

文章编号: 1000- 0887(2008) 09- 1117- 07

© 应用数学和力学编委会, ISSN 1000- 0887

Elman 网络梯度学习法的收敛性^{*}

吴 微, 徐东坡, 李正学

(大连理工大学 应用数学系, 辽宁 大连 116023)

(郭兴明推荐)

摘要: 考虑有限样本集上 Elman 网络梯度学习法的确定性收敛性. 证明了误差函数的单调递减性. 给出了一个弱收敛性结果和一个强收敛结果, 表明误差函数的梯度收敛于 0, 权值序列收敛于固定点. 通过数值例子验证了理论结果的正确性.

关 键 词: Elman 神经网络; 梯度学习算法; 收敛性; 单调性

中图分类号: TP183 文献标识码: A

引 言

Elman 网络是一类带隐层的递归神经网络, 每个隐单元通过反馈连接到全部隐单元^[1- 2]. 这个反馈连接使得 Elman 神经网络能够学习, 识别和生成时间模式与空间模式^[3]. 用于时间序列分类, Elman 网络是一种强有力的工具^[4], 线性与非线性动态系统建模^[5]. Elman 网络已经广泛地应用在许多不同的领域, 如语言习得^[6]、噪声生成^[7]、故障定位^[8]和流估计^[9]. Elman 网络包含在流行的 Matlab 神经网络工具箱里^[10].

类似于前馈神经网络情况, 梯度学习算法普遍用于训练递归神经网络^[11- 12], 主要由于它的简单性. Elman 网络梯度法的收敛性理论分析有助于理解方法的行为, 引导这个最简单学习方法的进一步改进.

对于对角型 Elman 网络, 下面(1)式中 V_2 是对角阵时, 文献[13- 14]研究了梯度法的收敛性. 对于一般型 Elman 网络, 已存在的收敛结果^[15]是概率性的渐进收敛性, 其假设训练样本的个数趋紧于无穷. 本文, 只考虑有限训练样本集可以利用, 不适合用随机理论方法处理. 相反, 用离线梯度法训练 Elman 网络, 相应地证明了一些确定性收敛结果. 表明在训练过程中误差函数单调下降, 它的梯度收敛于 0. 本文的证明用到了文献[16- 17]中的一些技巧.

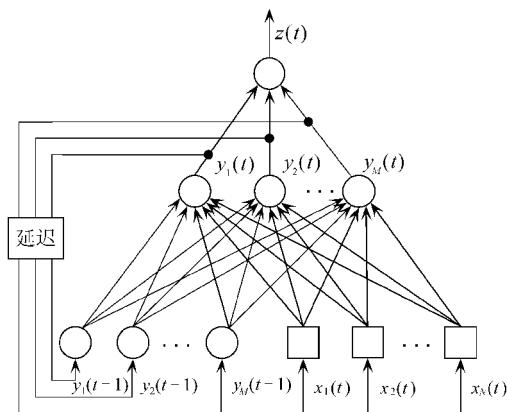
1 Elman 神经网络结构

如图 1 所示, Elman 网络具有 N 个输入神经元, M 个隐层神经元和一个输出神经元. 输入和递归权值矩阵分别为 $V_1 \in R^{M \times N}$ 和 $V_2 \in R^{M \times M}$. 为表述的简单, 我们合并权值矩阵为

* 收稿日期: 2007- 12- 05; 修订日期: 2008- 07- 19

基金项目: 国家自然科学基金资助项目(10471017)

作者简介: 吴微(1953—), 男, 黑龙江牡丹江人, 教授, 博士生导师(联系人. Tel: +86- 411- 84708294;
E-mail: wuweiw@dlut.edu.cn).

