

自适应模糊系统在大坝安全监测故障诊断中的应用

聂学军¹,顾冲时¹,严良平¹,罗龙洪²

(1. 河海大学水利水电工程学院,江苏 南京 210098; 2. 江苏省水利工程规划办公室,江苏 南京 210029)

摘要 为提高大坝安全自动化监测的稳定性与可靠性,提出一种基于模拟退火的自适应模糊系统(AFS: Adaptive Fuzzy System)的学习算法,并根据此算法建立了大坝安全监测非线性监测器模型,同时利用该模型构造了大坝安全自动化监测故障自诊断系统.实例表明,该系统既具有模拟退火算法(SAA: Simulated Annealing Algorithm)的全局优化搜索能力,又充分发挥了 AFS 的非线性逼近能力,并能够较好地实现故障的在线诊断和实时隔离.

关键词 自适应模糊系统 模拟退火 大坝 故障诊断

中图分类号 TV698.2

文献标识码 A

文章编号 1000-1980(2005)04-0395-04

我国大坝安全自动化监测研究始于 20 世纪 70 年代末期,80 年代有了长足发展.90 年代以后,随着科学技术的迅猛发展,大坝安全自动化监测有了质的飞跃.然而,在大坝安全自动化监测大力推广运用的同时,也会对监测自动化系统的工作稳定性和可靠性提出新的要求.尤其在工程实际中自动化监测系统存在的性能不够稳定和测值漂移等问题,影响了监测资料的稳定性和可靠性.为了能及时反馈和处理大坝安全自动化监测的工作性态,保证监测系统能正常工作,笔者将模拟退火算法引入自适应模糊系统(AFS),并根据 AFS 建立了自动化监测的监测器模型,同时利用该模型构造了大坝安全自动化监测故障自诊断系统.

1 模拟退火 AFS 的学习算法

1.1 AFS 的学习算法

模糊系统有较强的利用模糊集表示语言和结构化知识以及利用模糊逻辑完成近似推理的能力,其知识的获取常常依赖于领域的专家.神经网络则擅长用计算方法表示非线性映射,它通过样本学习获得知识.模糊系统与神经网络都具有函数逼近作用,两者的有机结合,即可以构成一种新的信息处理系统——AFS.本文研究的 AFS^[1,2],是一种模糊系统与神经网络的等价性结合,它由输入变量模糊化、模糊规则库、模糊推理和去模糊 4 部分组成.系统结构如图 1 所示.其工作原理为:输入信息 $X = (x_1, x_2, \dots, x_l)^T$,通过模糊化处理,产生模糊集 $A = (A_1, A_2, \dots, A_l)^T$,同时激发 m 个模糊推理规则 $FR_k (k = 1, 2, \dots, m)$,产生 m 个模糊子集 $B'_k (k = 1, 2, \dots, m)$, B'_k 再经过加权组合,得到输出的模糊子集 $B = \sum_{k=1}^m \omega'_k B'_k$,其中 $\omega'_k = \begin{cases} \omega_k & (\omega_k \geq \theta) \\ 0 & (\omega_k < \theta) \end{cases}$ 为动态

自适应门限,满足 $0 < \theta < 1$.由此可见,当某个 $\omega_k < \theta$ 时,则令 $\omega'_k = 0$,关闭第 k 路信号到累加器 Σ 的通道,防止不相关的信号干扰输出结果,从而可进一步提高推理精度.

