

вого кодирования – декодирования алфавитно-цифровой информации. К.1994. 24 с. 3. Шувалов В. П., Захарченко Н. В. и др. / Под ред. Шувалова В. П. Передача дискретных сообщений. М.: Радио и связь, 1990. 142 с. 4. Эжко А. Г., Кювский Д. Д., Назаров М. В., Финк Л. М. Теория передачи сигналов. М.: Радио и связь, 1986. 242 с.

Поступила в редколлегию 12.03.98

Полезный эффект от применения предложенного корректирующего кода заключается в повышении верности считываемой информации и снижении требований к аппаратуре обеспечения.

**Литература:** 1. Стариченко О., Голуб В. Коды и кодирование информации, штриховое кодирование выбор и применение штриховых кодов // Руководящий нормативный документ по стандартизации КНД 50-051-95. К.: Госстандарт Украины. 1995. 32 с. 2. Али К. Абуд Аль-Амери. Способы и средства помехоустойчивого штрихо-

**Голуб Владимир Иванович**, начальник инженерного центра украинского объединения почтовой связи "УКР-ПОЧТА". Адрес: 252001, Украина, Киев-1, Хрещатик, 22, тел. (044) 228-37-12.

**Жамхарьян Александр Сергеевич**, аспирант кафедры сети связи, НИЛ-20. Адрес: 270021, Украина, Одесса, ул. Кузнечная, 1, тел. (8-0482) 23-61-80.

**Фомина Ольга Владимировна**, аспирант кафедры сети связи, НИЛ-20. Адрес: 270021, Украина, Одесса, ул. Кузнечная, 1, тел. (8-0482) 23-61-80.

УДК 681.51.015:519.7

## ОБУЧЕНИЕ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ В СТОХАСТИЧЕСКИХ УСЛОВИЯХ

ВОРОБЬЕВ С. А.

Рассматривается задача обучения искусственных нейронных сетей в стохастических условиях для прямо-направленных сетей типа радиально-симметричной сети и многослойного перцептрона. При этом, при синтезе алгоритмов настройки синаптических весов сети, важным является требование наличия фильтрующих свойств у разрабатываемых алгоритмов. Исследуется сходимость предлагаемых алгоритмов в стохастических условиях обучения.

В последние годы для решения задач идентификации, моделирования и управления нелинейными системами широко применяются искусственные нейронные сети [1-4]. Основными задачами при проектировании нейронной сети являются выбор ее архитектуры и типа активационных функций нейронов, разработка алгоритмов настройки синаптических весов нейронов (алгоритмов обучения). Подробнее остановимся на задаче обучения нейронной сети в стохастических условиях.

Градиентная процедура настройки синаптических весов имеет вид

$$\begin{aligned} \omega(k+1) &= \omega(k) + \eta(k)\varepsilon(k, \omega)\nabla_{\omega}f(\varphi(k), \omega) = \\ &= \omega(k) + \eta(k)\varepsilon(k, \omega)G(\varphi(k), \omega). \end{aligned} \quad (1)$$

где  $\omega(k) = (\omega_1(k), \omega_2(k), \dots, \omega_{n_{\omega}}(k))^T$  – вектор синаптических весов нейронной сети;  $\eta(k)$  – параметр шага поиска, принимаемый чаще всего постоянным;  $\nabla_{\omega}f(\varphi(k), \omega) = G(\varphi(k), \omega)$  – градиент функции  $f(\varphi(k), \omega)$  по синаптическим весам;  $\varphi(k) = (y(k-1), \dots, y(k-n), u(k-1), \dots, u(k-p))^T$ ;  $f(\bullet)$  – некоторая функция;

$$\varepsilon(k, \omega) = y(k) - \hat{y}(k, \omega) \quad (2)$$

– ошибка идентификации;  $y(k)$  и  $u(k)$  – соответственно выход и вход системы;  $\hat{y}(k, \omega) = f(\varphi(k), \omega)$ .

Далее остановимся на более конкретных задачах настройки нейронных сетей в стохастических условиях. Рассмотрим радиально-симметричную искусственную нейронную сеть (RBFN-сеть), которая состоит из трех слоев, называемых: входным, скрытым и выходным [5]. Функцией первого слоя является простое прохождение входного сигнала на уровень скрытого слоя, который выполняет нелинейное преобразование пространства входных сигналов в новое пространство. При этом преобразование строится с помощью активационной функции гауссовского типа

$$H_l = \exp[-\|x - c_l\|^2 / \delta_l^2], \quad l = 1, 2, \dots, L,$$

где  $\|\bullet\|$  – евклидова норма вектора;  $c_l$  и  $\delta_l$  – соответственно центр и ширина гауссовской функции. Выходной слой сети представляет собой линейную комбинацию выходов нейронов скрытого слоя