图 1 Elman 神经网络 $N - M - 1$ 结构

$$\mathbf{W}_1 = (\mathbf{V}_1, \mathbf{V}_2) \in R^{M \times (N+M)}, \quad (1)$$

$w_0 \in R^M$ 表示隐层神经元和输出神经元连接的权值向量。对于时间序列 $\{x(t), t = 1, 2, \dots\} \subset R^N$ 输入给网络, 用 $y(t) \in R^M$ 表示隐层 t 时刻的相应输出, 定义 $y(0) = 0$. 假定 $g: \mathbf{R} \rightarrow \mathbf{R}$ 为隐层神经元和输出神经元的激活函数, 对任意向量 $a = (a_1, a_2, \dots, a_M)^T \in R^M$, 引入如下向量函数:

$$\mathbf{G}(a) = (g(a_1), g(a_2), \dots, g(a_M))^T. \quad (2)$$

为方便起见, 结合 $x(t)$ 和 $y(t-1)$ 为 $N+M$ 维向量

$$\mathbf{u}(t) = \begin{pmatrix} \mathbf{x}(t) \\ \mathbf{y}(t-1) \end{pmatrix}, \quad t = 1, 2, \dots, \quad (3)$$

隐层的输入为

$$s(t) = \mathbf{W}_1 \mathbf{u}(t) = \mathbf{V}_1 \mathbf{x}(t) + \mathbf{V}_2 \mathbf{y}(t-1), \quad t = 1, 2, \dots, \quad (4)$$

隐层的输出为

$$\mathbf{y}(t) = \mathbf{G}(s(t)). \quad (5)$$

网络的输出为

$$z(t) = g(\mathbf{w}_0 \cdot \mathbf{y}(t)), \quad t = 1, 2, \dots. \quad (6)$$

2 梯度学习算法

对于任意矩阵 $A \in R^{m \times n}$ 与向量 $\mathbf{x} \in R^n$, 其范数分别定义为 $\|A\| = \left(\sum_{i=1}^m \sum_{j=1}^n a_{ij}^2 \right)^{1/2}$ 和 $\|\mathbf{x}\| = \left(\sum_{i=1}^n x_i^2 \right)^{1/2}$, 显然 $\|Ax\| \leq \|A\| \|\mathbf{x}\|$.

定义 2.1 给定 $m \times n$ 矩阵 $A = (a_{ij})$, $\text{vec}A$ 定义为 mn 维向量如下:

$$\text{vec}A = (a_{11}, a_{21}, \dots, a_{m1}, a_{12}, a_{22}, \dots, a_{m2}, \dots, a_{1n}, a_{2n}, \dots, a_{mn})^T. \quad (7)$$

定义 2.2 $A = (a_{ij})$ 是 $p \times q$ 矩阵, $A^{(n)}$ 定义为 $A^{(n)} = (a_{ij}^n)$.

定义 2.3 $A = (a_{ij})$ 是 $m \times n$ 矩阵, $B = (b_{ij})$ 是 $p \times q$ 矩阵, Kronecker 积 $A \times B$ 是 $mp \times nq$ 矩阵, 其定义为

$$A \times B = \begin{bmatrix} a_{11}B & a_{12}B & \dots & a_{1n}B \\ a_{21}B & a_{22}B & \dots & a_{2n}B \\ \vdots & \vdots & & \vdots \\ a_{m1}B & a_{m2}B & \dots & a_{mn}B \end{bmatrix}. \quad (8)$$

定义 2.4 对于(2)式 $\mathbf{G}(a)$, 定义 $\mathbf{G}'(a)$ 为对角矩阵, 其对角元素为 $g'(a_1), \dots, g'(a_M)$. 同样定义 $\mathbf{G}''(a)$ 为对角矩阵, 其对角元素为 $g''(a_1), \dots, g''(a_M)$.

现在描述梯度学习算法. 假设训练样本集为 $\{\mathbf{x}(t), O(t)\}_{t=1}^Q$, 令

$$\mathbf{w}_1 = \text{vec} \mathbf{W}_1, \quad (9)$$

$$\mathbf{w} = \text{vec}(\mathbf{w}_0, \mathbf{W}_1). \quad (10)$$

定义平方误差函数

$$E(\mathbf{w}) = \frac{1}{2} \sum_{t=1}^Q (O(t) - g(\mathbf{w}_0 \cdot \mathbf{G}(\mathbf{W}_1 \mathbf{u}(t))))^2. \quad (11)$$