1.2 基于模拟退火的动态聚类方法

把上述 AFS 的学习过程分解为聚类 and 线性优化,其中以模拟退火作为聚类的工具.通过实测数据的聚类分析确定模糊推理的规则数(FR_k)和隶属度函数.因为模拟退火算法既能向目标函数减小的方向迭代,又




图 1 AFS 的结构示意图

Fig.1 Sketch of AFS structure

能以一定的概率接受目标升高的情况,所以理论上能以概率 1 收敛于全局最优解.将模拟退火算法引入动态聚类中,既能较好地消除常规聚类方法对初始聚类中心的敏感性,又能避免常规聚类过程易于较早地陷入局部极小点的弊端,从而可使所产生的模糊规则能够涵盖整个样本的特征空间^[3,4].设计的基于模拟退火算法的动态聚类方法的求解步骤如下:

步骤 1 :令 $k = 0$,计算输入样本点之间的距离,并记

$$\begin{cases} \Delta d_{\max} = \max d(X_i - X_j) & \Delta d_{\min} = \min d(X_i - X_j) \\ d(X_i - X_j) = \|X_i - X_j\|^2 & (i, j = 1, 2, \dots, N) \\ t_0 = 10\Delta d_{\max} & t_{\min} = 0.1\Delta d_{\min} \end{cases} \quad (1)$$

式中: N ——样本数; $\Delta d_{\max}, \Delta d_{\min}$ ——样本点之间的最大、最小距离.

步骤 2 :以前 c 个样本为初始聚类中心,对其他 $N - c$ 个样本依次按下列公式计算其所属的类别.

$$\begin{cases} l = \arg \{\min d_i\} \\ p_i = \exp[(d_l - d_i)/t_k] / \{1 + \exp[(d_l - d_i)/t_k]\} & \bar{p}_i = p_i / \sum_{i=1}^c p_i \\ h = \min_i \sum_{j=0}^i \bar{p}_j > \text{random}(0, 1) \end{cases} \quad (2)$$

式中 d_i 为样本到第 i 个中心的距离.

步骤 3 :计算新的聚类中心 $C_i(k)$ 和累积类内距离平方和 $J(k)$.

$$C_i(k) = \frac{1}{m_i} \sum_{j=1}^{m_i} X_j^{(i)} \quad (i = 1, 2, \dots, c) \quad (3)$$

$$J(k) = \sum_{i=1}^c \sum_{j=1}^{m_i} \|X_j^{(i)} - C_i(k)\|^2 \quad (4)$$

式中: m_i ——属于第 i 类的样本个数; $X_j^{(i)}$ ——属于第 i 类的样本 X_j .

步骤 4 :令 $k = k + 1, t_k = \alpha t_{k-1}$.

步骤 5 :依次计算每一个样本的 d_i, d_l .

$$\begin{cases} d_i = \frac{m_i}{m_i - 1} \|X_j^{(i)} - C_i(k)\|^2 \\ d_l = \frac{m_l}{m_l + 1} \|X_j^{(i)} - C_l(k)\|^2 \end{cases} \quad (l = 1, 2, \dots, c; l \neq i) \quad (5)$$

式中 i 为样本 j 原来所聚的类别.由式(2)决定样本所属类别 h ,如与原所聚类别不同,则分别对聚类中心和目标函数进行修正,即

$$\begin{cases} C_i(k) = C_i(k-1) + \frac{1}{m_i - 1} [C_i(k-1) - X_j^{(i)}] \\ C_k(k) = C_k(k-1) + \frac{1}{m_k - 1} [X_j^{(i)} - C_k(k-1)] \\ J(k) = J(k-1) - (d_i - d_j) \end{cases} \quad (6)$$

步骤 6 :若 $t_k < t_{\min}$,则结束并返回聚类结果;否则返回步骤 3,继续迭代.

1.3 基于模拟退火的 AFS 算法

将模糊化的隶属函数取为高斯型,模糊规则取为‘If...Then’的语言形式,模糊推理中的‘T 算子’采用‘代数积’形式,去模糊化采用‘中心平均反模糊化法’,则得到基于模糊退火的 AFS 为

$$Y = \sum_{k=1}^M W_k \prod_{j=1}^r \exp\left(-\left|\frac{X^j - C_k^j}{\sigma_k^j}\right|^2\right) / \sum_{k=1}^M \prod_{j=1}^r \exp\left(-\left|\frac{X^j - C_k^j}{\sigma_k^j}\right|^2\right) \quad (7)$$

式(7)对应的模糊系统是用一条规则来对应一组数据的.由基于模拟退火算法的动态聚类方法得到每组数据对应的输入模式中心 C_k^j ,再通过选取适当的 σ_k^j ,利用最小二乘法计算 W_k 以确定每条规则对应的方程.

