

递归联想记忆及在故障诊断中的应用

谭民 疏松桂

(中国科学院自动化所)

摘 要

本文介绍了神经网络递归联想记忆模型,并应用于控制系统的故障诊断中。

关键词: 递归联想记忆,广义逆,神经网络,故障诊断。

一、引 言

联想记忆是神经网络模拟人脑的一种重要的记忆方式,它具有容错性及抗干扰性^[1]。

联想记忆的过程分为两个阶段: 第一阶段是样本的存贮。首先把实际问题进行抽象、概括、总结出样本数据向量,设 $\mathbf{x}^{(p)} = (x_1^{(p)}, x_2^{(p)}, \dots, x_n^{(p)})^T$ 为样本输入向量, $\mathbf{y}^{(p)} = (y_1^{(p)}, y_2^{(p)}, \dots, y_m^{(p)})^T$ 为样本输出向量, $p = 1, 2, \dots, l$ 且 $\mathbf{x}^{(p)} \in \mathbb{R}^n$, $\mathbf{y}^{(p)} \in \mathbb{R}^m$, 把 $(\mathbf{x}^{(p)}, \mathbf{y}^{(p)})$ 称为样本向量对; 然后把 $(\mathbf{x}^{(p)}, \mathbf{y}^{(p)})$ 以一定的方式存贮到联想矩阵 M 中^[2]。第二阶段是联想回忆。当输入一信息 $\mathbf{x}^{(p)}$ 时, 经过联想矩阵 M , 得到 $\mathbf{y}^{(p)}$, 即 $\mathbf{y}^{(p)} = M\mathbf{x}^{(p)}$ 。

递归联想记忆模型是在已经存贮 $K-1$ 对样本向量之后, 对增加的新样本采用递归方式, 获得 K 对样本向量的联想记忆矩阵。

把这种方法应用于控制系统的故障诊断, $\mathbf{x}^{(p)}$ 存入故障的信息, $\mathbf{y}^{(p)}$ 存入解决故障的办法, 通过递归得到联想记忆阵 M 。当一个故障信息输入时, 即可进行诊断。

二、递归联想记忆模型

1. 样本的存贮方式

对样本数据对 $\mathbf{x}^{(p)} \rightarrow \mathbf{y}^{(p)}$, 经过联想矩阵 M 的作用, 得到 $\mathbf{y}^{(p)} = M\mathbf{x}^{(p)}$, $p = 1, 2, \dots, l$, 对所有的样本可得

$$Y = MX, \quad (1)$$

其中 X 是 $n \times l$ 阵, Y 是 $m \times l$ 阵, M 是 $m \times n$ 阵。

若 X 是 $n \times n$ 的满秩阵, X^{-1} 存在, 那么可以得到 $M = YX^{-1}$ 。但是实际问题中 X 经常是退化的或者不是方阵, X^{-1} 一般是不存在的。为此, 引入广义逆的概念, 设 A 是秩

为 r 的一个 $m \times n$ 阵, A 的一个广义逆是一个 $n \times m$ 阵 G , 使得 $X = GY$ 是方程 $AX = Y$ 的一个解, 令 $G = A^+$, A^+ 表示 A 的广义逆.

广义逆有一个重要的性质. 设 A 是 $m \times n$ 的矩阵, B 是 $m \times r$ 阵, C 是 $r \times n$ 阵, 若 $A = BC$, 那么广义逆

$$A^+ = C^T(CC^T)^{-1} \cdot (B^TB)^{-1}B^T,$$

其中 T 表示转置. 特别地当 A 为列满秩时,

$$A^+ = (A^TA)^{-1}A^T.$$

对于(1)式, 方程的解为

$$M = YX^+. \quad (2)$$

可以证明在最小均方差 (MSE) 准则的条件下, 式(2)中 M 是式(1)的最优解, 即当 $\mathbf{x}^{(p)}$ 输入时, $\hat{\mathbf{y}}^{(p)} = M\mathbf{x}^{(p)}$ 在 MSE 准则下最接近 $\mathbf{y}^{(p)}$ [3].

2. 递归联想记忆模型

设 $Y_k = (\mathbf{y}^{(1)}, \mathbf{y}^{(2)}, \dots, \mathbf{y}^{(k)})$ 是 $m \times k$ 阵, $\mathbf{y}^{(i)}$ 是列向量, 表示第 i 个输出样本, $X_k = (\mathbf{x}^{(1)}, \mathbf{x}^{(2)}, \dots, \mathbf{x}^{(k)})$ 是 $n \times k$ 阵. 假若对于已经存好 $k-1$ 个样本向量, 得到了 $M_{k-1} = Y_{k-1}X_{k-1}^+$, 当增加一个新样本时, 可以重新计算 $M_k = Y_kX_k^+$, 但这样做是很复杂的, 而且大量的重复性工作, 所以采用递归方式从 M_{k-1} 得到 M_k .

