

УДК 004.931

UDC 004.931

05.00.00 Технические науки

Technical sciences

**РАСПОЗНАВАНИЕ ПАТТЕРНОВ В
ДИАГРАММАХ УПРАВЛЕНИЯ НА ОСНОВЕ
НЕЙРОННЫХ СЕТЕЙ С ПОДКРЕПЛЕНИЕМ**

**PATTERN RECOGNITION IN THE CHART
CONTROL BASED ON NEURAL NETWORKS
WITH REINFORCEMENTS**

Частиков Аркадий Петрович
к.т.н., профессор кафедры информационных
систем и программирования *ФГБОУ ВО*
*“Кубанский государственный технологический
университет”*, Краснодар, Россия
350020, улица Московская, 2, Краснодар, Россия

Chastikov Arkadiy Petrovich
Cand.Tech.Sci., professor in the department of
information systems and programming
FGBOU VO “Kuban State Technological University”,
Krasnodar, Russia
350020, Moscow street, 2, Krasnodar, Russia

Урвачев Павел Михайлович
аспирант кафедры информационных систем и
программирования p.m.urvachev@gmail.com
*ФГБОУ ВО “Кубанский государственный
технологический университет”*, Краснодар,
Россия 350020, улица Московская, 2, Краснодар,
Россия

Urvachev Pavel Mihaylovich
p.m.urvachev@gmail.com *FGBOU VO “Kuban State
Technological University”*, Krasnodar, Russia
350020, Moscow street, 2, Krasnodar, Russia

Тотухов Константин Евгеньевич
к.т.н., старший преподаватель кафедры
информационных систем и программирования
РИНЦ-SCIENCE INDEX. SPIN-код=1082-9178
ke.dnw@mail.ru
*ФГБОУ ВО “Кубанский государственный
технологический университет”*, Краснодар,
Россия
350020, улица Московская, 2, Краснодар, Россия

Totukhov Konstantin Evgenievich
Cand.Tech.Sci., senior lecturer in the department of
information systems and programming
RSCI-SCIENCE INDEX SPIN-code=1082-9178
ke.dnw@mail.ru
FGBOU VO “Kuban State Technological University”,
Krasnodar, Russia
350020, Moscow street, 2, Krasnodar, Russia

Данная статья раскрывает применение нейронных сетей для распознавания паттернов в диаграммах управления. Распознать неестественные ситуации при управлении можно путём анализа паттернов на диаграмме. Нейронные сети с подкреплением являются третьим поколением нейронных сетей и в данной работе предлагаются для распознавания паттернов в диаграмме управления. Также, рассматриваются варианты усовершенствования данного алгоритма обучения в виде дополнительных правил для синоптических пауз, временных констант и порогов переключений нейронов

This article discloses the use of neural networks to recognize patterns in control charts. To recognize unnatural situation under control is possible by analyzing the chart pattern. Neural networks with reinforcements are the third generation of neural networks. In this study they are available for recognition in the management chart patterns. The article also discusses options for improvement of the learning algorithm in the form of additional rules for the synoptic pauses, time constants and switching threshold neurons

Ключевые слова: НЕЙРОННАЯ СЕТЬ,
ЭКСПЕРТНАЯ СИСТЕМА, ПАТТЕРН,
КОНЦЕПТУАЛЬНАЯ МОДЕЛЬ, ОБРАЗ

Keywords: NEURAL NETWORKS, EXPERT
SYSTEMS, PATTERN CONCEPTUAL MODEL,
IMAGE

Doi: 10.21515/1990-4665-124-050

Традиционно, статистическое управление процессами использовалось только для мониторинга отклонений процессов. Усовершенствования данного метода позволили прогнозировать поведение

процесса посредством идентификации паттернов диаграмм управления. Анализ паттернов делает возможным обнаружение признаков потери управляемости процесса.

Существует восемь базовых паттернов диаграмм управления: нормальный, систематический, циклический, нарастающий, убывающий, скачок вверх и скачок вниз. Все другие паттерны являются либо частными случаями базовых паттернов, либо их смешанной формой в числе двух или более. Достижения в производстве и измерительных технологиях сделали возможными оценки и измерения в реальном времени, быстро и всесторонне, по всем показателям качества. Базовые паттерны показаны на рисунке 1 [1].



Рисунок 1 – Базовые типы паттернов

Типовая диаграмма управления состоит из центральной линии, отражающей средний статистический уровень, и двух контрольных барьера на расстоянии $\pm 3\sigma$ от этой линии (где σ – СКО).