综上所述,基于模拟退火的 AFS 的工作过程为:(a)用模拟退火算法将系统输入聚为 m 类;(b)用这 m 类样本去训练 m 个神经网络,并将获得的 m 个模糊规则存储于网络的连接权中;(c)将历史样本作为输入,

将在 AFS 输出端得到的对应的输出与对应的实时样本进行比较,并根据误差判断对大坝安全监测系统的实时工作性态进行故障诊断.

2 基于模拟退火的 AFS 的大坝安全自动化监测故障自诊断设计^[5,6]

将大坝安全自动化监测视为多输入多输出离散非线性动态系统

$$y(k+1) = f(y(k), \cdots, y(k+1-n_y); u(k), \cdots, u(k+1-n_u)) + \delta(k) + \xi(k) \tag{8}$$

式中: $y(k+1)$ ——系统输出向量, $y(k+1) \in R^m$; $y(k)$ ——系统输入向量, $y(k) \in R^r$; n_y, n_u ——系统的输出和输入延迟; $\delta(k), \xi(k)$ ——系统的故障向量和噪声向量, $\delta(k) \in R^m, \xi(k) \in R^m$; $f(\cdot)$ ——非线性向量函数.

分析式(8)可知,构造非线性监测器的目的就是利用 AFS 来逼近系统的动力特性 $f(\cdot)$.

故障诊断是由残差产生和残差判决两部分组成的. 由上述学习算法建立的对象非线性监测器模型与实际系统并行工作,系统无故障时,两者之间的残差比较小且其幅值接近于零;系统偏离正常工作状态或发生故障时,残差按一定规律偏离零且残差较大. 因此,根据一定的故障分离策略就可以实现故障的在线诊断.

基于 AFS 的大坝安全自动化监测故障自诊断系统原理如图 2 所示.

3 大坝安全自动化监测故障自诊断系统实例

某钢筋混凝土平板坝自动化监测始于 1999 年 11 月 1 日. 其水平位移的自动化监测采用引张线和正、倒垂线,垂直位移自动化监测采用静力水准. 扬压力的自动化监测系统共有 33 个测点,是在人工监测孔的基础上改造而成的. 为检验自动化监测的稳定性和可靠性,对一些自动化监测点进行了人工监测. 本文以 2 号引张线的 X16 测点为例,其自动化测值序列为 1999 年 11 月 15 日至 2001 年 2 月 15 日的 452 个测值. 该测点水平位移测值过程线如图 3 所示,其中 2000 年 6 月 2 日~4 日(对应 k 值分别为 225, 226, 227)测值有一突变.

由于大坝运行多年,时效趋于稳定,影响大坝水平位移的主要因素是上游库水压力和坝区温度,所以输入 $u(k)$ 选取上游水位




图 4 输入样本(温度、水位)的动态聚类
Fig.4 Dynamic clustering of inputs(temperature and water level)

因子和温度因子,输出 $y(k)$ 为引张线上对应该测点的系列测值.

启动自动化监测的非线性观测器,利用观测器进行在线学习和估计,进行输出预报并计算输出残差.

图 4 是环境量的输入样本(温度、水位)的聚类图,圆圈为输入的训练样本点,实心黑点为通过聚类分析得到的样本特征点. 由图 4 可以看出,基于模拟退火算法的动态聚类能较好地寻求到整个样本空间上的特征点,发挥了全局优化的能力和处理局部极值的能力.

