

ближенно определить как

$$\alpha = \frac{t_s + t_2}{4} \quad (25)$$

Тогда общее время вычислений

$$t_0 = \frac{(4+L)(t_s + t_2)}{4} \quad (26)$$

Для эффективности вычислений в конвейерном режиме необходимо выполнение следующего неравенства:

$$\frac{(4+L)(t_s + t_2)}{4} < t_s L \quad (27)$$

Выражая из последнего выражения L , получим

$$L > \frac{4(t_s + t_2)}{3t_s - t_2} \quad (28)$$

Проведем анализ трудоемкости вычислений каждой стадии конвейера. Используя результаты предыдущего раздела, можно получить количество операций, вычисляемых каждым процессором

$$V(P_1) = m(2n + 1) \quad (29)$$

$$V(P_2) = (2m + 1) \quad (30)$$

$$V(P_3) = (4m + 4) \quad (31)$$

$$V(P_4) = m(4n + 4) \quad (32)$$

Отсюда следует, что различные ступени конвейера характеризуются различной сложностью вычислений. При этом время такта конвейера будет определяться временем прохождения самой медленной ступени P_4 . Для нейтрализации этого недостатка можно предложить конвейерно-параллельную схему. Она заключается в том, что самая медленная ступень разбивается, например, на m параллельно работающих процессоров, как это показано на рис. 6 для четвертой ступени.




Рисунок 6 – Схема конвейерно-параллельной параллелизации.

УДК 681.324: 519.711.7

Махнист Л.П.

ОБУЧЕНИЕ НЕЙРОННЫХ СЕТЕЙ С ИСПОЛЬЗОВАНИЕМ МЕТОДА СОПРЯЖЕННЫХ ГРАДИЕНТОВ

ВВЕДЕНИЕ

Рассмотрим нейронную сеть, состоящую из n нейронных элементов распределительного слоя и m - выходного слоя (рис. 1).

Для данной сети каждый нейрон распределительного слоя

В результате этого количество операций четвертой ступени конвейера можно сократить в среднем в m раз. Аналогичные действия можно применить для других ступеней конвейера, что позволяет повысить производительность вычислений.

Следующий вариант распараллеливания алгоритма обучения – групповая параллелизация. Такая схема предполагает разбиение обучающего множества на K групп и использования для каждой группы своей нейронной сети (рис. 7).




Рисунок 7 – Групповая параллелизация.

Количество образов в группе равняется L/K . Фаза межмодульного обмена в такой схеме происходит после подачи L/K образов в каждый процессор и заключается в изменении соответствующих синаптических связей. В качестве процессора P_i в такой схеме можно использовать последовательный процессор, параллельный процессор, рассмотренный в предыдущем разделе, и одну из конвейерных схем. Если применяется последовательный процессор, то производительность групповой параллелизации в K раз больше по сравнению с одним процессором. Аналогичное соотношение наблюдается для других схем параллелизации.

ЗАКЛЮЧЕНИЕ

Таким образом, в данной работе рассмотрены различные схемы реализации нейронных сетей на многопроцессорных системах. Приведены аналитические соотношения, позволяющие оценивать эффективность различных схем параллелизации. Окончательный выбор варианта параллелизации зависит от архитектуры многопроцессорной системы и допустимых аппаратных издержек, затрачиваемых на реализацию соответствующего алгоритма параллелизации.

СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

1. Frank M. Thiesing, Ulrich Middelberg, Oliver Vornberger. Parallel Back-Propagation for Sales Prediction on Transputer System. Harrogate. UK. Proc. Of World Transputer Congress. 1995.
2. Головкин В.А. Нейроинтеллект: теория и применение. Книга 1: Организация и обучение нейронных сетей с прямыми и обратными связями. Брест. Изд. БПИ, 1999 – 264 с.
3. Weigend A., Gershenfeld N. Time series prediction: forecasting the future and understanding past // Proceedings of the Santa Fe Institute. New Mexico: Addison-Wesley. – 1992. – 336 p.