Для обучения нейронной сети (НС) ключевое значение имеют размер окна, случайный шум, средний скачок (для паттернов «скачка»), наклон тренда (для трендовых паттернов), амплитуда цикла (для циклических паттернов), систематический вылет (для систематических паттернов), а также функции, приведённые в таблице 1, выраженные во всех типах паттернов.

Зависимости таблицы 1 использовались для создания параметров. В этой таблице η это номинальное среднее наблюдаемой переменной

процесса (принято 80), σ – среднеквадратическое отклонение (СКО) наблюдаемой переменной (принято 5), a – амплитуда циклических колебаний в циклическом паттерне (меньше либо 15), g – градиент тренда (для трендовых паттернов, принято от 0.2 до 0.5), b – направление скачка (для паттернов «скачка», 1 или 0), s – магнитуда скачка (от 7.5 до 20), r_i – случайное число (от -3 до 3), t – дискретное время (от 0 до 20), T – период цикла (от 4 до 12) и $P(t)$ - значение параметра в момент t .

Таблица 1 – Уравнения, моделирующие диаграммы управления

	Название паттерна	Уравнение
1	Систематический	$P(t) = \eta + r_i(t)\sigma + d \times (-1)^i$
2	Циклический	$P(t) = \eta + r_i(t)\sigma + a \sin\left(\frac{2\pi t}{T}\right)$
3	Нарастающий тренд	$P(t) = \eta + r_i(t)\sigma + g t$
4	Убывающий тренд	$P(t) = \eta + r_i(t)\sigma - g t$
5	Скачок вверх	$P(t) = \eta + r_i(t)\sigma + b s$
6	Скачок вниз	$P(t) = \eta + r_i(t)\sigma - b s$

Таким образом, задача предлагаемого алгоритма заключается в классификации паттернов, извлечённых из диаграмм управления, с целью оценки степени управляемости процесса во времени.

Архитектура нейронной сети с подкреплением. Нейронная сеть (НС) с подкреплением имеет типовую для НС структуру. Математически данные НС описываются моделями: Ходжкина-Хаксли [2], Leaky Integrate-and-Fire model (LIFN) [3], а также моделью отклика на подкрепление (SRM) [4-5].

Структура состоит их слоёв: H (входной), I (скрытый) и J (выходной). Согласно SRM, для нейрона j , имеющего набор D_j пре-синоптических нейронов, генерируется набор подкреплений с временами срабатываний t_i , $i \in D_j$. Таким образом, уравнение переменной внутреннего состояния нейрона выглядит как (1).

$$x_j(t) = \sum_{i \in D_j} w_{ij} y_j(t) \quad (1)$$

где $y_j(t)$ - стоимость перехода терминала с одним синапсом к состоянию $x_j(t)$.

Подкрепление работает согласно (2).

$$Y_i^k = \varepsilon(t - t_i - d^k) \quad (2)$$

где t_i – время срабатывания нейрона i ;

d^k – пауза в терминале k .




Рисунок 2 – Схема НС с подкреплением при множественном числе синоптических терминалов

При неединичном количестве синоптических терминалов, как это показано в схеме на рисунке 2, модель $x_j(t)$ равна (3).

$$x_j(t) = \sum_{i \in D_j} \sum_{k=1}^m w_{ij}^k y_j^k(t) \quad (3)$$

Отклик подкрепления описывается как (4).

$$\varepsilon(t) = \frac{t}{\tau} e^{-t/\tau}, \text{ при } t > 0, \text{ иначе } \varepsilon(t) = 0 \quad (4)$$

где τ - константа возрастания или убывания постсинаптического потенциала.

Модель индивидуального соединения, где каждый терминал служит как доп. соединение, ассоциированное с отдельным весом и паузой, показана на рисунке 3 [6].




Рисунок 3 – Модель индивидуальных соединений для распознаваний паттернов

Цель разработанного авторами алгоритма, использующего классический принцип обучения методом обратного распространения ошибки, в обучении группы выходных нейронов J с временами срабатывания $\{t_j^d\}$ распознать набор паттернов $\{P[t_1, t_2, \dots, t_h]\}$, где $h \in H$ – нейроны, вырабатывающие подкрепления. Функция ошибки задана как (5).

$$E_v = \frac{1}{2} \sum_j (t_j^a - t_j^d)^2, \quad \frac{\partial E}{\partial w_{ij}^k} = \frac{\frac{\partial E}{(\partial t_j)(t_j^a)(\partial t_j)}}{\frac{\partial a_j(t)}{(\partial a_j(t))(t_j^a)(\partial a_j(t))}} = \varepsilon_{ij}^k (t_j^a - t_i^a - d_{ij}^k) \delta_j \quad (5)$$