$$y_m(k) = \sum_{l=1}^L \omega_{lm}(k)H_l(k), \quad m = 1, 2, \dots, s.$$

Здесь  $\omega_{lm}(k)$  – настраиваемые весовые множители между скрытым и выходным слоем сети (синаптические веса). Таким образом, вектор настраиваемых синаптических весов  $m$ -го нейрона выходного слоя имеет вид

$$\hat{\omega}_m(k) = (\hat{\omega}_{1m}(k), \hat{\omega}_{2m}(k), \dots, \hat{\omega}_{Lm}(k))^T.$$

Для идентификации детерминированных объектов в теории искусственных нейронных сетей применяется алгоритм Уидроу-Хоффа [6]:

$$\hat{\omega}_m(k+1) = \hat{\omega}_m(k) + \frac{H(k)\varepsilon(k, \hat{\omega}_m)}{\|H(k)\|^2} H(k), \quad (3)$$

где  $H(k) = (H_1(k), H_2(k), \dots, H_L(k))^T$ ,  $\varepsilon(k, \hat{\omega}_m) = y_m(k) - \hat{\omega}_m^T(k)H(k)$ .

Однако при работе в стохастических условиях алгоритм (3) должен также обладать фильтрующими свойствами, что можно достичь, введя в (3) параметр сглаживания  $\alpha$ :

$$\begin{cases} \hat{\omega}_m(k+1) = \hat{\omega}_m(k) + ar^{-1}(k)\varepsilon(k, \hat{\omega}_m)H(k), \\ r(k) = \alpha r(k-1) + \|H(k)\|^2, \\ 0 \leq \alpha \leq 1, \quad 0 < a < 2, \quad r(0) = 1. \end{cases} \quad (4)$$

Алгоритм (4) совпадает с (3) при  $\alpha = 0$  и с процедурой Гудвина-Рэмеджа-Кейнеса [7] при  $\alpha = 1$ .

Проведем анализ сходимости алгоритма (4). Запишем (4) относительно ошибки настройки синаптических весов  $\tilde{\omega}_m(k) = \omega_m(k) - \hat{\omega}_m(k)$ :

$$\tilde{\omega}_m(k) = \tilde{\omega}_m(k-1) + ar^{-1}(k)H(k) \times \varepsilon(k, \hat{\omega}_m). \quad (5)$$

Тогда функция Ляпунова примет вид

$$\begin{aligned} V(k) &= \tilde{\omega}_m^T(k)\tilde{\omega}_m(k) = V(k-1) + \\ &+ 2ar^{-1}(k)\tilde{\omega}_m^T(k-1)H(k)(\varepsilon(k, \hat{\omega}_m) - \\ &- \xi_m(k)) + 2ar^{-1}(k)\tilde{\omega}_m^T(k-1)H(k)\xi_m(k) + \\ &+ a^2r^{-2}(k)\|H(k)\|^2(\varepsilon(k, \hat{\omega}_m) - \xi_m(k))^2 + \\ &+ 2\xi_m(k)(\varepsilon(k, \hat{\omega}_m) - \xi_m(k)) + \xi_m^2(k), \end{aligned} \quad (6)$$

где  $\xi_m(k)$  – помеха с нулевым средним и ограниченной дисперсией  $\sigma_{\xi_m}^2$ . Вводя обозначения

$\tilde{\xi}_m(k) = \varepsilon(k, \hat{\omega}_m) - \xi_m(k)$  и  $b(k) = -H^T(k)\tilde{\omega}_m(k-1)$  и усредняя (6) по  $\xi_m(k)$ , получаем

$$\begin{aligned} M\{V(k) / \mathfrak{F}_k\} &= V(k-1) - 2ar^{-1}(k) \times \\ &\times b(k)\tilde{\xi}_m(k) + a^2r^{-2}(k)\|H(k)\|^2\tilde{\xi}_m^2(k) + \\ &+ a^2r^{-2}(k)\|H(k)\|^2\sigma_{\xi_m}^2. \end{aligned} \quad (7)$$

Здесь  $M\{\bullet / \bullet\}$  – символ условного математического ожидания;  $\mathfrak{F}_k$  –  $\sigma$ -алгебра, порожденная величинами  $\{y(0), y(1), \dots, y(k)\}$ ,  $\mathfrak{F}_0 \subset \mathfrak{F}_1 \subset \dots \subset \mathfrak{F}_k$ .

