

УДК 621.391

Р.М. КАБАКЧЕЙ

Полтавский военный институт связи, Украина

ВЫБОР ОПТИМАЛЬНОЙ АРХИТЕКТУРЫ ИСКУССТВЕННОЙ НЕЙРОННОЙ СЕТИ ПРИ ПОСТРОЕНИИ ЭКСПЕРТНОЙ СИСТЕМЫ СРЕДСТВ ДИАГНОСТИКИ КОРПОРАТИВНЫХ ИНФОРМАЦИОННЫХ СЕТЕЙ

В статье проведен анализ существующих на сегодняшний день основных моделей искусственных нейронных сетей. Рассмотрен вопрос выбора оптимальной модели нейронной сети для использования ее в составе интеллектуальных систем для решения задач диагностирования дефектов, в частности в экспертной системе сетевых диагностирующих средств.

искусственная нейронная сеть, ансамбль нейронных сетей, экспертная система, диагностика

Введение

В последнее время разработчики прикладных интеллектуальных систем все чаще применяют гибридный подход к реализации систем искусственного интеллекта (ИИ)[1 – 3]. Данный подход основан на применении логической обработки данных классическими методами инженерии знаний и ассоциативной обработки данных нейронными сетями. Его применение позволяет использовать результаты, достигнутые в технике представления знаний, с ее удобством визуализации, вербализации и формализации знаний. Также он позволяет использовать возможности обучения и естественной работы с нечеткими знаниями, свойственными ИНС.

Интеллектуальные системы на основе искусственных нейронных сетей (ИНС) позволяют с успехом решать проблемы кластеризации, классификации (распознавания) образов, выполнения прогнозов, оптимизации, и т.д. Это в свою очередь можно эффективно использовать при построении и модернизации современных сетевых диагностирующих средств. Известны и иные, более традиционные подходы к решению данного рода задач [2], однако они не обладают необходимой гибкостью за пределами ограниченных условий. ИНС дают многообещающие альтернативные решения и могут быть успешно использованы в средствах диагностирования

дефектов корпоративных информационных сетей (КИС) для повышения эффективности локализации сетевых дефектов. Правильно выбрав модель ИНС и совместив ее с другими видами ИИ, можно получить так называемую гибридную экспертную систему (ЭС), которая намного облегчит работу сетевых администраторов в процессе диагностирования даже при возникновении дефектов, с которыми они ранее не сталкивались при диагностике сети.

Обзор существующих моделей ИНС и их особенности

ИНС можно рассматривать как направленный граф со взвешенными связями, в котором искусственные нейроны являются узлами. По архитектуре связей ИНС могут быть сгруппированы в два класса (рис. 1, 2): сети прямого распространения, в которых графы не имеют петель, и рекуррентные сети, или сети с обратными связями [1].

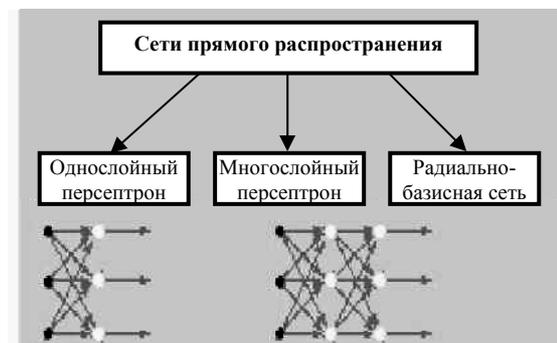


Рис. 1. Сети прямого распространения

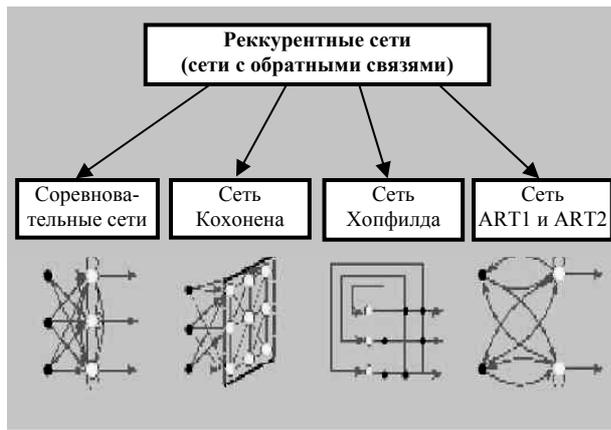


Рис. 2. Сети с обратными связями

В процессе работы ИНС нейроны возбуждаются (переходят в активное состояние). При этом в качестве функций активации могут быть выбраны различные функции. Наиболее часто используются следующие функции активации:

а) линейная, эквивалентная отсутствию порогового элемента: $f(x)=x$;

б) кусочно-линейная:

$$f(x)=\gamma, x \geq \gamma;$$

$$x, |x| < \gamma;$$

$$-\gamma, x \leq -\gamma;$$

в) ступенчатая пороговая:

$$f(x)=\gamma, x > 0;$$

$$-\gamma, x \leq 0;$$

г) сигмоидная:

$$S(x)=1/(1+1/\exp(x))$$

д) гиперболический тангенс:

$$S(x)=\tanh(x).$$

Способность к обучению является одним из уникальных свойств ИНС. Для ИНС процесс обучения представляет собой настройку архитектуры сети и весов связей ее элементов для эффективного выполнения возложенной на нее задачи.

Обычно нейронная сеть должна настроить веса связей по имеющейся обучающей выборке. Функционирование сети улучшается по мере итеративной настройки весовых коэффициентов.

Свойство сети обучаться на примерах делает их более привлекательными по сравнению с системами, которые следуют определенной системе правил

функционирования, сформулированной экспертами (например, экспертные системы).

Для конструирования процесса обучения, прежде всего, необходимо иметь модель внешней среды, в которой функционирует нейронная сеть – знать доступную для сети информацию. Эта модель определяет парадигму обучения [1].

Во-вторых, необходимо понять, как модифицировать весовые параметры сети – какие правила обучения управляют процессом настройки. Алгоритм обучения означает процедуру, в которой используются правила обучения для настройки весов.

Можно выделить три парадигмы обучения:

- "с учителем";
- "без учителя" (самообучение);
- смешанная.

В первом случае нейронная сеть располагает правильными ответами (выходами сети) на каждый входной пример. Веса настраиваются так, чтобы сеть производила ответы более близкие к известным правильным ответам. Усиленный вариант обучения с учителем предполагает, что известна только критическая оценка правильности выхода нейронной сети, но не сами правильные значения выхода.

Обучение без учителя не требует знания правильных ответов на каждый пример обучающей выборки. В этом случае раскрывается внутренняя структура данных или корреляции между образцами в системе данных, что позволяет распределить образцы по категориям. При смешанном обучении часть весов определяется посредством обучения с учителем, в то время как остальная получается с помощью самообучения.

Ниже приведена таблица (табл. 1), в которой отображены основные алгоритмы обучения и связанные с ними архитектуры ИНС.

Данная таблица также демонстрирует типы задач, которые решает та или иная ИНС. Как правило, каждый алгоритм обучения применяется для определенной архитектуры сети и решения ограниченного класса задач.

Таблица 1

Основные алгоритмы обучения ИНС

Парадигма	Обучающее правило	Архитектура	Алгоритм обучения	Задача	
С учителем	Коррекция ошибки	Однослойный и многослойный перцептрон	Алгоритмы обучения перцептрона Обратное распространение ошибки Adaline и Madaline	Классификация образов Аппроксимация функций Предсказание, управление	
	Правило Больцмана	Рекуррентная	Алгоритм обучения Больцмана	Классификация образов	
	Правило Хебба	Многослойная прямого распространения	Линейный дискриминантный анализ	Анализ данных Классификация образов	
	Соревнование	Соревнование	Сеть ART	ART Map	Категоризация внутри класса; сжатие данных
Сеть ART			ART Map	Классификация образов	
Без учителя	Коррекция ошибки	Многослойная прямого распространения	Проекция Саммона	Категоризация внутри класса; анализ данных	
	Правило Хебба	Прямого распространения или соревнование	Анализ главных компонентов	Анализ данных Сжатие данных	
		Сеть Хопфилда	Обучение ассоциативной памяти	Ассоциативная память	
	Соревнование	Соревнование	Сеть ART	ART Map	Категоризация внутри класса; сжатие данных
			SOM Кохонена	SOM Кохонена	Категоризация Анализ данных
			Сети ART	ART1, ART2	Категоризация
Смешанная	Коррекция ошибки и соревнование	Сеть RBF	Алгоритм обучения RBF	Классификация образов Аппроксимация функций Предсказание, управление	