где $\frac{\partial E}{\partial w_{ij}^k} = \frac{\frac{\partial E}{(\partial t_j)(t_j^a)(\partial t_j)}}{\frac{\partial a_j(t)}{(\partial a_j(t))(t_j^a)(\partial a_j(t))}}$ - частная производная функции ошибки

синоптических пауз по весу;

δ_j : для нейронов скрытого слоя равно (6), выходного слоя (7).

$$\delta_j = \frac{-(t_j^a - t_j^d)}{\sum_{i \in I_j} \sum_k w_{ij}^k \frac{\partial \varepsilon_{ij}^k}{\partial t(t_j^a - t_i^a - d_{ij}^k)}} \quad (6)$$

$$\delta_j = \frac{\sum_{i \in \Gamma_j} \delta_j \sum_k w_{ij}^k \frac{\partial \varepsilon_{ij}^k}{\partial t(t_j^a - t_i^a - d_{ij}^k)}}{\sum_{i \in \Gamma_j} \sum_k w_{ij}^k \frac{\partial \varepsilon_{ij}^k}{\partial t(t_j^a - t_i^a - d_{ij}^k)}} \quad (7)$$

Тогда правило для адаптации весов равно (8).

$$W_{ij}(T + 1) = W_{ij}(T) - \eta \frac{\partial E}{\partial w_{ij}(T)} \quad (8)$$

Усовершенствование алгоритма.

Усовершенствовать *синоптические паузы* можно, применив частную производную функции ошибки по паузе $\frac{\partial E}{\partial w_{ij}^k}$. Первые два термина этой производной аналогичны правилу обновления весов, поэтому рассмотрим третий терм в (9).

$$\frac{\partial a_j(t)}{\partial d_{ij}^k}(t_j^a) = -w_{ij}^k \frac{\partial \varepsilon_{ij}^k}{\partial t(t_j^a - t_i^a - d_{ij}^k)} = -w_{ij}^k \varepsilon_{ij}^k(t_j^a - t_i^a - d_{ij}^k) \left[\frac{1}{t_j^a - t_i^a - d_{ij}^k} - \frac{1}{\tau_{ij}^k} \right] \quad (9)$$

Путём замены через определение δ_j имеем (10).

$$\frac{\partial E}{\partial d_{ij}^k} = -w_{ij}^k \frac{\partial \varepsilon_{ij}^k}{\partial t(t_j^a - t_i^a - d_{ij}^k)} \delta_j \quad (10)$$

И тогда, окончательная форма для обновлений синоптических пауз равна (11).

$$\Delta d_{ij}^k = -\eta_d \frac{\partial E}{\partial d_{ij}^k} \quad (11)$$

Усовершенствовать *синоптические временные константы* можно через частную производную функции ошибки по временной константе (12).

$$\frac{\partial E}{\partial \tau_{ij}^k} = \frac{\partial E}{\partial t_j}(t_j^a) \frac{\partial t_j}{\partial a_j(t)}(t_j^a) \frac{\partial a_j(t)}{(\partial \tau_{ij}^k)(t_j^a)} \quad (12)$$

Произведя подстановку δ_j в третий терм производной, получаем итоговую функцию обновления временной константы в виде (13).

$$\Delta \tau_{ij}^k = -\eta_\tau \frac{\partial E}{\partial \tau_{ij}^k} \quad (13)$$

Усовершенствовать функцию порога переключения можно также через производную (14).

$$\frac{\partial E}{\partial \theta_j} = \frac{\partial E}{\partial t_j} (t_j^a) \frac{\partial t_j}{\partial \theta_j (t_j^a)}, \quad \frac{\partial t_j}{\partial \theta_j} (t_j^a) = \frac{1}{\frac{\partial a_j(t)}{\partial t(t_j^a)}} = \frac{1}{\sum_{i \in \tau_j} \sum_k w_{ij}^k \frac{\partial e_{ij}^k}{\partial t(t_j^a - t_i^a - a_{ij}^k)}} \quad (14)$$

Подставляя δ_j получаем $\frac{\partial E}{\partial \theta_j} = -\delta_j$, и тогда функция обновления порога равна (15).

$$\Delta \theta_j = -\eta_{\theta} \frac{\partial E}{\partial \theta_j} \quad (15)$$

Первоначально, для сравнения с НС с подкреплением, была сконструирована обычная НС (контрольная) с числом нейронов: 20 входных, 6 скрытых, 6 выходных. Желаемые параметры выходных нейронов контрольной НС приведены в таблице 2.