对于 $X_k = (X_{k-1} | \mathbf{x}^{(k)})$, 它的广义逆的形式一定为[4]

$$X_k^+ = \begin{pmatrix} Z_k & (k-1) \times n \\ \mathbf{b}_k & 1 \times n \end{pmatrix}.$$

计算 $X_kX_k^+$ 并利用广义逆的性质 $X_{k-1}^+X_kX_k^+ = X_{k-1}^+$, 可以得到 $Z_k = X_{k-1}^+ - X_{k-1}^+\mathbf{x}^{(k)}\mathbf{b}_k$, 所以

$$X_k^+ = \begin{pmatrix} X_{k-1}^+ - X_{k-1}^+\mathbf{x}^{(k)}\mathbf{b}_k \\ \mathbf{b}_k \end{pmatrix}. \quad (3)$$

那么

$$\begin{aligned} M_k &= Y_kX_k^+ = (Y_{k-1} | \mathbf{y}^{(k)}) \begin{pmatrix} X_{k-1}^+ - X_{k-1}^+\mathbf{x}^{(k)}\mathbf{b}_k \\ \mathbf{b}_k \end{pmatrix} \\ &= Y_{k-1}X_{k-1}^+ - Y_{k-1}X_{k-1}^+\mathbf{x}^{(k)}\mathbf{b}_k + \mathbf{y}^{(k)}\mathbf{b}_k \\ &= M_{k-1} - M_{k-1}\mathbf{x}^{(k)}\mathbf{b}_k + \mathbf{y}^{(k)}\mathbf{b}_k. \end{aligned} \quad (4)$$

其中

$$\mathbf{b}_k = \begin{cases} (\mathbf{c}_k^T\mathbf{c}_k)^{-1}\mathbf{c}_k^T, & \text{若 } \mathbf{c}_k \neq 0; \\ (1 + \mathbf{d}_k^T\mathbf{d}_k)^{-1}\mathbf{d}_k^TX_{k-1}^+, & \text{若 } \mathbf{c}_k = 0. \end{cases}$$

把它合并为

$$\mathbf{b}_k = \mathbf{c}_k^+ + (1 - \mathbf{c}_k^+\mathbf{c}_k)(1 + \mathbf{d}_k^T\mathbf{d}_k)^{-1}\mathbf{d}_k^TX_{k-1}^+. \quad (5)$$

其中

$$\mathbf{c}_k = \mathbf{x}^{(k)} - X_{k-1}\mathbf{d}_k, \quad (6)$$

$$\mathbf{d}_k = X_{k-1}^+\mathbf{x}^{(k)}. \quad (7)$$

由式(3)一式(7)就构成了联想矩阵 $M_k (k = 2, 3, \dots, l)$ 的递归算式. 对于初始值, 在存贮第一对样本向量 $(\mathbf{x}^{(1)}, \mathbf{y}^{(1)})$ 时,

$$X_1^+ = (\mathbf{x}^{(1)T} \mathbf{x}^{(1)})^{-1} \mathbf{x}^{(1)T},$$

$$M_1 = \mathbf{y}^{(1)} (\mathbf{x}^{(1)T} \mathbf{x}^{(1)})^{-1} \mathbf{x}^{(1)T}.$$

由此就可以进行递归联想存贮,至全部样本向量存完为止,得到联想矩阵 M_1 .

3. 数值例子

设有两组样本 $\mathbf{x}^{(1)} = (1, 1, 1, 0)^T$ 表示一种故障现象, $\mathbf{y}^{(1)} = (1, 0, 0, 0)^T$ 表示解决 $\mathbf{x}^{(1)}$ 的策略, $\mathbf{x}^{(1)} \rightarrow \mathbf{y}^{(1)}$; $\mathbf{x}^{(2)} = (0, 0, 1, 1)^T$ 表示另一种故障, $\mathbf{y}^{(2)} = (0, 1, 0, 0)^T$ 表示解决 $\mathbf{x}^{(2)}$ 的办法, $\mathbf{x}^{(2)} \rightarrow \mathbf{y}^{(2)}$. 用递归算法把这两对样本向量存贮起来.

第一对样本 $(\mathbf{x}^{(1)}, \mathbf{y}^{(1)})$

$$\mathbf{x}_1^+ = (\mathbf{x}^{(1)T} \mathbf{x}^{(1)})^{-1} \mathbf{x}^{(1)T} = \left(\frac{1}{3}, \frac{1}{3}, \frac{1}{3}, 0 \right);$$

$$M_1 = \mathbf{y}_1 \mathbf{x}_1^+ = \begin{pmatrix} \frac{1}{3} & \frac{1}{3} & \frac{1}{3} & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{pmatrix}.$$