分析图 5 可知:残差响应量 $r(k)$ 的幅值在自动化测值发生突变前均较小,低于设置的门限($\epsilon_1 = \pm 0.05$ mm);当 $k = 225$ 时测值发生突变,对应残差响应超过门限并发出故障报警. 同时,作为故障评判第 2 项指标的复合残差 $E(k)$ 的响




图 2 基于模拟退火的 AFS 故障自诊断原理
Fig.2 Principle diagram of fault diagnosis with simulated annealing-based AFS




图 3 自动化测值序列及观测器实时输出
Fig.3 Auto-monitoring data and outputs of model

应曲线如图6所示,其幅值也在 $k = 225$ 时超过门限($\varepsilon_2 = \pm 0.1 \text{ mm}$)。由图5和图6可以看出,当故障发生时,系统的残差均会产生突变且超过阈值。此时,系统可有效地检测出故障并进行报警。另外,第2项指标复合残差 $E(k)$ 的引入,可防止漏报和误差的出现。




图5 残差 $r(k)$ 的响应曲线

Fig.5 Response curve of residual error




图6 复合残差 $E(k)$ 的响应曲线

Fig.6 Response curve of compound residual error

此外,从该测点人工观测值来看,人工测值变化平稳,未产生突变,并且该时段的环境量和坝体结构均没有异常变化。所以,这一突变是由于自动化监测的传感器受到随机干扰而产生的,应属于自动化监测故障。

4 结 语

a. 本文运用模拟退火算法对输入样本进行聚类分析,较好地发挥了模拟退火算法的全局优化搜索能力和局部极值处理能力。这既可以筛除、压缩样本的冗余信息,又可全面提取样本空间的特征值,从而可使样本的有用信息不被丢失。

b. 大坝安全的自动化监测(包括变形、扬压力等的监测)是一个强非线性系统,将 AFS 运用于大坝安全监测的故障诊断,能充分发挥其非线性逼近功能,可对实际的监测输出进行拟合并提供预报。

c. 实例表明,基于模拟退火的 AFS 的大坝安全监测故障自诊断系统有较好的实用性和可操作性。需要说明的是,本文仅建立了引张线的自动化监测模型,而关于综合性、通用性的大坝自动化监测故障诊断系统以及阈值(门限)的确定,还有待进一步研究。

参考文献:

- [1] 楼顺天,胡昌华,张伟. 基于 Matlab 的系统分析与设计——模糊系统[M]. 西安:西安电子科技大学出版社,2001.10—52.
- [2] 蔡开龙,杨秉政,谢寿生. 基于模糊神经网络的航空发动机故障诊断研究[J]. 机械科学与技术,2004,23(1): 96—98.
- [3] 杨忠明,黄道,王行愚. 基于模拟退火算法的动态聚类方法[J]. 控制与决策,1997,12(增刊): 520—523.
- [4] 常久鹏,蔡遂生,陈昌圻,等. 模糊自学习故障诊断在柴油机电控系统中的应用[J]. 内燃机学报,2001,19(2): 153—158.
- [5] 苏怀智,吴中如,温志萍,等. 基于模糊神经网络和遗传算法的大坝安全监控模型[J]. 大坝观测与土工测试,2001,25(1): 10—12.
- [6] 胡昌华,张晓明. 基于自适应模糊系统的非线性系统故障诊断[J]. 西北轻工业学院学报,1998,16(4): 34—37.

Application of adaptive fuzzy system to fault auto-diagnosis in dam safety monitoring

NIE Xue-jun¹, GU Chong-shi¹, YAN Liang-ping¹, LUO Long-hong²

(1. College of Water Conservancy and Hydropower Engineering, Hohai University, Nanjing 210098, China;

2. Jiangsu Hydraulic Engineering Planning Office, Nanjing 210029, China)

Abstract: A kind of learning algorithm of adaptive fuzzy system (AFS) based on the simulated annealing algorithm (SAA) was presented to improve the stability and reliability of dam safety automatic monitoring. According to the algorithm, a non-linear monitor model and a fault auto-diagnosis system for dam safety monitoring were developed. A case study shows that the present system, just as SAA, brings the nonlinear fitting of AFS into full play, and has the capacity of global optimal search, realizing the on-line diagnosis and real-time separation of faults effectively.

Key words: adaptive fuzzy system; simulated annealing; dam; fault diagnosis