имеет синаптические связи w_{ij} , ($i = \overline{1, n}$, $j = \overline{1, m}$) со всеми нейронами обрабатывающего слоя. В качестве нейронов выходного слоя используются элементы с некоторой функцией активации F [1, 2]. На вход сети подаются входные

Махнист Леонид Петрович. К.т.н., доцент каф. высшей математики Брестского государственного технического университета.

Беларусь, БГТУ, 224017, г. Брест, ул. Московская, 267.

образы – векторы $\bar{x}^k = (x_1^k, \dots, x_n^k)$ ($k = \overline{1, L}$).




Рисунок 1 – Схема функционирования нейронной сети.

Выходное значение j -ого нейрона сети для k -ого образа определяется выражением:

$$y_j^k = F(S_j^k),$$

где

$$S_j^k = \sum_{i=1}^n w_{ij} x_i^k - T_j, \quad j = \overline{1, m}, \quad k = \overline{1, L}.$$

Задача обучения нейронной сети с фиксированной функцией активации F состоит в нахождении весовых коэффициентов w_{ij} ($i = \overline{1, n}, j = \overline{1, m}$) и порогов нейронных элементов T_j ($j = \overline{1, m}$), которые минимизируют некоторую ошибку сети E_S , как отклонение выходных значений y_j^k от эталонных значений t_j^k – j -ого нейрона сети для k -ого образа. В качестве ошибки сети можно рассмотреть “квадратичное отклонение” $E_S = \frac{1}{2} \sum_{k=1}^L \sum_{j=1}^m (y_j^k - t_j^k)^2$, которое будем

называть квадратичной ошибкой сети.

Столбец

$\bar{W} = (w_{11}, w_{21}, \dots, w_{n1}, T_1, w_{12}, w_{22}, \dots, w_{n2}, T_2, \dots, w_{1m}, w_{2m}, \dots, w_{nm}, T_m)^T$ будем называть приближенным решением или просто решением системы (по методу наименьших квадратов):

$$F\left(\sum_{i=1}^n w_{ij} x_i^k - T_j\right) = t_j^k, \quad j = \overline{1, m}, \quad k = \overline{1, L},$$

если “квадратичное отклонение”

$$E_S = \frac{1}{2} \sum_{k=1}^L \sum_{j=1}^m \left(F\left(\sum_{i=1}^n w_{ij} x_i^k - T_j\right) - t_j^k\right)^2$$

достигает своего наименьшего значения. Для нахождения такого решения можно применять различные градиентные методы [1, 2], например, метод сопряженных градиентов и его модификации, которые будут рассмотрены ниже.

ВЫРАЖЕНИЯ КВАЗИОПТИМАЛЬНЫХ ПАРАМЕТРОВ ШАГА ОБУЧЕНИЯ НЕЙРОННОЙ СЕТИ С ИСПОЛЬЗОВАНИЕМ МЕТОДА СОПРЯЖЕННЫХ ГРАДИЕНТОВ

Получим выражения для квазиоптимальных параметров шага обучения нейронной сети с использованием метода сопряженных градиентов после подачи на вход сети нескольких образов $\bar{x}^k = (x_1^k, \dots, x_n^k)$ ($k = \overline{1, L}$).

Рассмотрим дважды непрерывно дифференцируемую функцию $E_S(t)$ – ошибку сети, как функцию нескольких переменных:

$$E_S(w_{11}, w_{21}, \dots, w_{n1}, T_1, w_{12}, w_{22}, \dots, w_{n2}, T_2, \dots, w_{1m}, w_{2m}, \dots, w_{nm}, T_m)$$

Разложим функцию в ряд Тейлора, ограничиваясь частными производными второго порядка включительно:

$$E_S(t+1) = E_S(t) + (\nabla E_S(t), \bar{W}(t+1) - \bar{W}(t)) + \frac{1}{2} (\nabla^2 E_S(t) \cdot (\bar{W}(t+1) - \bar{W}(t)), \bar{W}(t+1) - \bar{W}(t)).$$