Таблица 2 – Желаемые выходные сигналы контрольной НС

	Название паттерна	Выходы контрольной НС					
		1	2	3	4	5	6
1	Систематический	1	0	0	0	0	0
2	Циклический	0	1	0	0	0	0
3	Нарастающий тренд	0	0	1	0	0	0
4	Убывающий тренд	0	0	0	1	0	0
5	Скачок вверх	0	0	0	0	1	0
6	Скачок вниз	0	0	0	0	0	1

Типовые паттерны. Типовые паттерны извлекаются из реальных диаграмм управления, но и имитационные (симулированные) данные также допустимы. В случае большого размера окна, эффективность идентификации паттернов можно повысить увеличением времени, отводимого на распознавание. Возьмём набор из 720 (120*6) типовых

паттернов, полученных из 120 наблюдений. Каждый набор имеет равное число одинаковых паттернов. Предложим этот набор контрольной НС, параметры которой даны в таблице 3.

Таблица 3-сетевые параметры НС с подкреплением

Параметр	Значение
Входных нейронов	20
Скрытых нейронов	6
Выходных нейронов	6
Порог срабатывания θ	0.3
Ошибка	0.001
ΔT	0-20мс
τ (Синап. врем. конст.)	170мс
К (Число синоп.терм-в)	3
Период обновления веса η_w	0.0075
Период обновления паузы η_d	0.0065
Период обновления врем. константы η_τ	0.0055
Период обновления порога срабатыва-я η_θ	0.0035

Рассмотрим архитектуру НС с подкреплением с единственным соединением и мультисиноптическими терминалами. Её состояния и желаемые выходные данные приведены в таблицах 4 и 5. Она состоит из k синоптических терминалов, где каждый терминал с отдельными весом и паузой между входным, скрытым и выходным слоями (величины весов от -1 до 1).

Модели НС с подкреплением при единственном и множественном синоптических терминалах соответственно показаны на рисунках 4 и 5.




Рисунок 4 – НС с подкреплением (единственный синопт. терминал)




Рисунок 5 – НС с подкреплением (множественный синопт. терминал)

В таблице 4 показаны желаемые выходные сигналы НС с подкреплением.

Таблица 4 – Выходы НС с подкреплением

	Название паттерна	Выходы НС с подкреплением					
		1	2	3	4	5	6
1	Систематический	20	10	10	10	10	10
2	Циклический	10	20	10	10	10	10
3	Нарастающий тренд	10	10	20	10	10	10
4	Убывающий тренд	10	10	10	20	10	10
5	Скачок вверх	10	10	10	10	20	10
6	Скачок вниз	10	10	10	10	10	20

Результаты и обсуждения

Таблица 5 отражает, что результат распознавания на контрольной НС на уровне 86.76%.

Метод обновления синоптических весов (при зафиксированных остальных параметрах) в НС с подкреплением дал, согласно таблице 6, повышение эффективности распознавания на 90.9% в сравнении с контрольной НС.

Результат применения метода обновления синоптической паузы показан в таблице 7. Он дал повышение эффективности распознавания на 92.4%. Значения синоптических весов были оптимальными, полученными на предыдущем этапе.

При оптимальных значениях синоптических весов и пауз, метод обновления временных констант дал результат, приведённый в таблице 8, согласно которому повышение эффективности распознавания равно 93.5%.

Результат применения метода обновления порога срабатывания нейронов, при зафиксированных оптимальных значениях временных констант, а также синоптических весов и пауз, приведён в таблице 9. Заметим, что особенно повышение эффективности удалось достичь для паттернов скачка вниз.

НС с подкреплением и множественными синоптическими терминалами.

В биологических системах наличие множественных синоптических связей предпочтительнее единичной связи. В данной работе предлагается вариант НС такого типа, отражённый на рисунке 5. Такая архитектура позволяет выбирать адекватное значение паузы согласно подходящему правилу. Топология данной НС также применяет подкрепление, причем число $k=3$ синоптических связей с индивидуальными значениями весов и пауз определено эвристически. К данной топологии также применялись методы усовершенствования, рассмотренные ранее.

Метод обновления синоптических весов дал повышение эффективности по всем паттернам, что показано в таблице 10. Аналогично рост для всех паттернов получен методом обновления синоптических пауз,

как это представлено в таблице 11. Также повысить эффективность, согласно таблице 12, позволил метод обновления временных констант. Для метода обновления порога срабатывания результаты приведены в таблице 13. Они демонстрируют повышение эффективности распознавания для паттернов скачка вниз.

В целом, общие результаты точности распознавания (95.68% по таблице 10, 96.51% в таблице 11, 97.08% в таблице 12, 98.61% в таблице 13) указывают, что имеет место повышение эффективности распознавания паттернов всех типов при использовании архитектуры НС с подкреплением, причём именно с множественными синоптическими терминалами.

