

# Обробка інформації в складних організаційних системах

УДК 004.032.26

Г.Г. Асеев

*Харьковская государственная академия культуры*

## НЕЙРОСЕТЕВОЙ АНАЛИЗ НЕПРЕРЫВНЫХ ПОТОКОВ ДАННЫХ ИЗ ЭЛЕКТРОННЫХ ХРАНИЛИЩ

*Рассмотрены структуры динамических и статических нейронных сетей для обработки стационарных и нестационарных потоков данных при их добыче Data Mining. Эти структуры позволяют работать на больших временных интервалах и в непрерывном режиме, аппроксимировать временные ряды и функциональные зависимости, а также выполнять распределенную обработку входных данных в нейросеть из электронных хранилищ.*

**Ключевые слова:** *нейронная сеть, структура, непрерывный режим, распределенная обработка, электронное хранилище.*

### Введение

В настоящее время в электронных хранилищах данных корпоративных информационных систем хранятся терабайты различной текстовой и числовой информации. Для обнаружения, извлечения и интеллектуального анализа этих данных используются методы Knowledge Discovery in Databases и Data mining [1]. В [1] были описаны некоторые рекомендации, следуя которым, можно подготовить качественные данные в нужном объеме для анализа. Это следующие: первичные источники данных, хранение данных, подготовка исходного набора данных, предобработка и очистка исходных данных [2], трансформация, нормализация, выдвижение гипотез и построение модели Data Mining [3]. Данная работа продолжает цикл статей, посвященных методам интеллектуального анализа данных в электронных хранилищах большого объема, в частности нейросетевому анализу непрерывных потоков данных из электронных хранилищ.

Нейрокибернетика, возникшая во второй половине сороковых годов прошлого века, дала начало исследованиям по технической имитации решения интеллектуальных задач человеком. В шестидесятые годы эта волна исследований уступила место имитации элементов человеческого мышления на основе формальной логики. В начале восьмидесятых (после работ Дж. Хопфилда), в связи с появлением алгоритмов, которые позволили обучать «скрытые» (не связанные со входами и выходами нейросети) слои нейронов, возникла вторая волна интереса к нейронным сетям. Эти алгоритмы значительно расширили возможности нейронных сетей, породив нейроинформатику – науку об обработке информа-

ции и управлении с помощью нейронных сетей. В дальнейшем нейросети стали активно внедряться в системы искусственного интеллекта с целью расширения возможностей формально логических методов при решении трудно формализуемых задач [4, 5]. В программе «Вычисления в реальном мире» для шестого поколения компьютеров «огромную роль (до 30 – 40 процентов ее содержания) отводят исследованию естественных и созданию искусственных нейронных сетей».

В современной нейроинформатике существует множество алгоритмов для решения широкого круга научно-технических задач. Доказан ряд теорем, обосновывающих широкие возможности нейронных сетей [6]. Показано, что тенденции вычислительной техники фокусируются на нейрокомпьютерных технологиях [7, 8]. Предложен способ описания иерархических архитектур нейронных сетей [7] и поисковые алгоритмы для их обучения [8-10].

Вместе с тем имеются определенные трудности, преодоление которых требует больших усилий и не всегда дает ожидаемые результаты. В частности, с рядом проблем сопряжено решение задач, связанных с обработкой нестационарных сигналов и пространственно-временных паттернов большой длительности, включая режимы непрерывного функционирования, при рассмотрении постоянных потоков данных из электронных хранилищ.

### Состояние области исследований: нейронные сети и спектральный анализ

Возможность представления нейронных сетей в виде рядов, как будет показано ниже, естественным

образом подталкивает к сопоставлению с традиционными методами спектрального анализа, в частности, гармонического анализа / синтеза с помощью рядов Фурье. Здесь допустимы не только сопоставления, но и прямое перенесение подобных представлений в нейроалгоритмы. Модель [11], нейроны которой описываются уравнениями:

$$Y_i = \sum_{j=1}^N a_j \sin \left( \sum_{k=1}^M b_{kj} X_k \right),$$

$Y_i$  - выход  $i$ -го нейрона;  $N$  - число нейронов;  $M$  - размерность входного вектора;  $X_k$  - входной вектор;  $a$ ,  $b$  - подстроечные коэффициенты нейронной сети.