网络学习的目的是找到 \mathbf{w}^* , 使得

$$E(\mathbf{w}^*) = \min E(\mathbf{w}). \quad (12)$$

对 $E(\mathbf{w})$ 关于 \mathbf{w}_0 和 \mathbf{w}_1 分别求偏导, 定义相应的梯度函数

$$E_{\mathbf{w}_0}(\mathbf{w}) = - \sum_{t=1}^Q (O(t) - z(t)) g'(\mathbf{w}_0 \cdot \mathbf{y}(t)) \mathbf{y}(t), \quad (13)$$

$$E_{\mathbf{w}_1}(\mathbf{w}) = - \sum_{t=1}^Q (O(t) - z(t)) g'(\mathbf{w}_0 \cdot \mathbf{y}(t)) (\mathbf{P}(t))^T \mathbf{w}_0, \quad (14)$$

这里

$$\mathbf{P}(t) = \mathbf{G}'(s(t))((\mathbf{u}(t))^T - \mathbf{I}_M + \mathbf{V}_2 \mathbf{P}(t-1)), \quad (15)$$

初始条件为 $\mathbf{P}(0) = 0$, \mathbf{I}_M 是 $M \times M$ 单位阵.

任意给定初始权值 \mathbf{w}^0 , 生成权值序列 \mathbf{w}^k

$$\mathbf{w}^{k+1} = \mathbf{w}^k - \eta E_{\mathbf{w}}(\mathbf{w}^k), \quad k = 0, 1, 2, \dots, \quad (16)$$

这里

$$E_{\mathbf{w}}(\mathbf{w}^k) = \begin{pmatrix} E_{\mathbf{w}_0}(\mathbf{w}^k) \\ E_{\mathbf{w}_1}(\mathbf{w}^k) \end{pmatrix}, \quad (17)$$

其中, $\eta \in (0, 1)$ 是常数学习率.

令

$$\Delta \mathbf{w}^k = \mathbf{w}^{k+1} - \mathbf{w}^k, \quad (18)$$

那么

$$\Delta \mathbf{w}_0^k = \eta \sum_{t=1}^Q (O(t) - z^k(t)) g'(\mathbf{w}_0^k \cdot \mathbf{y}^k(t)) \mathbf{y}^k(t), \quad (19)$$

$$\Delta \mathbf{w}_1^k = \eta \sum_{t=1}^Q (O(t) - z^k(t)) g'(\mathbf{w}_0^k \cdot \mathbf{y}^k(t)) (\mathbf{P}(\mathbf{w}_1^k, t))^T \mathbf{w}_0^k, \quad (20)$$

这里

$$z^k(t) = z(\mathbf{w}^k, t), \quad \mathbf{y}^k(t) = \mathbf{y}(\mathbf{w}_1^k, t), \quad (21)$$

$$s^k(t) = s(\mathbf{w}_1^k, t), \quad \mathbf{u}^k(t) = \mathbf{u}(\mathbf{w}_1^k, t). \quad (22)$$

本文中将会用到如下 3 个假设:

(A1) 对于任意的 $r \in \mathbb{R}$, $|g(r)|$, $|g'(r)|$, $|g''(r)|$ 有界.

(A2) 在学习过程(16)中, $\|\mathbf{w}_0^k\|$, $\|\mathbf{V}_2^k\|$ ($k = 0, 1, 2, \dots$) (参照(1)、(9)~(10)式) 有界.

(A3) 存在一个有界闭集 $\Phi \subset R^{M(N+M+1)}$, 使得 $\{\mathbf{w}^k\} \subset \Phi$ 且 $\Phi_0 = \{\mathbf{w} \in \Phi : E_{\mathbf{w}}(\mathbf{w}) = 0\}$ 是有限点集.

注 2.1 激活函数 g 通常取为 Sigmoid 型函数, 其满足于假设(A1). 为了保证迭代过程的收敛性, 经常用到文献[18] 中的假设(A2). 假设(A3) 将用于获得强收敛结果.

3 主要结果

介绍一些在证明过程中要用到的符号:

$$\Delta s^k(t) = s^{k+1}(t) - s^k(t), \quad (23)$$

$$\Delta y^k(t) = y^{k+1}(t) - y^k(t), \quad (24)$$

$$\prod_{i=j}^k A_i = \begin{cases} A_k A_{k-1} \dots A_j, & j \leq k, \\ 1, & j > k. \end{cases} \quad (25)$$

如下 3 个引理类似于文献[14] 的对应结果, 因此省略其证明过程.

