

研究简报

# 一种实现故障定位技术的研究<sup>1)</sup>

郭其一

卢桂章 黄亚楼

(上海铁道大学电气工程系 上海 200331)

(南开大学机器人与信息自动化研究所 天津 300071)

**关键词** 故障诊断, 故障定位.

## FAULT LOCATING AND COMPONENT DIAGNOSIS TECHNIQUE BASED ON NEURAL NETWORKS

GUO Qiyi

LU Guizhang HUANG Yalou

(Shanghai Tiedao University, Shanghai 200331)

(Nankai University, Tianjin 300071)

**Key words** Fault diagnosis, fault location.

### 1 问题的提出

故障诊断的主要目的是实现故障预防或故障发生时的定位、机理分析与故障保护和隔离等,实现故障定位是故障诊断的关键内容之一.由于神经网络的学习特性和对非线性对象的描述特性,因而被广泛应用在故障诊断这样的智能领域.然而从以往文献看<sup>[1,2]</sup>,主要是将对象作为黑箱来研究.若网络结构简单则不足以描述对象,网络结构复杂则训练速度太慢,不适合在线动态诊断.神经网络诊断系统是一个神经网络专家系统,将诊断推理转变为网络的静态计算过程,这是一种基于浅知识的诊断方法<sup>[3]</sup>.

上述方法在实现故障定位时相当困难,已知的定位方法往往要求对象完全已知,但是由于对象的复杂性,很难完全确定对象的准确数学模型.本文则提出一种以系统的可知部分模型为基础,结合状态补偿构造神经网络作为状态估计的观测器,建立一个能描述系统物理结构特征的诊断模型,实现灰箱系统的故障定位与故障隔离.

### 2 基于神经网络的部件诊断模型

设系统的结构模型为

$$\begin{cases} \dot{x}(t) = f(x(t), u(t)), \\ y(t) = h(x(t), u(t)). \end{cases} \quad (1)$$

$n \times 1$  状态变量  $x(t) \in R^n$ ,  $m \times 1$  输出  $y(t) \in R^m$ ,  $r \times 1$  输入  $u(t) \in R^r$ . 将式(1)在平衡点  $t_0$  以时间步长  $T$  线性化并且离散化后得:

$$\begin{cases} x(k+1) = \sum_{i=0}^{l_1} A_i x(k-i) + \sum_{i=0}^{l_2} B_i u(k-i), \\ y(k+1) = Cx(k+1) + Du(k+1), \end{cases} \quad (2)$$

$A_i$  是  $n \times n$  矩阵 ( $i=1, 2, \dots, l_1$ ),  $B_i$  是  $n \times r$  矩阵 ( $i=1, 2, \dots, l_2$ ),  $C$  是  $m \times n$  矩阵,  $D$  是  $m \times r$  矩阵.

式(2)是在特定前提下获得的, 不完全代表系统(1), 仅表示特定条件下的可知部分, 不可知部分主要包含时延、控制策略、非线性因素等. 因此式(2)具有非完全确定性. 令:

$$g(k) = x(k), \quad (3)$$

其中  $g(k) = (g_1(k), g_2(k), \dots, g_n(k))^T$ . 若系统满足能观测性条件, 则由式(2)可求出式(4)作为系统(1)的状态估计构造图1的  $\Psi_1$  部分:

$$\Psi_1: g(k) = \sum_{l=0}^{k_1} \omega_l y(k-l) + \sum_{l=k_1}^{k_1+k_2} \omega_{k_1+l} u(k+k_1-l). \quad (4)$$

但(4)并不完全等于状态估计  $\hat{x}(k)$ , 构造串联网路作为未知部分  $\Psi_2$  对状态估计的补偿输出

$$\Psi_2: f(k) = (f_1(k), f_2(k), \dots, f_n(k))^T = V(k)g(k) \quad (5)$$

其中  $f(k) = x(k)$ ,  $V(k)$  是  $n \times n$  权系数矩阵. 因此(4)、(5)两式共同构成了一个基于对象数学模型的神经网络, 同时又是一个状态观测器, 实现对系统状态的估计(图1所示).




图1 基于模型和神经网络的诊断系统结构原理

已知量  $\omega_{ij}$  由系统已知知识获得. 变量  $v_{ij}(k)$  是  $\Delta y(k)$  控制下学习获得, 它的设计根据是系统的结构特性, 部件激励特性必须在权学习中强制性体现出来, 构成一个深知识诊断模型达到部件诊断的目的. 该网络结构仅需学习网络权系数  $v_{ij}(k)$ , 故学习时间短, 可以在线实现; 每一个神经单元都有一定的物理背景, 神经元间的连接表达相应的状态关系, 因此该神经网络充分描述系统的结构特征. 通过残差分析实现故障检测, 系统故障时依据网络中的物理关系, 反演推理可以将故障隔离到部件级, 实现故障定位和部件诊断, 发现故障机理.