Далее, как и в [7], будем рассматривать последовательность (7) как супермартигал. При этом принципиальным моментом является выполнение на каждом шаге настройки сети условия  $r^2(k) > r(k)r(k-1)$  или,

$$(\alpha(k)r(k-1) + \|H(k)\|^2) > (\alpha(k)r(k-1) + \|H(k)\|^2)r(k-1).$$

Следовательно, нахождение требуемого  $\alpha(k)$  связано с решением неравенства

$$\begin{aligned} &\alpha^2(k) + \alpha(k)(2r(k-1)\|H(k)\|^2 - \\ &- r^2(k-1))r^{-2}(k-1) + (\|H(k)\|^4 - \\ &- \|H(k)\|^2r(k-1))r^{-2}(k-1) > 0, \end{aligned}$$

которое принимает вид

$$|\beta(k)| > \sqrt{m(k)}, \quad (8)$$

где

$$\beta(k) = \alpha(k) + \frac{2\|H(k)\|^2 - r(k-1)}{2r(k-1)}, \quad (9)$$

$$\begin{aligned} m(k) &= \left( \frac{2\|H(k)\|^2 - r^2(k-1)}{2r(k-1)} \right)^2 - \\ &- \frac{\|H(k)\|^4 - \|H(k)\|^2r(k-1)}{r^2(k-1)} = \frac{1}{4}. \end{aligned} \quad (10)$$

Из (9), (10) получаем

$$\alpha(k) + \frac{2\|H(k)\|^2 - r(k-1)}{2r(k-1)} > \frac{1}{2},$$

откуда имеем

$$1 - \frac{\|H(k)\|^2}{r(k-1)} < \alpha(k) \leq 1. \quad (11)$$

Из (11) следует очевидное соотношение

$$(1 - \alpha(k)) \sum_{j=1}^k \alpha^{k-j-1} \|H(k)\|^2 \leq \|H(k)\|^2,$$

являющееся решением уравнения

$$\alpha(k) = (\alpha_0\alpha(k-1) + (1 - \alpha_0)), \quad 0 \leq \alpha_0 \leq 1.$$

Следовательно, сходимость алгоритма (4) может обеспечиваться либо постоянным ростом величины  $\|H(k)\|^2$ , что можно сделать путем настройки центра и ширины гауссовской функции, либо соответствующим изменением параметра сглаживания  $\alpha(k)$ , который должен увеличиваться от 0 до 1.

Далее, используя в качестве характеристики скорости сходимости изменение функции Ляпунова на каждом шаге, можно оценить влияние  $\alpha(k)$  на скорость сходимости алгоритма (9). Значение, обеспечивающее максимальную скорость сходимости, равно  $r(k) = a\|H(k)\|^2$ .

Кроме того,  $r(k)$  определяется вторым соотношением из (4), откуда видно, что максимальное быстрое действие алгоритма достигается при  $a = 1$  и  $\alpha(k) = 0$ , т. е. обеспечивается процедурой (3).

Следовательно, в стохастических условиях для RBFN-сети с алгоритмом настройки синаптических весов (4) следящие свойства алгоритма (4), которые определяют скорость обучения сети, вступают в противоречие с его фильтрующими свойствами. Поэтому в процессе настройки синаптических весов целесообразно начинать работу с малых значений

параметра  $\alpha(k)$ , обеспечивая тем самым высокую скорость обучения сети, далее увеличивать его до уровня, обеспечивающего компромисс между фильтрующими и следящими свойствами алгоритма (4).

Рассмотрим теперь задачу настройки многослойного перцептрона вида [8]:

$$y(k+1) = \sum_{i=1}^{H_q} \omega_i^{(q)} f \left[ \sum_{t=1}^{H_q-1} \omega_{it}^{(q-1)} f \left[ \dots \right. \right. \\ \left. \left. f \left[ \sum_{j=1}^n \omega_{sj}^{(1)} y(k-j+1) + \sum_{j=1}^p \omega_{s,n+j}^{(1)} u(k-j+1) \right] \dots \right] \right], \quad (12)$$

где  $\omega_{sj}^{(k)}$  – синаптические веса  $k$ -го слоя;

$f(\bullet) = \{1 + \exp[-(\bullet)]\}^{-1}$  или  $f(\bullet) = \tanh(\bullet)$  – сигмоидальная функция активации или функция гиперболического тангенса соответственно. Запишем нелинейный одношаговый вариант алгоритма Маркварда [9]:

$$\omega(k+1) = \omega(k) + (G(\varphi(k), \omega) G^T(\varphi(k), \omega) + \\ + \rho(k) E)^{-1} G(\varphi(k), \omega) \varepsilon(k, \omega). \quad (13)$$