Учитывая, что в соответствии с идеей метода сопряженных градиентов

$$\bar{W}(t+1) = \bar{W}(t) - \alpha(t) \cdot \nabla E_S(t) + \beta(t) \cdot (\bar{W}(t) - \bar{W}(t-1)) \quad (1)$$

и введя обозначение $\Delta \bar{W}(t) = \bar{W}(t) - \bar{W}(t-1)$, получим

$$\begin{aligned} E_S(t+1) &= E_S(t) + (\nabla E_S(t), -\alpha(t) \cdot \nabla E_S(t) + \beta(t) \cdot \Delta \bar{W}(t)) + \\ &+ \frac{1}{2} (\nabla^2 E_S(t) \cdot (-\alpha(t) \cdot \nabla E_S(t) + \beta(t) \cdot \Delta \bar{W}(t)), \\ &- \alpha(t) \cdot \nabla E_S(t) + \beta(t) \cdot \Delta \bar{W}(t)) = \\ &= E_S(t) - \alpha(t) \cdot (\nabla E_S(t), \nabla E_S(t)) + \\ &+ \beta(t) \cdot (\nabla E_S(t), \Delta \bar{W}(t)) + \\ &+ \frac{1}{2} \alpha^2(t) (\nabla^2 E_S(t) \cdot \nabla E_S(t), \nabla E_S(t)) - \\ &- \alpha(t) \beta(t) \cdot (\nabla^2 E_S(t) \cdot \nabla E_S(t), \Delta \bar{W}(t)) + \\ &+ \frac{1}{2} \beta^2(t) \cdot (\nabla^2 E_S(t) \cdot \Delta \bar{W}(t), \Delta \bar{W}(t)). \end{aligned}$$

Найдем критические точки функции $E_S(t+1) = E_S(\alpha; \beta)$, как функции двух переменных.

Для этого найдем частные производные функции $E_S(\alpha; \beta)$ и решим систему уравнений:

$$\begin{cases} \frac{\partial E_S}{\partial \alpha} = -(\nabla E_S, \nabla E_S) + \alpha \cdot (\nabla^2 E_S \cdot \nabla E_S, \nabla E_S) - \\ - \beta \cdot (\nabla^2 E_S \cdot \nabla E_S, \Delta \bar{W}) = 0 \\ \frac{\partial E_S}{\partial \beta} = (\nabla E_S, \Delta \bar{W}) - \alpha \cdot (\nabla^2 E_S \cdot \nabla E_S, \Delta \bar{W}) + \\ + \beta \cdot (\nabla^2 E_S \cdot \Delta \bar{W}, \Delta \bar{W}) = 0 \end{cases}$$

Тогда приходим к системе:

$$\begin{cases} \alpha \cdot (\nabla^2 E_S \cdot \nabla E_S, \nabla E_S) - \beta \cdot (\nabla^2 E_S \cdot \nabla E_S, \Delta \bar{W}) = \\ = (\nabla E_S, \nabla E_S) \\ \alpha \cdot (\nabla^2 E_S \cdot \nabla E_S, \Delta \bar{W}) - \beta \cdot (\nabla^2 E_S \cdot \Delta \bar{W}, \Delta \bar{W}) = \\ = (\nabla E_S, \Delta \bar{W}) \end{cases}$$