引理 3.1 对于迭代公式(15) 及零初始条件, 推得

$$P(t) = \sum_{j=0}^{t-1} \prod_{l=j+1}^t (\mathbf{G}'(s(l)) V_2) \mathbf{G}'(s(t-j)) (\mathbf{u}(t-j))^T \succ I_M. \quad (26)$$

引理 3.2 对于(23) 式中的 $\Delta s^k(t)$, 推得

$$\Delta s^k(t) = ((\mathbf{u}^k(t))^T \succ I_M + V_2^k P(\mathbf{w}_1^k, t)) \Delta \mathbf{w}_1^k + \delta^k(t),$$

这里

$$\begin{aligned} \delta^k(t) = & \sum_{j=1}^{t-1} \prod_{l=j+1}^{t-1} (\mathbf{V}_2^k \mathbf{G}'(s^k(l))) \Delta \mathbf{V}_2^k \mathbf{G}'(s^k(t-j)) \Delta s^k(t-j) + \\ & \frac{1}{2} \sum_{j=1}^{t-1} \prod_{l=t-j+1}^{t-1} (\mathbf{V}_2^k \mathbf{G}'(s^k(l))) V_2^{k+1} \mathbf{G}''(s^k(t-j)) (\Delta s^k(t-j))^{(2)}, \end{aligned}$$

向量 $s^k(t)$ 的每个分量落在向量 $s^k(t)$ 和向量 $s^{k+1}(t)$ 的相应分量之间.

引理 3.3 假设(A1) 和(A2) 成立, 那么

$$\begin{aligned} \|y^k(t)\| &\leq C_0, \\ \|\Delta s^k(t)\| &\leq C_1 \|\Delta \mathbf{w}_1^k\|, \\ \|\Delta y^k(t)\| &\leq C_2 \|\Delta \mathbf{w}_1^k\|. \end{aligned}$$

下一个引理因其证明基本上与文献[19] 中定理 14.1.5 相同^[20], 故省略.

引理 3.4 设 $F: \Phi \subset R^m \rightarrow R^m$ ($m \geq 1$) 在有界闭集 Φ 上连续, 集合 $\Phi_0 = \{\mathbf{w} \in \Phi: F(\mathbf{w}) = 0\}$ 是有限点集. 序列 $\{\mathbf{w}^k\} \subset \Phi$ 满足 $\lim_{k \rightarrow \infty} F(\mathbf{w}^k) = 0$ 和 $\lim_{k \rightarrow \infty} \|\mathbf{w}^{k+1} - \mathbf{w}^k\| = 0$. 那么, 存在 $\mathbf{w}^* \in \Phi_0$, 使得 $\lim_{k \rightarrow \infty} \mathbf{w}^k = \mathbf{w}^*$.

下面的定理是我们的主要结果.

定理 3.1 误差函数由(11) 式给出, 假设(A1)、(A2) 均成立, 对任意初始权值 \mathbf{w}^0 , 权值序列 $\{\mathbf{w}^k\}$ 由算法(16) 式生成, 学习率 η 满足下面(33) 式, 则有

- (a) $E(\mathbf{w}^{k+1}) \leq E(\mathbf{w}^k)$, $k = 0, 1, 2, \dots$;
- (b) 存在 $E^* \geq 0$ 使得 $\lim_{k \rightarrow \infty} E(\mathbf{w}^k) = E^*$;
- (c) $\lim_{k \rightarrow \infty} \|\Delta \mathbf{w}^k\| = 0$, $\lim_{k \rightarrow \infty} \|E(\mathbf{w}^k)\| = 0$.

而且, 如果假设(A3) 也成立, 则有强收敛性:

- (d) 存在 $\mathbf{w}^* \in \Phi_0$, 使得 $\lim_{k \rightarrow \infty} \mathbf{w}^k = \mathbf{w}^*$.