В работе [12] показано, что существуют системные инварианты, определяющие общие правила построения быстрых алгоритмов (Фурье, Уолша – Адамара, Хаара, Виленкина – Кристенсона и др.), и уточняется, что с позиций сегодняшнего дня быстрое перестраиваемое преобразование можно рассматривать как специфичную, многослойную нейронную сеть с прореженными связями и линейными функциями активации. При трансформации быстрого перестраиваемого преобразования в нейронную сеть в каждый слой добавляются нелинейные функции активации. Исследование инвариантных свойств быстрых алгоритмов также выполнено на примере быстрого преобразования Фурье (БПФ).

Преобразование Фурье получило широкое распространение в науке и технике, особенно электронике [13], теории управления [14], цифровой обработке сигналов [15], [16] и изображений [17], и др.

Вместе с тем, при всей своей популярности, преобразование Фурье имеет ряд недостатков, которые особенно заметно проявляются на нынешнем этапе научно-технического развития. Дело в том, что современные системы обработки информации и управления все в большей степени ориентируются на работу со сложными сигналами в реальном времени в условиях помех. Повышенные требования к точности и быстродействию при обработке нестационарных сигналов (а таковых сейчас большинство) создают серьезные трудности для применения БПФ [18], включая и его «оконные» версии.

Среди проблем, возникающих при использовании БПФ для обработки сложных сигналов, выделим следующие [9, 18]:

– базисной функцией для разложения в ряд Фурье является гармоническое (синусоидальное) колебание, которое математически определено в интервале времени от  $-\infty$  до  $+\infty$  и имеет неизменные во времени параметры;

– в результате, отдельные особенности сигнала (например, разрывы или пики) вызывают незначительное изменение частотного образа сигнала во

всем интервале частот от  $-\infty$  до  $+\infty$ , которые «размазываются» по всей частотной оси, что делает их обнаружение по спектру практически невозможным;

– такая плавная базисная функция, как синусоида, в принципе не может представить перепады сигналов с бесконечной крутизной, хотя такие сигналы (например, прямоугольные импульсы) применяются очень широко;

– по составу высших составляющих спектра практически невозможно оценить местоположение особенностей на временной зависимости сигнала и их характер;

– для нестационарных сигналов (а таковых сейчас большинство) трудности многократно возрастают;

– в случае оконного преобразования Фурье действует принцип неопределенности, согласно которому улучшение разрешения по одному параметру (частоте или времени) ведет к ухудшению разрешения по другому параметру [19].

Очевидно, что некоторые проблемы Фурье-преобразования характерны и для нейронных сетей традиционной архитектуры, сопоставление с которыми, приведенное в работе [12], обсуждалось выше.

Одним из эффективных способов решения задачи анализа нестационарных сигналов является использование вейвлет-анализа, позволяющего отражать локальные особенности сигналов и решающего другие описанные проблемы.

Для нас, в данном случае, представляет интерес не попытка прямого переноса математического аппарата вейвлетов [20] на нейронные сети, что представляется неразумным, а трансляция некоторых базовых идей вейвлет-анализа на нейросетевой базис.

**Цель данной работы** – предложить формальное описание динамических (рекуррентных) и статических (слоистых) нейронных сетей для обработки стационарных и нестационарных сигналов. Эти структуры позволяют эффективно работать на больших временных интервалах и в режиме непрерывного функционирования электронных хранилищ данных.