Следовательно,

$$\left\{ \begin{aligned} \alpha &= \frac{\left| \begin{pmatrix} \nabla E_S, \nabla E_S \\ \nabla E_S, \Delta W \end{pmatrix} - \begin{pmatrix} \nabla^2 E_S \cdot \nabla E_S, \overline{\Delta W} \\ \nabla^2 E_S \cdot \Delta W, \Delta W \end{pmatrix} \right|}{\left| \begin{pmatrix} \nabla^2 E_S \cdot \nabla E_S, \nabla E_S \\ \nabla^2 E_S \cdot \nabla E_S, \Delta W \end{pmatrix} - \begin{pmatrix} \nabla^2 E_S \cdot \nabla E_S, \overline{\Delta W} \\ \nabla^2 E_S \cdot \Delta W, \Delta W \end{pmatrix} \right|} \\ \beta &= \frac{\left| \begin{pmatrix} \nabla^2 E_S \cdot \nabla E_S, \nabla E_S \\ \nabla^2 E_S \cdot \nabla E_S, \Delta W \end{pmatrix} \begin{pmatrix} \nabla E_S, \nabla E_S \\ \nabla E_S, \Delta W \end{pmatrix} \right|}{\left| \begin{pmatrix} \nabla^2 E_S \cdot \nabla E_S, \nabla E_S \\ \nabla^2 E_S \cdot \nabla E_S, \Delta W \end{pmatrix} - \begin{pmatrix} \nabla^2 E_S \cdot \nabla E_S, \overline{\Delta W} \\ \nabla^2 E_S \cdot \Delta W, \Delta W \end{pmatrix} \right|} \end{aligned} \right.$$

или

$$\left\{ \begin{aligned} \alpha &= \frac{-\left(\nabla E_S, \nabla E_S\right) \cdot \left(\nabla^2 E_S \cdot \overline{\Delta W}, \overline{\Delta W}\right) + \left(\nabla E_S, \overline{\Delta W}\right) \cdot \left(\nabla^2 E_S \cdot \nabla E_S, \overline{\Delta W}\right)}{-\left(\nabla^2 E_S \cdot \nabla E_S, \nabla E_S\right) \cdot \left(\nabla^2 E_S \cdot \overline{\Delta W}, \overline{\Delta W}\right) + \left(\nabla^2 E_S \cdot \nabla E_S, \overline{\Delta W}\right)^2} \\ \beta &= \frac{\left(\nabla E_S, \overline{\Delta W}\right) \cdot \left(\nabla^2 E_S \cdot \nabla E_S, \nabla E_S\right) - \left(\nabla E_S, \nabla E_S\right) \cdot \left(\nabla^2 E_S \cdot \nabla E_S, \overline{\Delta W}\right)}{-\left(\nabla^2 E_S \cdot \nabla E_S, \nabla E_S\right) \cdot \left(\nabla^2 E_S \cdot \overline{\Delta W}, \overline{\Delta W}\right) + \left(\nabla^2 E_S \cdot \nabla E_S, \overline{\Delta W}\right)^2} \end{aligned} \right.$$

Таким образом (2).

Вычислим частные производные второго порядка функции $E_S(\alpha; \beta)$:

$$\frac{\partial^2 E_S}{\partial \alpha^2} = \left(\nabla^2 E_S \cdot \nabla E_S, \nabla E_S\right),$$

$$\frac{\partial^2 E_S}{\partial \alpha \partial \beta} = \frac{\partial^2 E_S}{\partial \beta \partial \alpha} = -\left(\nabla^2 E_S \cdot \nabla E_S, \overline{\Delta W}\right) \text{ и}$$

$$\frac{\partial^2 E_S}{\partial \beta^2} = \left(\nabla^2 E_S(t) \cdot \overline{\Delta W}, \overline{\Delta W}\right).$$

Тогда гессиан $\left|\nabla^2 E_S(\alpha; \beta)\right|$ функции $E_S(\alpha; \beta)$ равен

$$\left|\nabla^2 E_S(\alpha; \beta)\right| = \left| \begin{pmatrix} \nabla^2 E_S \cdot \nabla E_S, \nabla E_S & -\left(\nabla^2 E_S \cdot \nabla E_S, \overline{\Delta W}\right) \\ -\left(\nabla^2 E_S \cdot \nabla E_S, \overline{\Delta W}\right) & \left(\nabla^2 E_S \cdot \nabla E_S, \overline{\Delta W}\right) \end{pmatrix} \right| = \\ = \left(\nabla^2 E_S \cdot \nabla E_S, \nabla E_S\right) \cdot \left(\nabla^2 E_S \cdot \overline{\Delta W}, \overline{\Delta W}\right) - \left(\nabla^2 E_S \cdot \nabla E_S, \overline{\Delta W}\right)^2.$$

В случае если $\left|\nabla^2 E_S(\alpha; \beta)\right| > 0$ и $\left(\nabla^2 E_S \cdot \nabla E_S, \nabla E_S\right) > 0$, то функция $E_S(\alpha; \beta)$ достигает минимального значения при $\alpha(t)$ и $\beta(t)$, определяе-

мыми соотношениями (2).