Таблица 5 – Распознавание паттернов контрольной НС

	Название паттерна	Выходные уровни					
		1 (%)	2(%)	3(%)	4(%)	5(%)	6(%)
1	Систематический	86	2	0	0	0	12
2	Циклический	1	84	0	3	12	0
3	Нарастающий тренд	0	0	87	0	13	0
4	Убывающий тренд	0	0	10	88.1	0	1.9
5	Скачок вверх	12	0	0.8	0	87.2	0
6	Скачок вниз	0	0	10	1.7	0	88.3

Таблица 6 – Результат распознавания НС с подкреплением (при единственной синопт. связи) при методе обновления синоптических весов

	Название паттерна	Желаемые выходные уровни					
		1 (%)	2(%)	3(%)	4(%)	5(%)	6(%)
1	Систематический	90	2	0	0	0	8

2	Циклический	1	89	0	0	10	0
3	Нарастающий тренд	0	0	92.5	0.5	7	0
4	Убывающий тренд	0	0	2.9	91.1	0	6
5	Скачок вверх	9	0	0.8	0	90.2	0
6	Скачок вниз	0	0	7	0	0	93

Таблица 7 - Результат распознавания НС с подкреплением (при единственной синапт. связи) при методе обновления синоптических пауз

	Название паттерна	Желаемые выходные уровни					
		1 (%)	2(%)	3(%)	4(%)	5(%)	6(%)
1	Систематический	92	0.8	0	0	0	7
2	Циклический	3	90	0	0	7	0
3	Нарастающий тренд	0	0	94.5	0.5	5	0
4	Убывающий тренд	0	0	0.8	93.2	0	6
5	Скачок вверх	9	0	0	0	91	0
6	Скачок вниз	0	0	6	0	0	94

Таблица 8 - Результат распознавания НС с подкреплением (при единственной синапт. связи) при методе обновления временной константы

	Название паттерна	Желаемые выходные уровни					
		1 (%)	2(%)	3(%)	4(%)	5(%)	6(%)
1	Систематический	94	0.8	0	0	0	5.2
2	Циклический	2	91	0	0	7	0
3	Нарастающий	0	0	94.8	0.2	5	0

	тренд						
4	Убывающий тренд	0	0	0.7	94.3	0	5
5	Скачок вверх	7	0	0.7	0	92.3	0
6	Скачок вниз	0	0	5.4	0	0	94.6

Таблица 9 - Результат распознавания НС с подкреплением (при единственной синопт. связи) при методе обновления порога срабатывания

	Название паттерна	Желаемые выходные уровни					
		1 (%)	2(%)	3(%)	4(%)	5(%)	6(%)
1	Систематический	95	0.8	0	0	0	4.2
2	Циклический	3	91.4	0	0	5.6	0
3	Нарастающий тренд	0	0	95	0.2	4.8	0
4	Убывающий тренд	0	0	0.8	95.2	0	4
5	Скачок вверх	7	0	0.2	0	92.8	0
6	Скачок вниз	0	0	5	0	0	95

Таблица 10 - Результат распознавания НС с подкреплением (при множественной синапт. связи) при методе обновления синопт. весов

	Название паттерна	Желаемые выходные уровни					
		1 (%)	2(%)	3(%)	4(%)	5(%)	6(%)
1	Систематический	97	0.8	0	0	0	2.2
2	Циклический	3	93	0	0	4	0
3	Нарастающий тренд	0	0	96	4	0	0
4	Убывающий	0	0	0.8	96.2	0	3

	тренд						
5	Скачок вверх	4	0	0.6	0	95.4	0
6	Скачок вниз	3	0	0.5	0	0	96.5

Таблица 11 - Результат распознавания НС с подкреплением (при множественной синопт. связи) при методе обновления синоптических пауз

	Название паттерна	Желаемые выходные уровни					
		1 (%)	2(%)	3(%)	4(%)	5(%)	6(%)
1	Систематический	98	0.6	0	0	0	1.4
2	Циклический	3	95	0	0	5	0
3	Нарастающий тренд	0	0	96.4	3.6	0	0
4	Убывающий тренд	0	0	0.2	96.8	0	3
5	Скачок вверх	3	0	0.6	0	96	0.4
6	Скачок вниз	3	0	0.1	0	0	96.9

Таблица 12 - Результат распознавания НС с подкреплением (при множ. синопт. связи) при методе обновления временной константы

	Название паттерна	Желаемые выходные уровни					
		1 (%)	2(%)	3(%)	4(%)	5(%)	6(%)
1	Систематический	98	0.6	0	0	0	1.4
2	Циклический	3	96	0	0	4	0
3	Нарастающий тренд	0	0	97	3	0	0
4	Убывающий тренд	0	0	0	98	0	2
5	Скачок вверх	3	0	0.5	0	96.5	0