**Постановка задачи.** Анализ современного состояния области исследований позволил провести определенные параллели между методами спектрального анализа и современными нейронными сетями. Несмотря на большие возможности, алгоритмы современной нейроинформатики содержат определенные ограничения, не позволяющие полностью раскрыть потенциал нейросетевых методов в обработке и анализе информации, а также управлении сложными системами. Среди них – ограничения по формированию сложных сигналов при непрерывном функционировании и трудности с обработ-

кой нестационарных сигналов, сходные с проблемами традиционного спектрального анализа.

Упомянутые трудности ограничивают дальнейший рост возможностей нейронных сетей в решении сложных задач в условиях динамичных изменений окружающей обстановки, управление сложной динамикой распределенных объектов и др.

Для преодоления указанных трудностей ставится задача разработки математических представлений, позволяющих предложить формальное описание нейронных сетей для работы на больших временных интервалах и в режимах непрерывного функционирования электронных хранилищ данных распределенной обработки информации и обработки нестационарных сигналов.

### Динамические сети для больших интервалов времени

Одним из существенных ограничений большинства современных нейросетевых алгоритмов является неспособность, либо ограниченные возможности обучения и функционирования на больших интервалах времени. Между тем, дальнейший прогресс нейроинформатики с необходимостью обусловлен наличием такой возможности, позволяющей нейронным сетям эффективно решать задачи моделирования и анализа сложных сигналов реального мира, адаптивного управления поведением сложных объектов и др.

Для построения нейросетей, способных работать со стационарными сигналами на больших интервалах времени, рассмотрим модель, функционирующую в дискретном времени. Простейший пример такой нейронной сети приведен на рисунке 1.

Пусть функционирование *i*-го формального нейрона нейросети описывается уравнением:

$$\alpha_i^k = \arctg(\gamma_i \rho_i^k + \omega_i \rho_i^{k-1}), \quad (1)$$

где  $\gamma_i$  и  $\omega_i$  - подстроочные коэффициенты, а

$$\rho_i^k = \sum_j \alpha_j^{k-1} x_{ij} + A_j^k, \quad (2)$$




Рис. 1. Пример простейшей полностью связанной нейронной сети из трех нейронов [21]:  
1 – входной нейрон; 2 – выходной нейрон;  
3 – ассоциативный нейрон, который не связан непосредственно с входом и выходом

Преобразуем уравнение (1) к следующему виду:

$$\begin{aligned} \operatorname{tg} \alpha_i^k - \gamma_i A_i^k - \omega_i A_i^{k-1} = \\ = \lambda_i \sum_j \alpha_j^{k-1} x_{ij} + \omega_i \sum_j \alpha_j^{k-2} x_{ij}. \end{aligned} \quad (3)$$

Просуммировав по *i* уравнение (3), получим:

$$\begin{aligned} \sum_i \left( \operatorname{tg} \alpha_i^k - \gamma_i A_i^k - \omega_i A_i^{k-1} \right) - \\ - \sum_i \sum_j \left( \gamma_i \alpha_j^{k-1} + \omega_i \alpha_j^{k-2} \right) = 0. \end{aligned} \quad (4)$$

Уравнение (4) демонстрирует представление нейронной сети в виде ряда, с помощью которого можно аппроксимировать любую непрерывную функцию на больших интервалах времени. Напомним, что такое представление эффективно для стационарных сигналов.

### Динамические сети для нестационарных сигналов

Как уже указывалось в предыдущем параграфе, уравнение функционирования (1) эффективно для представления стационарных сигналов. Однако на практике часто встречаются сигналы с изменяющимися во времени свойствами. Для качественной аппроксимации таких сигналов нейронной сетью, по аналогии с вейвлет-преобразованием, уравнение функционирования нейрона может быть дополнено членом  $\Psi_i$ :

$$\alpha_i^k = \Psi_i(k) \arctg(\gamma_i \rho_i^k + \omega_i \rho_i^{k-1}), \quad (5)$$

где  $\Psi_i$  является аналогом базисных функций при вейвлет-преобразовании, а оставшаяся часть выражения – эквивалентом вычисления коэффициентов при функции  $\Psi_i$ , содержащих информацию о конкретном сигнале. Одним из возможных способов представления функции  $\Psi_i$  является следующий:

$$\Psi_i(k) = \mu_i \left[ 1 - (v_i k - \phi_i)^2 \right] e^{-\frac{(v_i k - \phi_i)^2}{2}}, \quad (6)$$

где  $\mu_i$  - коэффициент масштабирования;  $v_i$  - коэффициент сжатия / растяжения;  $\phi_i$  - коэффициент смещения по оси дискретного времени.

