.1, no. 1. P. 1–18.
4. Каляев А.В., Тимофеев А.В. Методы обучения и минимизации сложности когнитивных нейро-модулей нейрокомпьютера с программируемой архитектурой // Доклады АН. 1994. Т. 237. С. 180–183.
5. Тимофеев А.В. Методы синтеза диофантовых нейросетей минимальной сложности. // Доклады АН. 1995. Т.301, № 3. С.1106–1109.
6. Тимофеев А.В., Шибзухов З.М. Методы синтеза и минимизации сложности диофантовых нейронных сетей над конечным полем // Автоматика и телемеханика. 1997. № 4. С. 204–212.
7. Тимофеев А.В. Оптимальный синтез и минимизация сложности генно-нейронных сетей по генетическим базам данных // Нейрокомпьютеры: разработка и применение. 2002. № 5–6. С. 34–39.
8. Тимофеев А.В., Шибзухов З.М., Шеожев А.М. Синтез нейросетевых архитектур по многозначному дереву решений. // Нейрокомпьютеры: разработка и применение. 2002. № 5–6. С. 44–49.
9. Timofeev A.V. Polynomial neural network with self-organizing architecture. // International Journal on Optical Memory and Neural Networks. 2004. no. 2. P. 25–30.
10. Timofeev A.V. Multi-agent information processing and adaptive control in global telecommunication and computer networks // Journal on Information Theories and Applications. 2003. Vol. 10, no. 1. P. 54–60.
11. Тимофеев А.В., Шеожев А.М. Методы построения обучающих выборок для развернутой медицинской диагностики на базе нейросетевых технологий // Доклады АМАН. 2000. Т. 5, № 1. С. 69–71.
12. Тимофеев А.В., Шибзухов З.М., Шеожев А.М. Применение диофантовых нейронных систем для генетического анализа и диагностики // Труды 6-го Санкт-Петербургского симпозиума по теории адаптивных систем “SPAS-99”. СПб: Омега, 1999. Т.2. С. 169–171.
13. Тимофеев А.В., Шибзухов З.М., Шеожев А.М. Проектирование и обучение мульти-агентных диагностических систем // Труды I-ой Международной конференции по мехатронике и робототехнике “M&R-2000”. СПб. 2000. Т. 2. С. 342–345.
14. Timofeev A.V. Parallelism and self-organization in polynomial neural networks for image recognition // Pattern Recognition and Image Analysis. 2005. Vol. 15, no.1. P. 97–100.
15. Тимофеев А.В., Сырцев А.В. Модели и методы маршрутизации потоков данных в телекоммуникационных системах с изменяющейся динамикой. М.: Новые технологии, 2005. 85 с.
16. Timofeev A.V. Parallel structures and self-organization of heterogeneous polynomial neural networks for pattern recognition and diagnostics of states // Pattern Recognition and Image Analysis. 2007. Vol. 17, no. 1. P. 163–169.

17. *Сырцев А.В., Тимофеев А.В.* Нейросетевые модели и методы маршрутизации в динамических телекоммуникационных системах // Нейрокомпьютеры: разработка и применение. 2005. № 10–11. С.14–22.
18. *Тимофеев А.В., Шибзухов З.М., Шеожев А.М.* Мультиагентные диофантовые нейронные сети в задачах распознавания и диагностики // Нейрокомпьютеры: разработка и применение. 2005. № 10–11. С.69–74.