Таким образом, доказано следующее утверждение.

Теорема. Величины квазиоптимальных параметров $\alpha(t)$ и $\beta(t)$ шага обучения нейронной сети с использованием метода сопряженных градиентов в момент времени t определяется соотношениями [3] (3, 4), где функция квадратичной ошибки сети

$$E_S(t) = E_S(w_{11}, w_{21}, \dots, w_{n1}, T_1, w_{12}, w_{22}, \dots, w_{n2}, T_2, \dots, w_{1m}, w_{2m}, \dots, w_{nm}, T_m)$$

дважды непрерывно дифференцируемая функция нескольких переменных,

$$\overline{W}(t) = (w_{11}, w_{21}, \dots, w_{n1}, T_1, w_{12}, w_{22}, \dots, w_{n2}, T_2, \dots, w_{1m}, w_{2m}, \dots, w_{nm}, T_m)^T$$

вектор переменных,

$$\nabla E_S(t) = \left(\frac{\partial E_S}{\partial w_{11}}, \frac{\partial E_S}{\partial w_{21}}, \dots, \frac{\partial E_S}{\partial w_{n1}}, \frac{\partial E_S}{\partial T_1}, \frac{\partial E_S}{\partial w_{12}}, \frac{\partial E_S}{\partial w_{22}}, \dots, \frac{\partial E_S}{\partial w_{n2}}, \frac{\partial E_S}{\partial T_2}, \dots, \frac{\partial E_S}{\partial w_{1m}}, \frac{\partial E_S}{\partial w_{2m}}, \dots, \frac{\partial E_S}{\partial w_{nm}}, \frac{\partial E_S}{\partial T_m} \right)^T$$

вектор градиента функции $E_S(t)$, $\nabla^2 E_S(t)$ – матрица Гессе вторых производных функции $E_S(t)$ в момент времени t .

Так как

$$\frac{\partial E_S}{\partial w_{ij}(t)} = \sum_p (y_j^p - t_j^p) \cdot F'(S_j^p) x_i^p, \\ (i = \overline{1, n}, j = \overline{1, m}),$$

и

$$\frac{\partial E_S}{\partial T_j(t)} = -\sum_p (y_j^p - t_j^p) F'(S_j^p), (j = \overline{1, m}),$$

то, подставляя эти соотношения в (1), получим, что модификация синаптических связей с использованием квазиоптимальных параметров шага обучения определяется выражениями:

$$w_{ij}(t+1) = w_{ij}(t) - \alpha(t) \sum_{k=1}^L (y_j^k(t) - t_j^k) \cdot F'(S_j^k(t)) x_i^k + \beta(t) (w_{ij}(t) - w_{ij}(t-1)), i = \overline{1, n}, j = \overline{1, m} \quad (5)$$