В данном случае ряд, представляющий нейронную сеть, примет следующий вид:

$$\begin{aligned} \sum_i \left( \operatorname{tg} \frac{\alpha_i^k}{\Psi_i(k)} - \gamma_i A_i^k - \omega_i A_i^{k-1} \right) - \\ - \sum_i \sum_j \left( \gamma_i \alpha_j^{k-1} + \omega_i \alpha_j^{k-2} \right) = 0. \end{aligned} \quad (7)$$

Одним из отличий предложенного подхода от традиционного вейвлет-анализа является отсутствие жесткой необходимости в конструировании базис-

ных функций, поскольку коэффициенты при уравнении (6) могут быть получены с помощью адаптивной процедуры наравне с подстроечными параметрами  $x_{ij}$ .

### Статические сети для нестационарных сигналов

Уравнение (5) легко модифицировать для статической (нерекуррентной) сети с целью аппроксимации в дискретном времени заданной функциональной зависимости или сигнала:

$$\alpha_i^k = \Psi_i(k) \arctg(\rho_i^k), \quad (8)$$

При этом уравнение (6) остается неизменным. Здесь, для упрощения, при использовании слоистой сети предполагается работа с одним скрытым слоем  $n = 2$ . На уравнение (2) вводится условие:  $i \neq j$ .

### Статические сети для распределенной обработки

Интересные результаты могут быть получены модификацией предложенных представлений на случай задач, не содержащих времени. Так, вместо времени может быть введена зависимость от номера класса входных данных. Очевидно, что в этом случае входные данные нейросети перед подачей на нее должны классифицироваться, например, с помощью алгоритма [21]. Перепишем уравнение (5) следующим образом:

$$\alpha_i^k = Q_i(n) \arctg(\rho_i^k), \quad (9)$$

где  $n$  – номер класса для входных данных. Уравнение (6) при этом примет вид:

$$Q_i(n) = \mu_i \left[ 1 - (v_i n - \phi_i)^2 \right] e^{-\frac{(v_i n - \phi_i)^2}{2}}. \quad (10)$$

Здесь, как и в предыдущем параграфе, предполагается работа с одним скрытым слоем  $n = 2$  и на уравнение (2) вводится условие:  $i \neq j$ . Такая нейросеть будет избирательно реагировать на входные данные, распределяя их обработку по пространству сети.

### Необходимые этапы нейросетевого анализа

Теперь, после знакомства с базовыми структурами динамических и статических нейронных сетей, можно приступить к некоторым рекомендациям для решения конкретных задач. Первое, с чем сталкивается пользователь – это необходимость подготовки данных для нейросети. До сих пор мы не касались этого, вообще говоря, непростого вопроса, молчаливо предполагая, что данные для обучения уже имеются и представлены в виде, доступном для нейросети. На практике же именно предобработка

данных может стать наиболее трудоемким элементом нейросетевого анализа. Причем, знание основных принципов и приемов предобработки данных не менее, а может быть даже более важно, чем знание собственно нейросетевых алгоритмов.