证明 由(22) ~ (24) 式, Taylor 展开公式, 引理 3.2 和学习规则(20) 式, 我们有

$$-\sum_{t=1}^Q (O(t) - z^k(t)) g'(\mathbf{w}_0^k \cdot \mathbf{y}^k(t)) \mathbf{w}_0^k \cdot \Delta \mathbf{y}^k(t) = -\frac{1}{\eta} \|\Delta \mathbf{w}_1^k\|^2 + \beta_t^k, \quad (27)$$

这里

$$\begin{aligned} \rho_1^k = & - \sum_{t=1}^Q (O(t) - z^k(t)) g'(\mathbf{w}_0^k \cdot \mathbf{y}^k(t)) (\mathbf{w}_0^k)^T \mathbf{G}'(\mathbf{s}^k(t)) \delta^k(t) - \\ & \frac{1}{2} \sum_{t=1}^Q (O(t) - z^k(t)) g'(\mathbf{w}_0^k \cdot \mathbf{y}^k(t)) (\mathbf{w}_0^k)^T \mathbf{G}''(\mathbf{t}^k(t)) (\Delta \mathbf{s}^k(t))^2, \end{aligned} \quad (28)$$

向量 $\mathbf{t}^k(t) \in R^M$, 其分量落在 $\mathbf{s}^{k+1}(t)$ 和 $\mathbf{s}^k(t)$ 的相应分量之间.

再次利用 Taylor 展开公式, 且注意到(10)~(11)、(19)、(27)~(28) 式, 我们有

$$\begin{aligned} E(\mathbf{w}^{k+1}) - E(\mathbf{w}^k) = & \\ & - \sum_{t=1}^Q (O(t) - z^k(t)) g'(\mathbf{w}_0^k \cdot \mathbf{y}^k(t)) \Delta \mathbf{w}_0^k \cdot \mathbf{y}^k(t) - \\ & \sum_{t=1}^Q (O(t) - z^k(t)) g'(\mathbf{w}_0^k \cdot \mathbf{y}^k(t)) \mathbf{w}_0^k \cdot \Delta \mathbf{y}^k(t) + \rho_2^k = \\ & - \frac{1}{\eta} \|\Delta \mathbf{w}^k\|^2 + \rho_1^k + \rho_2^k, \end{aligned} \quad (29)$$

这里

$$\begin{aligned} \rho_2^k = & - \frac{1}{2} \sum_{t=1}^Q (O(t) - z^k(t)) g''(\theta^k(t)) (\mathbf{w}_0^{k+1} \cdot \mathbf{y}^{k+1}(t) - \mathbf{w}_0^k \cdot \mathbf{y}^k(t))^2 - \\ & \sum_{t=1}^Q (O(t) - z^k(t)) g'(\mathbf{w}_0^k \cdot \mathbf{y}^k(t)) \Delta \mathbf{w}_0^k \cdot \Delta \mathbf{y}^k(t), \end{aligned} \quad (30)$$

$\theta^k(t)$ 是 1 个实数, 落在 $\mathbf{w}_0^k \cdot \mathbf{y}^k(t)$ 和 $\mathbf{w}_0^{k+1} \cdot \mathbf{y}^{k+1}(t)$ 之间.

由假设(A1)、(A2), 引理 3.2 和引理 3.3, 存在 1 个正常数 C^* 使得

$$|\rho_i^k| \leq C^* \|\Delta \mathbf{w}^k\|^2, \quad i = 1, 2. \quad (31)$$

结合(29)和(31)式导出

$$E(\mathbf{w}^{k+1}) - E(\mathbf{w}^k) \leq \left(\frac{1}{\eta} - 2C^* \right) \|\Delta \mathbf{w}^k\|^2. \quad (32)$$

因此, 结论(a)是正确的, 如果学习率足够小使得

$$0 < \eta < \frac{1}{2C^*}, \quad (33)$$

这里, C^* 是(31)式中的常数.

因为非负序列 $\{E(\mathbf{w}^k)\}$ 单调下降且有下界, 那么一定存在 1 个极限值 $E^* \geq 0$, 使得 $\lim_{k \rightarrow \infty} E(\mathbf{w}^k) = E^*$. 因此结论(b)证得.

注意到(16)、(18)和(32)式, 得到

$$\eta \sum_{k=0}^{\infty} E(\mathbf{w}^k) = \sum_{k=0}^{\infty} \|\Delta \mathbf{w}^k\|^2 < \infty, \quad (34)$$

因此

$$\lim_{k \rightarrow \infty} \|E(\mathbf{w}^k)\| = \lim_{k \rightarrow \infty} \|\Delta \mathbf{w}^k\| = 0. \quad (35)$$

最后, 证明强收敛性(d). 利用引理 3.4, 取 $F(\mathbf{w}) = E(\mathbf{w})$. 那么, 由结论(c), 假设(A3)和(35)式, 推得结论(d). 定理证明完毕.