Здесь  $\omega(k) = (\omega_1(k), \omega_2(k), \dots, \omega_{n_\omega}(k))^T$  – вектор

всех синаптических весов;  $n_\omega = \sum_{i=0}^q (n_i + 1) n_{i+1} + n_{q-1} n_q$ ,

$q$  – количество слоев сети;  $n_i, 1 \leq q \leq n_i$  – количество нейронов  $i$ -го слоя;  $\varepsilon(k, \omega)$  определяется соотношением (2);  $\rho(k) > 0$ ,  $E$  – единичная матрица,  $G(\varphi(k), \omega) = \nabla_\omega f(\varphi(k), \omega)$ . Используя соотношения

$$\left\{ \begin{array}{l} \lim_{\rho(k) \rightarrow 0} (G(\varphi(k), \omega) G^T(\varphi(k), \omega) + \\ + \rho(k) E)^{-1} = (G(\varphi(k), \omega) G^T(\varphi(k), \omega))^+, \\ (G(\varphi(k), \omega) G^T(\varphi(k), \omega))^+ G(\varphi(k), \omega) = \\ = (G(\varphi(k), \omega))^+ = G(\varphi(k), \omega) \|G(\varphi(k), \omega)\|^{-2}, \end{array} \right.$$

запишем оптимальный по быстродействию вариант алгоритма (13) в виде

$$\omega(k+1) = \omega(k) + \frac{y(k) - \hat{y}(k, \omega)}{\|G(\varphi(k), \omega)\|^2} G(\varphi(k), \omega), \quad (14)$$

который в линейном случае совпадает с алгоритмом настройки синаптических весов Уидроу-Хоффа [7]. Как и в предыдущем случае, для того, чтобы придать дополнительные сглаживающие свойства алгоритму (14), необходимые при его использовании для настройки MLP-сети в задаче идентификации нелинейного нестационарного стохастического объекта, введем следующую экспоненциально-взвешенную модификацию:

$$\left\{ \begin{array}{l} \omega(k+1) = \omega(k) + r^{-1}(k)(y(k) - \hat{y}(k, \omega))G(\varphi(k), \omega), \\ r(k) = \alpha r(k-1) + \|G(\varphi(k), \omega)\|^2, \\ 0 \leq \alpha \leq 1, \quad r(0) = 1. \end{array} \right. \quad (15)$$

Анализ сходимости процедуры (15) можно провести с использованием той же техники, что была применена ранее. Однако следует учесть, что  $G(\varphi(k), \omega)$  – это градиент активационной функции, а алгоритм (15) в целом является нелинейным.

**Литература:** 1. Narendra K.S., Parthasarathy K. Identification and control of dynamical systems using neural networks // IEEE Trans. on Neural Networks. 1990. Vol.1, N1. P.4-26. 2. Sudharsanan S.I., Sudareshan M.K. Supervised training of dynamical neural networks for associative memory design and identification of nonlinear maps // Int. J. Neural Systems. 1994. Vol.5, N3. P.165-180. 3. Pham D.T., Liu X. Neural Networks for Identification, Prediction and Control. London: Springer-Verlag, 1995. 238p. 4. Chen S., Billings S.A. Neural networks for nonlinear dynamic system modeling and identification // Int. J. Control. 1992. Vol.56, N2. P.319-346. 6. Moody J., Darken C.J. Fast learning in networks of locally-tuned processing units // Neural Computation. 1989. N1. P.281-294. 6. Rojas R. Neural Networks. A Systematic Introduction. Berlin: Springer-Verlag, 1996. 502p. 7. Goodwin G.C., Ramadge P.J., Caines P.E. A globally convergent adaptive predictor // Automatica. 1981. Vol.17, N1. P.135-140. 8. Tan Y., van Cauwenberghe A. Nonlinear one-step-ahead control using neural networks: control strategy and stability design // Automatica. 1996. Vol.32, N12. P.1701-1706. 9. Marquardt D. An algorithm for least-squares estimation on nonlinear parameters // SIAM J. Appl. Math. 1963. N11. P.431-441.

Поступила в редколлегию 05.03.98

**Воробьев Сергей Анатольевич**, канд. техн. наук, старший научный сотрудник проблемной научно-исследовательской лаборатории автоматизированных систем управления ХТУРЭ. Научные интересы: искусственные нейронные сети, фильтрация и прогнозирование нестационарных процессов, фракталы и фрактальная размерность, иррационализм. Хобби: психология, иностранные языки, музыка. Служебный адрес: 310726, Украина, Харьков, пр. Ленина, 14; тел. (0572) 409890, (0572) 434278, e-mail: svor@kture.kharkov.ua.