### 3 传动控制系统的诊断实践

一个实际传动控制系统的数学模型

$$u_d = C_e \phi n + L \frac{di_d}{dt} + R_d i_d, \quad (6)$$

$$C_M \phi i_d = M_L + J \frac{dn}{dt} + Bn, \quad (7)$$

其中  $R_d = 0.061 \Omega$  为电枢等价电阻,  $L = 16.5 \text{mH}$  为等价电感,  $C_e \phi$  为电机的结构常数和励磁磁通,  $C_M \phi = 9.55 C_e \phi$  是电机转矩常数与磁通的乘积,  $B = 7.5$  是风阻系数,  $J$  为折算到电机上的等价转动惯量,  $M_L$  折算到电机上的阻力转矩. 系统测量是输入  $u_{d_0}(k)$ 、电机电枢电压  $u_d(k)$ 、电枢电流  $i_d(k)$  和速度  $n(k)$ , 经处理后按百分数表达的值, 100% 分别代表电流 2 000A、电压 2 000V、速度 200km/h. 令:

$$u(k) = u_d(k), x_1(k) = i_d(k), x_2(k) = n(k), y = [x_1, x_2]^T, f_1 = \hat{x}_1, f_2 = \hat{x}_2.$$

将系统数学模型(6),(7)式离散化, 则可求图1中  $\Psi_1$  部分的网络联接权  $\omega_{ij}$ . 其中:

$$\omega_{11} = 1 + \frac{TR_d}{L}, \omega_{21} = \frac{TC_e \phi}{L}, \omega_{31} = -\frac{T}{L}, \omega_{12} = -\frac{C_M \phi T}{J}, \omega_{22} = 1 + \frac{TB}{J}, \omega_{32} = 0.$$

由于要求未知部分的连接必须体现部件的物理特性和激励特性, 令:

$$v_{ij}(k) = \zeta_{ij}(k) \Delta_i, \quad i = 1, 2, \quad j = 1, 2. \quad (8)$$

而 
$$\Delta_1 = \frac{R_d + \Delta R}{L + \Delta L} - \frac{R_d}{L}, \quad \Delta_2 = \frac{1}{R_d + \Delta R} + \frac{1}{L + \Delta L} - \frac{1}{R} - \frac{1}{L}$$

一般取  $\Delta R = \pm 1\% R_d \sim \pm 5\% R_d$ ,  $\Delta L = \pm 1\% L \sim \pm 5\% L$ .  $v_{ij}(k)$  的学习即变为  $\zeta_{ij}(k)$  的学习. 通过这样一个过程, 将静态范畴的神经网络转变为一个动态过程. 学习的准则为:

$$\min \left\{ \frac{1}{2} |\Delta y(k)|^2 \right\} = \min \left\{ \frac{1}{2} |y(k) - \hat{y}(k)|^2 \right\}. \quad (9)$$

状态估计误差  $e_1(k) = e_{u_0}(k) = 0$ ,  $e_2(k) = u(k) - \hat{u}(k)$ ,  $e_3(k) = x_1(k) - f_1(k)$ ,  $e_4(k) = x_2(k) - f_2(k)$ . 残差

$$AVG(k) = \frac{1}{2} \{ |e_1(k)|^2 + |e_2(k)|^2 + |e_3(k)|^2 + |e_4(k)|^2 \}. \quad (10)$$

诊断过程的实现:a)建立诊断模型;b)给出初始参数  $v_{ij}(0) = K_0$ ,  $K_0$  是系统放大系数, 可以通过试验预先获得;c)由采样信息, 在(9)式控制下在线学习网络联接权  $v_{ij}(k)$ ; d)由式(9),(10)计算跟踪误差和残差; e)根据已知的  $R_d, L$ , 由式(8)用辨识算法在线求  $\zeta_{ij}$  出值; f)根据残差评估准则分析  $AVG(k)$ ; 状态正常则重复步骤 c), 否则步骤 g); g)若系统异常, 辨识出故障时的  $R', L'$ ; h)判决故障部位, 给出故障报警; i)重复步骤 c), 进入下一轮诊断过程.

图2是基于上述诊断模型的状态估计跟踪特性仿真结果, 单位阶跃输入, 已知非线性部分经分段处理, 联接权的学习采用最小二乘法, 四个测量周期递推, 跟踪达到误差控制要求. 图3是式(6),(7)系统一次实际故障记录, 现象是电枢电流过流导致保护动作, 经本文给出的算法在线计算后得到的结论, 是回路等价电阻由  $0.061 \Omega$  下降至  $0.021 \Omega$ , 而回路等价电感几乎不变, 结论为系统发生接地现象而致瞬间过流, 这与实际检修结论相吻合.




图2 以速度为输出的跟踪特性仿真结果




图3 系统(6),(7)的一次实际故障记录

## 4 结束语

本文所给出的被诊断对象,  $M_L, n$  变化范围达10倍之多, 且存在变参数和严重非线性, 故障因素较多, 用系统设置的传感器仅仅实现故障检测并非难事. 但本文提出基于系统已知部分模型, 结合串联网络作为对结构参数变化和非线性的补偿, 实现故障定位与隔离, 方法简单, 计算量小, 易于在线诊断实现.

## 参 考 文 献

- 1 刘建华, 张伟江, 徐晓鸣. 基于 PNN 滤波的非线性系统故障检测方法. 控制理论与应用, 1997, 14(2): 171~177
- 2 潭民, 疏松桂. 基于神经网络的控制系统故障诊断. 控制与决策, 1990, 5(1): 58~60
- 3 杨叔子等. 基于知识的诊断推理. 北京: 清华大学出版社, 1993. 76~119

**郭其一** 1961年出生. 1984年毕业于南开大学自动控制理论专业. 现为上海铁道大学电气工程系副教授. 主要从事控制、检测及故障诊断方面的教学与研究工作.