4 数值例子

Elman 神经网络用于学习 2 阶延迟的 XOR 问题^[12]. 网络包含 2 个输入单元和 1 个偏置单元($N = 3$, 如图 1), 4 个隐层单元($M = 4$)和 1 个输出单元. 隐层和输出层神经元激活函数

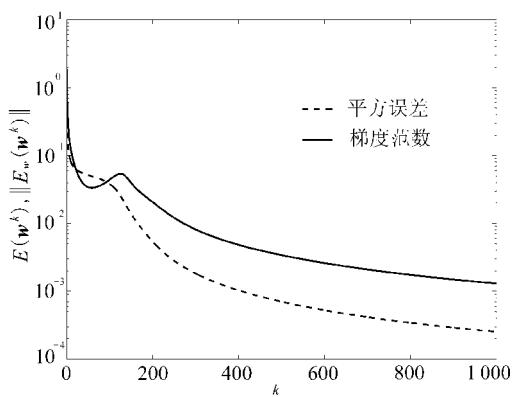


图 2 误差函数与梯度的范数变化曲线
7 时, 有相同的外部输入 $(x_1, x_2) = (0, 1)$. 由于递归性, 网络的响应是完全不同的.

表 1 训练后网络的性能

no	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
x_1	1	0	1	0	1	0	0	0	1	0	1	0	1	0	0	1
x_2	1	0	0	1	1	0	1	1	1	0	0	1	1	0	1	0
O	0	1	0	1	1	1	0	1	1	1	0	1	1	1	0	1
z	0.00	0.99	0.00	0.97	0.99	0.99	0.00	0.99	0.97	0.99	0.00	0.98	0.97	0.99	0.00	0.98

5 结 论

本文证明了有限样本集上 Elman 网络梯度学习法的一些确定性收敛结果. 作为比较, 已存在的收敛结果^[15]是概率性的渐进收敛性, 其假设训练样本的个数趋近于无穷. 这个方法使用常学习率. 收敛性分析的关键是证明学习过程中误差函数的单调性, 假设权值有界和学习率足够小(见(33)式). 我们建立了一些弱收敛和强收敛结果. 弱收敛结果意味着 $\lim_{k \rightarrow \infty} \|E_{\mathbf{w}}(\mathbf{w}^k)\| = 0$. 在 $E_{\mathbf{w}}(\mathbf{w})$ 包含有限零点条件下, 我们证明了强收敛结果 $\lim_{k \rightarrow \infty} \mathbf{w}^k = \mathbf{w}^*$. 这里, \mathbf{w}^* 是 $E(\mathbf{w})$ 的局部极小点. 通过数值试验演示了定理的合理性.

致谢 作者感谢编辑及审稿人富有洞察力的评论和有价值的建议, 提高了本文的质量和可读性.

[参 考 文 献]

- [1] Elman J L. Finding structure in time[J]. Cognitive Science, 1990, 14(2): 179– 211.
- [2] Tsoi A C, Back A D. Locally recurrent globally feedforward networks: a critical review of architectures[J]. IEEE Transactions on Neural Networks, 1994, 5(2): 229– 239.
- [3] WANG De-liang, LIU Xiao-mei, AHALT S C. On temporal generalization of simple recurrent networks[J]. Neural Networks, 1996, 9(7): 1099– 1118.
- [4] Kremer S C. On the computational power of Elman- style recurrent net works[J]. IEEE Transactions on Neural Networks, 1995, 6(4): 1000– 1004.
- [5] Pham D T, Liu X. Training of elman networks and dynamic system modeling[J]. International Journal of Systems Science, 1996, 27(2): 221– 226.
- [6] Cartling B. On the implicit acquisition of a context- free grammar by a simple recurrent neural network[J]. Neurocomputing, 2008, 71(7/9): 1527– 1537.

均取为 $g(x) = (e^x - e^{-x})/(e^x + e^{-x})$. 学习率 η 设定为 0.2, 在 $[-1, 1]$ 闭区间内随机选取初始权值 \mathbf{w}^0 , 当迭代步数达到 1000 或者误差函数小于 $E < 0.0001$, 则停止训练.