$$\left\{ \begin{aligned} \alpha(t) &= \frac{\|\nabla E_S(t)\|^2 \cdot \left(\nabla^2 E_S(t) \cdot \overline{\Delta W}(t), \overline{\Delta W}(t)\right) - \left(\nabla E_S(t), \overline{\Delta W}(t)\right) \cdot \left(\nabla^2 E_S(t) \cdot \nabla E_S(t), \overline{\Delta W}(t)\right)}{\left(\nabla^2 E_S(t) \cdot \nabla E_S(t), \nabla E_S(t)\right) \cdot \left(\nabla^2 E_S(t) \cdot \overline{\Delta W}(t), \overline{\Delta W}(t)\right) - \left(\nabla^2 E_S(t) \cdot \nabla E_S(t), \overline{\Delta W}(t)\right)^2} \\ \beta(t) &= \frac{\|\nabla E_S(t)\|^2 \cdot \left(\nabla^2 E_S(t) \cdot \nabla E_S(t), \overline{\Delta W}(t)\right) - \left(\nabla E_S(t), \overline{\Delta W}(t)\right) \cdot \left(\nabla^2 E_S(t) \cdot \nabla E_S(t), \nabla E_S(t)\right)}{\left(\nabla^2 E_S(t) \cdot \nabla E_S(t), \nabla E_S(t)\right) \cdot \left(\nabla^2 E_S(t) \cdot \overline{\Delta W}(t), \overline{\Delta W}(t)\right) - \left(\nabla^2 E_S(t) \cdot \nabla E_S(t), \overline{\Delta W}(t)\right)^2} \end{aligned} \right. \quad (2)$$

$$\alpha(t) = \frac{\|\nabla E_S(t)\|^2 \cdot \left(\nabla^2 E_S(t) \cdot \overline{\Delta W}(t), \overline{\Delta W}(t)\right) - \left(\nabla E_S(t), \overline{\Delta W}(t)\right) \cdot \left(\nabla^2 E_S(t) \cdot \nabla E_S(t), \overline{\Delta W}(t)\right)}{\left(\nabla^2 E_S(t) \cdot \nabla E_S(t), \nabla E_S(t)\right) \cdot \left(\nabla^2 E_S(t) \cdot \overline{\Delta W}(t), \overline{\Delta W}(t)\right) - \left(\nabla^2 E_S(t) \cdot \nabla E_S(t), \overline{\Delta W}(t)\right)^2} \quad (3)$$

$$\beta(t) = \frac{\|\nabla E_S(t)\|^2 \cdot \left(\nabla^2 E_S(t) \cdot \nabla E_S(t), \overline{\Delta W}(t)\right) - \left(\nabla E_S(t), \overline{\Delta W}(t)\right) \cdot \left(\nabla^2 E_S(t) \cdot \nabla E_S(t), \nabla E_S(t)\right)}{\left(\nabla^2 E_S(t) \cdot \nabla E_S(t), \nabla E_S(t)\right) \cdot \left(\nabla^2 E_S(t) \cdot \overline{\Delta W}(t), \overline{\Delta W}(t)\right) - \left(\nabla^2 E_S(t) \cdot \nabla E_S(t), \overline{\Delta W}(t)\right)^2} \quad (4)$$

$$T_j(t+1) = T_j(t) + \alpha(t) \sum_{k=1}^L (y_j^k(t) - t_j^k) F'(S_j^k(t)) + \beta(t)(T_j(t) - T_j(t-1)), \quad j = \overline{1, m} \quad (6)$$

Замечание. Для использования соотношений (3)-(6) необходимо знать начальные значения $\overline{W}(0)$ и $\overline{W}(1)$. Как правило, вектор $\overline{W}(0)$ получают случайной инициализацией, а вектор $\overline{W}(1)$ может быть вычислен на основании соотношений для шага обучения нейронной сети с использованием метода наискорейшего спуска [2]:

$$\alpha(t) = \frac{\sum_{k=1}^L \sum_{j=1}^m (y_j^k(t) - t_j^k) F'(S_j^k(t)) a_j^k(t)}{\sum_{k=1}^L \sum_{j=1}^m ((F'(S_j^k(t)))^2 + (y_j^k(t) - t_j^k) F'(S_j^k(t))) (a_j^k(t))^2} \quad (7)$$

где $a_j^k(t) = \sum_{p=1}^L (y_j^p(t) - t_j^p) F'(S_j^p(t)) \left(\sum_{i=1}^n x_i^p x_i^k + 1 \right)$, и $j = \overline{1, m}, k = \overline{1, L}$

$$w_{ij}(t+1) = w_{ij}(t) - \alpha(t) \cdot \sum_{k=1}^L (y_j^k(t) - t_j^k) \cdot F'(S_j^k(t)) x_i^k, \quad i = \overline{1, n}, j = \overline{1, m}$$

$$T_j(t+1) = T_j(t) + \alpha(t) \cdot \sum_{k=1}^L (y_j^k(t) - t_j^k) F'(S_j^k(t)), \quad j = \overline{1, m}$$

