

基于证据理论的迭代多步预测方法研究

洪 贝¹, 胡昌华¹, 姜学鹏²

(1. 解放军第二炮兵工程学院 302 教研室, 陕西 西安 710025; 2. 解放军海军航空工程学院 701 教研室, 山东 烟台 264001)

摘要: 为了有效利用复杂非线性工程系统中各种不确定信息和主观知识, 本文结合相空间重构理论和证据推理理论, 建立时序证据的多步预测模型. 本文先对时序证据进行相空间重构; 针对时序证据预测中信息量大且存在误差累积的不足, 采用时序证据滑动窗口处理方法, 以降低累积误差; 窗口内运用迭代融合规则, 以降低信息量的存储. 将该模型应用于某型陀螺仪漂移预测, 试验结果证明, 本文方法能够有效降低迭代时产生的累积误差和信息量, 结论更接近实际情况.

关键词: 证据理论; 迭代多步预测; 滑动窗口

中图分类号: TP274 **文献标识码:** A

Iterative multi-step prediction model based on theory of evidence

HONG Bei¹, HU Chang-hua¹, JIANG Xue-peng²

(1. Xi'an Research Institute of Hi-Tech Hongqing Town, Xi'an Shaanxi 710025, China;

2. Unit701, Naval Aeronautical and Astronautical University, Yantai Shandong 264001, China)

Abstract: To make use of the uncertain information and subjective knowledge in complex nonlinear systems, we propose a multi-step prediction method for time series of evidence based on the phase space reconstruction theory and evidence inference theory. In the reconstruction of phase space for time series of evidence, we use the sliding window for time series of evidence to deal with the great amount of information and the shortage of accumulation errors to reduce the accumulated errors. The information storage is reduced by applying the iterative rules to the windows. The proposed methods have been applied to the simulation tests of a missile inertia device for fault prediction. The results show the effectiveness of these methods.

Key words: theory of evidence; iterative multi-step predicting; sliding widow

1 引言(Introduction)

随着现代工业和科学技术的发展, 系统的复杂程度和自动化程度日益提高, 出现了一些大型复杂系统, 社会生产实践对这类系统的可靠性、安全性提出了越来越高的要求, 故障预报已经作为重要问题被关注^[1]. 因此基于目前可获得的数据和状态, 开展复杂系统故障预报研究具有十分重要的意义. 对于复杂的非线性工程系统, 其故障预报问题涉及到定性和定量的信息, 以及各种不确定信息, 如不完整性、模糊性信息等. 因此很难通过获取完整的历史数据来建立完善的系统数学模型. 传统的基于数据的预测模型, 如时间序列分析模型和基于滤波器的模型一般很难建立. 另一方面, 在大部分实际应用中, 决策者拥有最终的决策权, 其主观判断对于最终

的决策起到很重要的作用. 文献[2,3]提到的方法对于处理既存在数值型数据又有不确定性主观判断信息(可能是不完整的或不确定的)的问题时存在局限性. 因此, 需要建立一种比较通用的预测模型, 既能够对数值型数据进行建模和分析, 又能够处理不确定、不完整、模糊的主观判断信息. 同时在工程实际中, 除了一步预测, 更希望获得多步预测的结果, 这一需求的同时也增加了预测难度.

2007年不确定性处理领域国际著名学者Smets^[4]从理论上分析了证据融合的结果反映了系统的历史信息, 并且历史的信息都存储在最后的合成结果中, 这一理论成果为证据理论应用于时间序列的多步预测提供了基础. 但证据理论对证据的累积融合, 使得多步时序证据组合过程中容易产生累积误差,

通常的静态加权规则已不再适合处理该类问题, 为此本文拟探寻一种新的方法. 基于此, 本文首先应用FNN选择嵌入维数和C-C算法确定时延参数, 重构时间序列的相空间, 方便从中提取更多信息; 借助于专家经验和历史数据, 用证据理论描述这些知识, 提出时序证据加窗处理, 以降低累积误差; 并以无后效性为迭代前提, 建立满足多步预测的迭代规则. 本文将用于某型陀螺仪漂移预测, 试验结果证明, 本文方法能够有效降低时序证据的累积误差和信息量, 结论更接近实际情况.

2 预测模型分析(Analysis of predicting model)

2.1 证据理论(Theory of evidence)

证据理论由Dempster在1967年最初提出, 又称为D-S理论、证据推理(ER)、信度函数理论等. 因其能够很好地处理不确定信息, 并具有无需先验概率、推理形式简单等优点, 被广泛应用于不确定性数据的处理, 取得了较好的结果.