6	Скачок вниз	3	0	0	0	0	97
---	-------------	---	---	---	---	---	----

Таблица 13 - Результат распознавания НС с подкреплением (при множ. синопт. связи) при методе обновления порога срабатывания

	Название паттерна	Желаемые выходные уровни					
		1 (%)	2(%)	3(%)	4(%)	5(%)	6(%)
1	Систематический	99	0.6	0	0	0	1
2	Циклический	2	98.2	0	0	0.8	0
3	Нарастающий тренд	0	0	98	0	0	2
4	Убывающий тренд	0	0	0	98.5	0	1.5
5	Скачок вверх	0	0	1	0	99	0
6	Скачок вниз	0.4	0	0	0.6	0	99

Таблица 14 показывает сравнение трёх сетевых топологий в распознавании паттернов. В таблице 15 приведено сравнение НС с подкреплением (по LVQ алгоритму) [7] с представленной в статье разработкой.

Из таблицы 15 можно утверждать, что НС с подкреплением (с тремя синоптическими терминалами) позволяет достичь большей точности распознавания паттернов.

Таблица 14 – Сравнение точности распознавания контрольной НС и с подкреплением

Паттерн	Контр .нс	НС с подкрепл. (единственный синопт. терминал)				НС с подкрепл. (множественный синопт. терминал)			
		Вес(%)	Пауза (%)	Врем.кон ст(%)	Пор ог сра б- ия(%)	Вес(%)	Пауза (%)	Врем.кон ст(%)	Пор ог сра б- ия(%)
Систематич еский	86	90	92	94	95	97	98	98	99
Циклическ ий	84	89	90	91	91.4	93	95	96	98.2
Нарастающ ий тренд	87	92.5	94.5	94.8	95	96	96.4	97	98
Убывающи й тренд	88.1	91.1	93.2	94.3	95.2	96.2	96.8	98	98.5
Скачок вверх	87.2	90.2	91	92.3	92.8	95.4	96	96.5	99
Скачок вниз	88.3	93	94	94.6	95	96.5	96.9	97	99

Таблица 15 – Результат сравнения четырёх разных сетей распознавания

Тип НС	Эффективность обучения	Кол-во эпох	Эффективность распознавания
LVQ	100	20	97.7
Контрольная	98	100	86.76
НС с подкрепл-м. (единственный синопт. терминал)	99	150	94.06
НС с подкрепл. (множественный синопт. терминал)	100	200	98.61

Заключение

В данной работе рассмотрен оригинальный метод распознавания паттернов в диаграммах управления на основе нейронных сетей с подкреплением, усовершенствованных дополнительными правилами уточнения значений синоптических весов и паузы, а также временной константы и порога срабатывания нейрона. Имитационные эксперименты позволили зафиксировать существенное повышение эффективности данного метода перед классическими нейронными сетями, как по критерию точности распознавания, так и по степени эффективности обучения.

Список литературы

1. Малыгина М.П., Бегман Ю.В. ГИБРИДНЫЕ НЕЙРОЭКСПЕРТНЫЕ СИСТЕМЫ В ОБРАЗОВАНИИ // Инновационные процессы в высшей школе / Материалы XIV Всероссийской научно-практической конференции. 2008. С. 193-194.
2. Малыгина М.П., Шичкин Д.А. АСПЕКТЫ ПРАКТИЧЕСКОГО ПРИМЕНЕНИЯ ЦВЕТОВОГО РАЗЛИЧИЯ ДЛЯ РАСПОЗНАВАНИЯ И ВЫДЕЛЕНИЯ ГРАНИЦ ИЗОБРАЖЕНИЙ / Политематический сетевой электронный научный журнал Кубанского государственного аграрного университета = Polythematic online scientific journal of Kuban State Agrarian University. 2013. Т. 89. № 89-89 (09). С. 676-688.

3. Рыжков А.А. ПРОГРАММНАЯ РЕАЛИЗАЦИЯ СЕТИ ХОПФИЛДА ДЛЯ РАСПОЗНАВАНИЯ И КЛАССИФИКАЦИИ ЭЛЕКТРИЧЕСКИХ СИГНАЛОВ / А. А. Рыжков // Молодой ученый. — 2012. — №5. — С. 62-67.

4. Частиков А.П., Глушко С.П., Тотухов К.Е. Система тестирования и отладки управляющих программ для промышленного робота // Журнал «Перспективы науки» № 9(11)2010 – 103 с. С. 47-51

5. Частиков А.П., Дедкова Т.Г., Алешин А.В. Системы искусственного интеллекта. От теории к практике. – Краснодар, 1998.