Легко показать, что такой же вектор $\overline{W}(1)$ может быть получен с использованием метода сопряженных градиентов, определяемого выражениями (5), (6), где $\beta(t) = 0$, а $\alpha(t)$ будет вычислено в соответствии с (7).

АЛГОРИТМ ОБУЧЕНИЯ НЕЙРОННОЙ СЕТИ С ИСПОЛЬЗОВАНИЕМ МЕТОДА СОПРЯЖЕННЫХ ГРАДИЕНТОВ

Приведем алгоритм обучения нейронной сети с использованием метода сопряженных градиентов, использующий соотношения (3)-(6):

1. задается минимальная квадратичная ошибка сети ϵ_m , которой необходимо достичь в процессе обучения.
2. Записывается число $t=0$ в счетчик числа итераций алгоритма.

3. Случайным образом инициализируются весовые коэффициенты сети $w_{ij}(t)$ ($i = \overline{1, n}, j = \overline{1, m}$), и пороговые значения нейронных элементов $T_j(t)$ ($j = \overline{1, m}$).

4. Подаются входные образы $\overline{x}^k = (x_1^k, \dots, x_n^k)$ ($k = \overline{1, L}$) на нейронную сеть и вычисляются векторы $\overline{y}^k(t) = (y_1^k(t), \dots, y_m^k(t))$ ($k = \overline{1, L}$) выходной активности сети, определяемые соотношениями (4).

5. Если $t \neq 0$, то величины квазиоптимальных параметров $\alpha(t)$, $\beta(t)$ шага обучения с использованием метода сопряженных градиентов вычисляются в соответствии с соотношениями (3)-(4), в противном случае параметр $\alpha(t)$ определяется выражением (7), а $\beta(t)$ полагается равным нулю.

6. Производится изменение весовых коэффициентов $w_{ij}(t+1)$ ($i = \overline{1, n}, j = \overline{1, m}$) и порогов нейронной сети $T_j(t+1)$ ($j = \overline{1, m}$) согласно выражениям (5) и (6), соответственно.

7. Полагается $t=t+1$.

8. Алгоритм завершает свою работу, если суммарная квадратичная ошибка сети $E_S(t) = \frac{1}{2} \sum_{j=1}^m \sum_{k=1}^L (y_j^k(t) - t_j^k)^2$ или норма вектора $\overline{\Delta W}(t) = \overline{W}(t) - \overline{W}(t-1)$ не превосходят заданной величины ϵ_m , т. е. $E_S(t) \leq \epsilon_m$ или $\|\overline{\Delta W}(t)\| =$

$$= \sqrt{\sum_{i=1}^n \sum_{j=1}^m (w_{ij}(t) - w_{ij}(t-1))^2 + \sum_{j=1}^m (T_j(t) - T_j(t-1))^2} < \epsilon_m$$

в противном случае выполняется п. 4.

СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

1. Головкин В.А. Нейронные сети: обучение, организация и применение. Кн. 4: Учебное пособие для вузов / Общая ред. А.И. Галушкина. – М.: ИПРЖР, 2001. – 256 с.: ил. (Нейрокомпьютеры и их применение).
2. Гладкий И.И., Головкин В.А., Махнист Л.П. Обучение нейронных сетей с использованием метода наискорейшего спуска // Вестник Брестского государственного технического университета. – Брест: БГТУ, 2001. – № 5: Физика, математика, химия. – С. 47-55.
3. Махнист Л.П. О решении одной системы разностно-дифференциальных уравнений и ее применении // Тезисы докладов международной математической конференции “Еругинские чтения – VIII”. – Брест: БрГУ, 2002. – С. 88-89.