Процесс решения прикладных задач, в том числе и подготовка данных, целиком ложится на плечи пользователя. Напомним всю технологическую цепочку, т.е. необходимые этапы нейросетевого анализа [2, 3]:

- кодирование входов-выходов: нейросети могут работать только с числами;
- нормировка данных: результаты нейроанализа не должны зависеть от выбора единиц измерения;
- предобработка данных: удаление очевидных регулярностей из данных облегчает нейросети выявление нетривиальных закономерностей;
- обучение нескольких нейросетей с различной архитектурой: результат обучения зависит как от размеров сети, так и от ее начальной конфигурации;
- отбор оптимальных сетей: тех, которые дадут наименьшую ошибку предсказания на неизвестных пока данных;
- оценка значимости предсказаний: оценка ошибки предсказаний не менее важна, чем само предсказанное значение.

Если до сих пор мы ограничивали наше рассмотрение, в основном, обработке данных при их добыче Data Mining, то напомним, что на первых этапах нейросетевого анализа – предобработке данных необходимо уделить максимальное внимание [2]. Хотя предобработка данных не связана непосредственно с нейросетями, она является одним из ключевых элементов этой информационной технологии.

### Заключение

Использование предложенных математических методов и типов формальных нейронов дает возможность строить архитектуры нейронных сетей, которые во многих случаях позволяют решать задачи повышенной сложности, не прибегая к громоздким комбинациям разнородных методов, усложняющих и удорожающих систему, увеличивающих время разработки, а также сказывающихся на ее надежности. Особенно это касается иерархических архитектур (для нейросетей такое описание предложено в [7]), необходимых при решении задач повышенной сложности.

Предложенные решения позволяют нейросетям эффективно работать на больших интервалах времени и в непрерывных режимах, вести распределенную обработку входных информационных потоков и работать с нестационарными входными сигналами, характерными для реальной окружающей среды, в которой зачастую приходится работать системам

искусственного интеллекта. Такими задачами являются, например, процессы реализации распределенной обработки входных данных в нейросеть при их добыче Data Mining из электронных хранилищ.