Особенности функционирования систем искусственного интеллекта в средствах диагностики КИС

Одним из перспективных способов повышения эффективности функционирования средств диагностирования компьютерных информационных сетей является применение систем ИИ, а именно, ЭС различных конфигураций и сложности [7].

Перспективным же направлением систем ИИ средств диагностирования КИС являются гибридные ЭС. В гибридных ЭС представлены различные виды знаний. Главная задача при разработке таких систем состоит в оптимальном сочетании различных форм представления и методов обработки знаний в процессе принятия решения диагностической ЭС.

Среди специализированных систем, основанных на знаниях, наиболее значимы экспертные системы реального времени, или динамические экспертные системы. Классы задач, решаемых экспертными системами реального времени, имеют прямое отношение к сетевым средствам диагностирования: мониторинг в реальном масштабе времени, системы управления верхнего уровня, системы обнаружения неисправностей, диагностика, составление расписаний, планирование, оптимизация, системы-советчики оператора, системы проектирования. Статические экспертные системы не способны решать подобные задачи, так как они не выполняют требования, предъявляемые к системам, работающим в реальном времени [2]:

1. Представлять изменяющиеся во времени данные, поступающие от внешних источников, обеспечивать хранение и анализ изменяющихся данных.

2. Выполнять временные рассуждения о нескольких различных асинхронных процессах одновременно (т.е. планировать в соответствии с приоритетами обработку поступивших в систему процессов).

3. Обеспечивать механизм рассуждения при ограниченных ресурсах (время, память).

4. Обеспечивать "предсказуемость" поведения системы, т.е. гарантию того, что каждая задача будет запущена и завершена в строгом соответствии с временными ограничениями.

5. Моделировать "окружающий мир", рассматриваемый в данном приложении, обеспечивать создание различных его состояний.

6. Протоколировать свои действия и действия персонала, обеспечивать восстановление после сбоя.

7. Обеспечивать настройку системы на решаемые задачи (проблемная/предметная ориентированность).

8. Обеспечивать создание и поддержку пользовательских интерфейсов для различных категорий пользователей.

Из сказанного выше следует, что в современных средствах диагностирования ключевым моментом является использование ЭС реального времени комбинированной с ИНС.

База знаний такой ЭС содержит информацию в соответствии с методом диагностики, адаптированным в среде ЭС с учетом требований решаемой пользователем задачи. База знаний в среде гибридной ЭС образуется в виде отдельных понятий (формул, зависимостей, таблиц и нечетких правил), которые образуют ее структурную и физическую организацию. При этом формы представления знаний можно разделить на декларативные (описательные) и процедурные (вычислительные) [3]. Это разделение очень условно, так как в процессе принятия решения ЭС эффективно используются обе формы

представления знаний (логическая и сетевая). Это связано с тем, что на различных этапах диагностики сетей и локализации дефектов может использоваться различная степень детализации.

Так в одном случае, на этапе экспресс-анализа, она может быть описана как формальная система, которая может быть задана в общем виде:

$$M = \langle A, B, C, D \rangle, \quad (1)$$

где A – множество базовых элементов, B – множество синтаксических правил для построения из A правильных выражений; C – множество истинных выражений (аксиом); D – семантические нечеткие правила для построения аксиом из других выражений. Данный подход позволяет провести «грубый» анализ по выявлению явных дефектов [5] (обрыв соединительных линий и т.д.)

В другом случае, когда необходим точный диагноз состояния сети и более полная информация относительно локализации скрытых дефектов [5] целесообразно использовать сетевые модели. Они имеют возможность охватывать более сложный спектр. Эти модели предполагают включение в явной форме всех отношений, образующих информационную структуру объекта моделирования с описанием их семантики в виде семантических сетей и фреймов. Этот подход более точен и информативен.