6. T. Natschlager, B. Ruf, Spatial and temporal pattern analysis via spiking neurons, Network: Computation in Neural Systems 9 (3) (1998) 319–332.

7. D.T. Pham, S. Shahnorbanun, Control Chart Pattern Recognition with Spiking Neural Networks, Manufacturing Engineering Centre, Cardiff University, Cardiff CF24 3AA, UK, 1994.

8. Частиков А.П., Тотухов К.Е. Создание базы знаний для интеллектуального анализа поведения виртуального робота. // Вопросы современной науки и практики. Университет им. В. И. Вернадского (ВАК) / Ассоциация «Объединённый университет им. В. И. Вернадского». – Тамбов, 2013. С.76-81

9. Частиков А.П., Тотухов К.Е. Теоретические основы интеллектуальной симуляции промышленных роботов: монография. – LAP LAMBERT Academic Publishing, 2013 г. - 111 с.: ил.

10. Частиков А.П., Тотухов К.Е., Урвачев П.М. Дерево логического вывода интеллектуальной системы функционирования виртуального робота // Современные проблемы науки и образования (ВАК). – 2013. – № 2; URL: www.science-education.ru/108-8976

11. Частиков А.П., Тотухов К.Е., Урвачев П.М. Интеллектуальная диагностика состояния виртуального робота с программным управлением // Современные проблемы науки и образования (ВАК). – 2012. - № 6; URL: www.science-education.ru/106-7507

12. Частиков А.П., Тотухов К.Е., Урвачев П.М. Теоретические основы интеллектуальной диагностики виртуального робота // Современные проблемы науки и образования (ВАК). – 2013. – № 1; URL: www.science-education.ru/107-8310

13. Частикова В. А. Исследование основных параметров генетического алгоритма метода генетических схем в интеллектуальных системах, основанных на знаниях/ В. А. Частикова //Научный журнал кубгау [Электронный ресурс]. - Краснодар: кубгау, 2011. -№ 69 (5). - Шифр Информрегистра: 0421100012/0162. - Режим доступа: <http://ej.kubagro.ru/2011/05/pdf/32.pdf>.

14. Частикова В.А. Оптимизация процессов поиска решений в интеллектуальных системах обработки экспертной информации на основе генетических алгоритмов. Диссертация на соискание ученой степени кандидата технических наук. - Краснодар, 2005.

15. Частикова В.А., Власов К.А., Картамышев Д.А. Обнаружение DDoS-атак на основе нейронных сетей с применением метода роя частиц в качестве алгоритма обучения // Фундаментальные исследования. 2014. № 8-4. С. 829-832.

16. Частикова В.А., Картамышев Д.А., Власов К.А. Нейросетевой метод защиты информации от DDoS-атак // Современные проблемы науки и образования. 2015. № 1-1. С. 183.

17. Частиков А.П., Малыхина М.П., Урвачев П.М. Анализ распознавания паттернов нейросетевыми методами // Политематический сетевой электронный научный журнал Кубанского государственного аграрного университета. 2014. № 98. С. 457-467.

18. Частиков А.П., Алешин А.В., Частикова В.А. Выявление аномалий в базах знаний интеллектуальных систем // в сборнике: Пятьдесят лет развития кибернетики Труды международной научно-технической конференции. Посвящается 100-летию Санкт-Петербургского государственного технического университета (Политехнического института). 1999. С. 123-124.

19. Малыхина М.П., Бегман Ю.В. НЕЙРОСЕТЕВАЯ ЭКСПЕРТНАЯ СИСТЕМА НА ОСНОВЕ ПРЕЦЕДЕНТОВ ДЛЯ РЕШЕНИЯ ПРОБЛЕМ АБОНЕНТОВ СОТОВОЙ СВЯЗИ // Краснодар, 2011.

References

1. Malyhina M.P., Begman Ju.V. GIBRIDNYE NEJROJEKSPERTNYE SISTEMY V OBRAZOVANII // Innovacionnyye processy v vysshej shkole / Materialy XIV Vserossijskoj nauchno-prakticheskoj konferencii. 2008. S. 193-194.

2. Malyhina M.P., Shichkin D.A. ASPEKTY PRAKTICHESKOGO PRIMENENIJA CVETOVOGO RAZLICHIJA DLJA RASPOZNAVANIJA I VYDELENIJA GRANIC IZOBRAZhENIJ / Politematicheskij setevoy jelektronnyj nauchnyj zhurnal Kubanskogo gosudarstvennogo agrarnogo universiteta = Polythematic online scientific journal of Kuban State Agrarian University. 2013. T. 89. № 89-89 (09). S. 676-688.