增加新样本 $(\mathbf{x}^{(2)}, \mathbf{y}^{(2)})$

$$d_2 = \mathbf{x}_1^+ \mathbf{x}^{(2)} = \frac{1}{3} (1, 1, 1, 0)(0, 0, 1, 1)^T = \frac{1}{3};$$

$$\mathbf{c}_2 = \mathbf{x}^{(2)} - \mathbf{x}_1 d_2 = \left(-\frac{1}{3}, -\frac{1}{3}, \frac{2}{3}, 1 \right)^T;$$

$$\mathbf{b}_2 = \mathbf{c}_2^+ = (\mathbf{c}_2^T \mathbf{c}_2)^{-1} \mathbf{c}_2^T = \left(-\frac{1}{5}, -\frac{1}{5}, \frac{2}{5}, \frac{3}{5} \right);$$

$$X_2^+ = \left(\frac{\mathbf{x}_1^+ - d_2 \mathbf{b}_2}{\mathbf{b}_2} \right) = \begin{pmatrix} \frac{2}{5} & \frac{2}{5} & \frac{1}{5} & -\frac{1}{5} \\ -\frac{1}{5} & -\frac{1}{5} & \frac{2}{5} & \frac{3}{5} \end{pmatrix};$$

$$M_2 = \begin{pmatrix} \frac{2}{5} & \frac{2}{5} & \frac{1}{5} & -\frac{1}{5} \\ -\frac{1}{5} & -\frac{1}{5} & \frac{2}{5} & \frac{3}{5} \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{pmatrix}.$$

这样得到了递归联想记忆矩阵.

当原存贮的样本 $\mathbf{x}^{(1)} = (1, 1, 1, 0)^T$ 输入时,

$$\hat{\mathbf{y}}^{(1)} = M_2 \mathbf{x}^{(1)} = (1, 0, 0, 0)^T = \mathbf{y}^{(1)}.$$

当原存贮的样本 $\mathbf{x}^{(2)} = (0, 0, 1, 1)^T$ 输入时,

$$\hat{\mathbf{y}}^{(2)} = M_2 \mathbf{x}^{(2)} = (0, 1, 0, 0)^T = \mathbf{y}^{(2)}.$$

假若一个新的信息 $\mathbf{x} = (1, 0, 1, 0)^T$ (它可以看作是样本 $\mathbf{x}^{(1)}$ 第二项信息丢失后

的向量)作为输入,

$$\begin{aligned}\hat{\mathbf{y}} &= M_2 \mathbf{x} = \left(\frac{3}{5}, \frac{1}{5}, 0, 0 \right)^T \\ &= \frac{3}{5} \mathbf{y}^{(1)} + \frac{1}{5} \mathbf{y}^{(2)}.\end{aligned}$$

$\hat{\mathbf{y}}$ 是输出样本 $\mathbf{y}^{(1)}$ 和 $\mathbf{y}^{(2)}$ 的线性组合,但权重倾向于 $\mathbf{y}^{(1)}$ 一边.

三、递归联想记忆在故障诊断中的应用

上面的简单数值例子解释了递归联想记忆算法的过程及应用.应当说明在实际控制系统的故障诊断中会遇到很多复杂的问题,对具体系统的故障诊断还要作具体分析.

把这种方法应用到“锅炉给水装置”的控制系统故障诊断上.对这套装置,总结出 20 个故障模式,针对每个故障模式找到相应的解决办法,然后进行数据处理,得到样本数据对 $(\mathbf{x}^{(p)}, \mathbf{y}^{(p)})$, ($p = 1, 2 \cdots 20$),把这些样本经过递归运算,存贮到联想记忆矩阵 M 中,在 IBM-PC/XT 上进行了仿真,结果表明,这种方法用于控制系统故障诊断,效果较好.

四、结 束 语

联想记忆是神经网络的重要特征之一.本文给出了递归联想记忆模型,其中的 M 是在最小均方差准则的条件下得到的,其精度较高,另外,当一个新样本向量增加时,这个模型是在原有的基础上,对样本向量进行递归运算,因而更合乎人的记忆方式.

参 考 文 献

- [1] Kohonen, T., *Self-Organization and Association Memory*, Springer-Verlag, Berlin, 1984.
- [2] Kohonen, T., *Correlation Matrix Memories*, *IEEE Trans. Computer*, April 1972.
- [3] Kohonen T. and Ruohonen, M., *Representation of Associated Data by Matrix Operators*, *IEEE Trans. Computer*, July 1973.
- [4] Greville, T. *Some Application of the Pseudoinverse of A Matrix*, *SIAM Rev.*, 2(1960), 1.

A MODEL OF RECURSIVE ASSOCIATIVE MEMORY AND ITS APPLICATION TO FAULT DIAGNOSIS

TAN MIN SHU SONGGUI

(Institute of Automation, Academia Sinica)

ABSTRACT

In this paper, a model of recursive associative memory is introduced and its application to fault diagnosis is presented.

Key words: Recursive associative memory; pseudoinverse; neural network; fault diagnosis.