### Список литературы

1. Асеев Г.Г. Проблема обнаружения нового знания в хранилищах данных методами Knowledge Discovery in Databases / Г.Г. Асеев // Вестник НТУ «ХПИ», – Х.: НТУ «ХПИ», 2006. – № 19. – С. 62-70.
2. Асеев Г.Г. Методы интеллектуальной преобработки данных в электронных хранилищах / Г.Г. Асеев // Радиоэлектроника. Информатика. Управление. – 2010. – №2(23). – С. 106-111.
3. Асеев Г.Г. Методы интеллектуального анализа данных в электронных хранилищах / Г.Г. Асеев // Бионика интеллекта: науч.-техн. журнал. – 2008. – №1(70). – С. 28–33.
4. Dayan, P. *Theoretical Neuroscience: Computational and Mathematical Modeling of Neural Systems* / P. Dayan, L. Abbott // The MIT Press, Cambridge, Massachusetts. – London, England, 2004. – 573 p.
5. Злобин В. К. Нейросети и нейрокомпьютеры / В. К. Злобин, В. Н. Ручкин. – СПб, БХВ, 2011. – 256 с.
6. Владимирский Б.М. Нейронные сети как источник идей и инструмент моделирования процессов самоорганизации и управления / Б.М. Владимирский // Экономический вестник Ростовского государственного университета. – 2006. – Т. 4, № 4. – С. 142-144.
7. Басканова Т.Ф. Иерархические нейронные сети, как средство решения трудноформализуемых задач искусственного интеллекта / Т.Ф. Басканова, Ю.П. Ланкин, С.В. Комиссаров // Искусственный интеллект. – 2009. – № 1. – С. 100-111.
8. Lankin J.P. Algorithms of self-adaptation for atmospheric model designing / J.P. Lankin, T.F. Baskanova // SPIE. – 2004. – Vol. 5397. – P. 260-270.
9. Басканова Т.Ф. Нейросетевой анализ непрерывных потоков нестационарных данных / Т.Ф. Басканова, Ю.П. Ланкин // Искусственный интеллект. – 2009. – № 4. – С. 483-489.
10. Okhonin V. Neural network based approach to the Evaluation of Degradation Lifetime / V. Okhonin, S. Okhonin, A. IIs [and all.] // Neural Network World. – 2001. – Vol. 11, № 2. – P. 145-151.
11. Хайкин С. Нейронные сети: полный курс / С. Хайкин; пер с англ. – М.: Издат. дом «Вильямс», 2006. – 1104 с.
12. Дорогов А.Ю. Структурные и топологические инварианты быстрых перестраиваемых преобразований / А.Ю. Дорогов // VIII Всероссийская научно-техническая конференция «Нейроинформатика-2006». Научная сессия МИФИ-2006: в 3-х частях. Ч. 1. – М.: МИФИ, 2006. – С. 39-50.
13. Манаев Е.И. Основы радиоэлектроники / Е.И. Манаев. – М.: Советское радио, 1976. – 480 с.
14. Никулин Е.А. Основы теории автоматического управления. Частотные методы анализа и синтеза систем / Е.А. Никулин. – СПб.: БХВ-Петербург, 2004. – 640 с.
15. Блейхут Р. Быстрые алгоритмы цифровой обработки сигналов / Р. Блейхут; пер. с англ. – М.: Мир, 1989. – 448 с.
16. Даджион Д. Цифровая обработка многомерных сигналов / Д. Даджион, Р. Мерсеро; пер. с англ. – М.: Мир, 1988. – 488 с.
17. Рудаков П.И. Обработка сигналов и изображений. MATLAB 5.x / П.И. Рудаков, В.И. Сафонов, под общ. ред. В.Г. Потемкина. – М.: ДИАЛОГ-МИФИ, 2000. – 416 с.
18. Дьяконов В. MATLAB. Обработка сигналов и изображений. Специальный справочник / В. Дьяконов, И. Абраменкова. – СПб.: Питер, 2002. – 608 с.
19. Дьяконов В. Вейвлеты. От теории к практике / В. Дьяконов. – М.: САЛОН-Пресс, 2004. – 400 с.
20. Смоленцев Н.К. Основы теории вейвлетов. Вейвлеты в MATLAB / Н.К. Смоленцев – М.: ДМК Пресс, 2005. – 304 с.
21. Ланкин Ю.П. Обучение без учителя на основе нейронных сетей с самостоятельной адаптацией / Ю.П. Ланкин, Т.Ф. Басканова // Реляторные, непрерывно-логические нейронные сети и модели. Труды международной конференции «Континуальные алгебраические логики, исчисления и нейроинформатика в науке, технике и экономике – КЛИН-2002». – Ульяновск: УлГТУ, 2002. – Том 3. – С. 39-41.

Поступила в редколлегию 30.04.2013

Рецензент: д-р техн. наук, проф. В.М. Левыкин, Харьковский национальный университет радиоэлектроники.

### НЕЙРОМЕРЕЖЕВИЙ АНАЛІЗ БЕЗПЕРЕРВНИХ ПОТОКІВ ДАНИХ З ЕЛЕКТРОННИХ СХОВИЩ

Г.Г. Асеев

Розглянуті структури динамічних і статичних нейронних мереж для обробки стаціонарних та нестационарних потоків даних при їх добуванні Data Mining. Ці структури дозволяють працювати на великих часових інтервалах і в безперервному режимі, апроксимувати часові ряди та функціональні залежності, а також виконувати розподільну обробку вхідних даних в нейромережу з електронних сховищ.

**Ключові слова:** нейронна мережа, структура, безперервний режим, розподільна обробка, електронне сховище.

### NEURAL NETWORK ANALYSIS OF CONTINUOUS DATA FLOW FROM ELECTRONIC WAREHOUSES

G.G. Aseyev

The structures of dynamic and static neural networks for processing stationary and non-stationary data flows during the data mining are examined. These structures make it possible to work with larger time intervals and in a continuous mode, approximate time series and functional dependencies, and perform distributed processing of input data from the electronic warehouse into the neural network.

**Key words:** neural network, structure, continuous mode, distributed processing, electronic warehouse.