3. Ryzhkov A.A. PROGRAMMNAJA REALIZACIJA SETI HOPFILDA DLJA RASPOZNAVANIJA I KLASSIFIKACII JELEKTRICHESKIH SIGNALOV / A. A. Ryzhkov // Molodoy uchenyj. — 2012. — №5. — S. 62-67.

4. Chastikov A.P., Glushko S.P., Totuhov K.E. Sistema testirovanija i otladki upravljajushhih programm dlja promyshlennogo robota // Zhurnal «Perspektivy nauki» № 9(11)2010 – 103 s. S. 47-51

5. Chastikov A.P., Dedkova T.G., Aleshin A.V. Sistemy iskusstvennogo intellekta. Ot teorii k praktike. – Krasnodar, 1998.

6. T. Natschlager, B. Ruf, Spatial and temporal pattern analysis via spiking neurons, Network: Computation in Neural Systems 9 (3) (1998) 319–332.

7. D.T. Pham, S. Shahnorbanun, Control Chart Pattern Recognition with Spiking Neural Networks, Manufacturing Engineering Centre, Cardiff University, Cardiff CF24 3AA, UK, 1994.

8. Chastikov A.P., Totuhov K.E. Sozdanie bazy znaniy dlja intellektual'nogo analiza povedenija virtual'nogo robota. // Voprosy sovremennoj nauki i praktiki. Universitet im. V. I. Vernadskogo (VAK) / Associacija «Ob#edinjonnyj universitet im. V. I. Vernadskogo». – Tambov, 2013. S.76-81

9. Chastikov A.P., Totuhov K.E. Teoreticheskie osnovy intellektual'noj simuljicii promyshlennyh robotov: monografija. – LAP LAMBERT Academic Publishing, 2013 g. - 111 s.: il.

10. Chastikov A.P., Totuhov K.E., Urvachev P.M. Derevo logicheskogo vyvoda intellektual'noj sistemy funkcionirovanija virtual'nogo robota // Sovremennye problemy nauki i obrazovanija (VAK). – 2013. – № 2; URL: www.science-education.ru/108-8976

11. Chastikov A.P., Totuhov K.E., Urvachev P.M. Intellektual'naja diagnostika sostojanija virtual'nogo robota s programmnyj upravleniem // Sovremennye problemy nauki i obrazovanija (VAK). – 2012. - № 6; URL: www.science-education.ru/106-7507

12. Chastikov A.P., Totuhov K.E., Urvachev P.M. Teoreticheskie osnovy intellektual'noj diagnostiki virtual'nogo robota // Sovremennye problemy nauki i obrazovanija (VAK). – 2013. – № 1; URL: www.science-education.ru/107-8310

13. Chastikova V. A. Issledovanie osnovnyh parametrov geneticheskogo algoritma metoda geneticheskikh shem v intellektual'nyh sistemah, osnovannyh na znanijah/ V. A. Chastikova //Nauchnyj zhurnal kubgau [Elektronnyj resurs]. - Krasnodar: kubgau, 2011. -№ 69 (5). - Shifr Informregistra: 0421100012/0162. - Rezhim dostupa: <http://ej.kubagro.ru/2011/05/pdf/32.pdf>.

14. Chastikova V.A. Optimizacija processov poiska reshenij v intellektual'nyh sistemah obrabotki jekspertnoj informacii na osnove geneticheskikh algoritmov. Dissertacija na soiskanie uchenoj stepeni kandidata tehniceskikh nauk. - Krasnodar, 2005.

15. Chastikova V. A., Vlasov K. A., Kartomishev D. A. Detection of DDoS-attacks based on neural networks using the method of particle swarm algorithm as training // Basic Research. 2014. № 8-4. Pp 829-832.

16. Chastikova V. A., Kartomishev D. A., Vlasov K. A. Neural network information protection method of DDoS-attacks // Modern problems of science and education. 2015. № 1-1. S. 183.

17. Chastikov A.P., Malyhina M.P., Urvachev P.M. Analysis of pattern recognition with neural network method // multidisciplinary network electronic scientific journal of the Kuban State Agrarian University. 2014. № 98. S. 457-467.

18. Chastikov A.P., Aleshin A.V., Chastikova V. A. Anomaly detection in knowledge bases of intellectual systems // In the collection Fifty years of development of cybernetics Proceedings of the International scientific and technical conference. Dedicated to the 100th anniversary of St. Petersburg State Technical University (Polytechnic). 1999, pp 123-124.

19. Malyhina M.P., Begman Ju.V. NEURAL NETWORK EXPERT SYSTEM BASED ON THE PRECEDENT FOR SOLVING cellular subscribers // Krasnodar, 2011.

W