Выбор оптимально ИНС для использования в гибридных ЭС средств диагностики КИС

Приняв во внимание и проанализировав существующие модели ИНС, а также зная особенности функционирования систем ИИ в средствах диагностики можно сформировать ряд требований к выбираемой архитектуре ИНС.

Среди них можно выделить основные:

- ИНС должна успешно решать задачи классификации и кластеризации;
- ИНС должна иметь возможность обучения без учителя.

Среди существующих моделей ИНС, используемых для классификации и кластеризации, можно выделить следующие: 1) многослойный перцептрон прямого распространения с алгоритмом обучения обратным распространением ошибки (Back propagation); 2) радиально-базисные (RBF) сети; 3) самоорганизующиеся карты Кохонена (SOM); 4) сети адаптивного резонанса ART1 и ART2.

Три первых сети имеют ряд определенных недостатков. Главный из которых заключается в необходимости заранее знать количество классов. При этом в картах Кохонена и RBF сетях нужно задавать приблизительные характеристики классов.

Анализ работ [4,6] показывает, что карты Кохонена успешно справляются с задачами классификации, но при этом возникают трудности при решении задач кластеризации.

Соответственно сети адаптивного резонанса ART1 и ART2 лишены вышеупомянутых недостатков и эффективно справляются в решении задач кластеризации [6]. При этом сети ART1 и ART2 имеют существенные различия: ART1 работает только с двоичными векторами, а ART2 запоминает и классифицирует непрерывные входные векторы.

Для эффективного решения сложных комплексных задач диагностики могут успешно применяться ансамбли ИНС.

Они по сравнению с обычными ИНС позволяют получить определенные преимущества:

- декомпозиция сложных систем на ряд подсистем;
- ансамбль ИНС легче адаптируется под изменяющиеся внешние условия;
- структура ансамбля ИНС может быть оптимизирована под конкретную задачу;
- быстродействие и точность НА значительно выше, чем классических полносвязных сетей.

В работе [6] применен ансамбль ИНС, в котором задачу классификации решает сеть Кохонена, а задачу кластеризации – сеть ART2.

Выводы

Таким образом, подводя итог анализа существующих основных моделей ИНС, следует отметить, что для решения задач диагностирования состояния КИС в составе гибридных ЭС наиболее перспективными являются сети Кохонена и ART. При этом возможен вариант их совместного использования в ансамбле для повышения эффективности работы гибридной ЭС средств диагностики КИС.

Литература

1. Anil K. Jain, Jianchang Mao, K.M. Mohiuddin. Artificial Neural Networks: A tutorial // Computer. – 1996. – Vol. 29. – P. 31-44.
2. Попов Э.В. Экспертные системы реального времени // Открытые системы. – 1995. – № 2. – С. 35-41.
3. Жернаков С.В. Комбинированная диагностика и контроль параметров ГТД нейронечеткой гибридной экспертной системой // Радіотехніка, інформатика, управління. – 2000. – № 2. – С. 55-67.
4. Takashi Torigoe, Masami Konishi. Application of neural network to fault diagnosis of electro-mechanical system // Memoirs of the faculty of engineering, Okayama University. – 2005. – Vol. 39. – P. 21-27.
5. Польщиков К.А., Кабакчей Р.М. Методика обоснования требований к экспертной системе средств диагностики корпоративных информационных сетей // Радиоэлектронные и компьютерные системы. – 2006. – № 7. – С. 126-131.
6. Pomogova O.V. Neural nets method of computer systems diagnosis // Радиоэлектронные и компьютерные системы. – 2006. – № 5. – С. 155-160.
7. Польщиков К.А., Кабакчей Р.М. Приховані та явні дефекти корпоративних інформаційних мереж // Інформаційні інфраструктура і технології. – 2006 – № 1. – С. 14-18.

Поступила в редакцию 1.03.2007

Рецензент: канд. техн. наук, доц. В.А. Ольховский, Полтавский военный институт связи, Полтава.