试验结果如图 2 和表 1 所示. 从图 2, 我们看到随着迭代步数的增加, 误差单调递减, 对应梯度趋近于 0, 与收敛性结果吻合. 表 1 给出了网络训练停止后, 实际输出 $z(t)$ 与目标输出 $O(t)$ 的对比. 表 1 中行标签 no, x_i , O 和 z 分别代表样本序号, 外部输入向量的第 i 个分量, 目标输出和网络实际输出. 我们观察到, 例如, 当 no = 4 和 no = 7 时, 有相同的外部输入 $(x_1, x_2) = (0, 1)$. 由于递归性, 网络的响应是完全不同的.

- [7] LI Xiang, CHEN Zeng- qiang, YUAN Zhu- zhi, et al. Generating chaos by an Elman network[J]. IEEE Transactions on Circuits and Systems – I , 2001, **48**(9): 1126– 1131.
- [8] Ekici S, Yildirim S, Poyraz M. A transmission line fault locator based on Elman recurrent networks [J]. Applied Soft Com puting, DOI: 10.1016/J.asoc.2008.04.011.
- [9] Neto L B, Coelho P H G, Soares de Mello J C C B, et al . Flow estimation using an Elman networks [A] . In: Wunsch D, Ed Proceedings of 2004 IEEE International Joint Conference on Neural Networks [C] . Budapest, Hungary: IEEE Press, 2004, 831– 836.
- [10] Demuth H B, Beale M H, Hagan M T. Neural Network Toolbox User’ Sguide [M]. atick, MA: The Mathworks Inc, 2007.
- [11] Jes s O D, Hagan M T. Back propagation algorithms for a broad class of dynamic networks[J]. IEEE Transaction s on Neural Networks , 2007, **18**(1): 14– 27.
- [12] Williams R J, Zisper D. A learning algorithm for continually runningfully recurrent neural networks [J] . Neural Computation , 1989, **1**(2): 270– 280.
- [13] Ku C C, Lee K Y. Diagonal recurrent neural networks for dynamic systems control[J]. IEEE Trans action on Neural Networks , 1995, **6**(1): 144– 156.
- [14] XU Dong- po, LI Zheng- xue, WU Wei, et al . Convergence of gradient descent algorithm for diagonal recurrent neural networks[A] . In: CUI Guang- zhao, Ed. International Conference on Bio – Inspired Computing : Theories and Application s [C] . Zhengzhou, China: IEEE Press, 2007.
- [15] Kuan C M, Hornik K, White H. A convergence results for learning inrecurrent neural networks[J]. Neural Computation , 1994, **6**(3): 420– 440.
- [16] WU Wei, FNG Guo- rui, LI Zheng- xue, et al . Convergence of an online gradient method for BP neural networks[J] . IEEE Transactionson Neural Networks , 2005, **16**(3): 533– 540.
- [17] WU Wei, SHAO Hong- mei, QU Di. Strong convergence for gradient methods for BP networks training[A] . In: ZHAO Ming- sheng, SHI Zhong- zhi, Eds. Proceedings of 2005 International Conference on Neural Networks and Brains [C] . Beijing, China: IEEE Press, 2005, 332– 334.
- [18] Gori M, Maggini M. Optimal convergence of on- line back propagation[J]. IEEE Transaction on Neural Networks , 1996, **7**(1): 251– 254.
- [19] Ortega J, Rheinboldt W. Iterative Solution of Nonlinear Equations in Several Variables [M] . New York Academic Press, 1970.
- [20] 袁亚湘, 孙文瑜. 最优化理论与方法[M]. 北京: 科学出版社, 2001, 149.

Convergence of Gradient Method for Elman Networks

WU Wei, XU Dong- po, LI Zheng- xue

(Department of Applied Mathematics, Dalian University of Technology,
Dalian, Liaoning 116024, P. R. China)

Abstract: The gradient method for training Elman networks with finite training sample set is considered. The monotonicity of the error function in the iteration is shown. A weak and a strong convergence results are proved, indicating that the gradient of the error function goes to zero and the weight sequence goes to a fixed point, respectively. A numerical example is given to support the theoretical findings.

Key words: Elman network; gradient learning algorithm, convergence; monotonicity