证据理论首先定义一个空间 Θ , 称为辨识框架, 是由相互排斥的命题组成的有限完备集. Θ 的幂集为 2^Θ , 表示 Θ 所有子集的集合. 其最基本的信息载体为基本概率指派(basic probability assignment, BPA), 定义如下:

定义 1 令 Θ 为识别框架, 称映射 $m: 2^\Theta \rightarrow [0, 1]$ 为 Θ 上的BPA函数, m 满足:

- 1) $0 \leq m(A) \leq 1$;
- 2) $m(\emptyset) = 0$, \emptyset 表示空集;
- 3) $\sum A \subseteq \Theta, m(A) = 1$.

$m(A)$ 表示证据对命题 A 的支持程度, 其信任区间为 $[\text{Bel}(A), \text{Pl}(A)]$, Bel 和 Pl 分别称为信任函数和似真函数:

$$\text{Bel}(A) = \sum_{A_i \subseteq A} m(A_i), \quad (1)$$

$$\text{Pl}(A) = 1 - \text{Bel}(\bar{A}), \bar{A} = \Theta/A, \quad (2)$$

函数 $\text{Bel}(A)$ 为集合的信度下界值, 函数 $\text{Pl}(A)$ 为集合的信度上界值. 证据理论的核心是融合规则, 通过规则来融合不同信息源产生的证据, Dempster融合规则表示如下:

$$m_1 \oplus m_2(C) = \begin{cases} 0, & A = \emptyset, \\ \frac{\sum_{\cap A_i=A} \prod_{i=1}^n m_i(A_i)}{(1-K)}, & A \neq \emptyset. \end{cases} \quad (3)$$

其中 $K = \sum_{\cap A_i=\emptyset} \prod_{i=1}^n m_i(A_i)$, 表示融合过程中各证据

之间冲突程度, $1 - K$ 称为归一化因子, 避免在合成过程中将非零的概率分配给空集. 当 $K = 0$ 时即为Smets定义的开放世界的转移信度模型(transerable belief model, TBM). 考虑本文应用对象为时序证据, 不存在空集, TBM较之Dempster融合规则, 不需要计算归一化因子, 计算简单, 更符合实际应用, 因此本文选用TBM融合规则.

已经证明TBM和Dempster组合规则满足结合律和交换律, 即

- 1) 结合律: $(m_1 \oplus m_2) \oplus m_3 = m_1 \oplus (m_2 \oplus m_3)$;
- 2) 交换律: $m_1 \oplus m_2 = m_2 \oplus m_1$.

这两个性质表明证据组合结果与组合顺序无关, 因此在对多个BPA函数进行组合时, 可以通过两两组合的方式进行.

2.2 构建故障状态识别框架(Frame of fault discernment)

故障状态的确定依赖于具体问题, 因此故障状态识别框架也需要根据实际情况确定. 例如可使用3种状态来描述故障程度: “轻度” (F_1), “中等” (F_2), “严重” (F_3), 故定义故障识别框架为 $\Theta = \{F_1, F_2, F_3\}$. 为了得到更细致的故障程度、定位等预报结果, 只需将故障程度继续深入划分, 而故障识别框架随之丰富; 反之只是为了快速得到预报结果, 则粗分故障程度. 依据具体问题, 可粗化或细化识别框架.

2.3 预测模型训练集的信度函数(Confidence function of training set)

在工程实际中, 数据可能是数值或主观分布等中任一种或混合的形式, 为了能够应用证据理论, 需要把工程数据转换为证据理论中定义的信度函数分布的形式:

$$e(x_i) = \{(F_n, m_{n,i}), n = 1, \dots, N\}, \quad (4)$$

其中: $i = 1, \dots, L, m_{n,i} \geq 0, \sum_{n=1}^N m_{n,i} \leq 1$, 且 $m_{n,i}$ 表示输入变量 x_i 被评估为等级 F_n 的信度. 如果 $\sum_{n=1}^N m_{n,i} = 1$, 则称对输入变量 e_i 的评估是完整的, 否则为不完整的评估. $m_{n,i}$ 的获取方式依赖于输入变量 x_i ($i = 1, \dots, L$)的特点, 比如定量属性的数据以数值的形式表示, 而定性属性的数据以分布的形式表示^[5]. 为了在统一的信度框架下处理定性属性与定量属性, Yang^[6]已经提出了等价信息变换技术, 通过变换, 数值数据、随机数据或定性信息都可以变换为信度函数形式. 具体的算法参见文献[6].

2.4 嵌入维数和时延参数的选择(Determining the embedding dimension)

为了从时间序列中获得更多信息, 在对时间序列研究前, 需重构相空间. 常用坐标延迟法, 其本质是通过一维时间序列的不同时间延迟 τ 来构造 m 维相空间矢量. 大量的学者都在研究如何选择一个最优维数的问题. 目前主要的成就有学者L.Y.Cao提出的Cao理论^[7]、奇异值分解法^[8], 以及虚假最临近点法(FNN)^[9]等, 其中FNN被认为是计算嵌入维数很有效的方法, 并得到了广泛应用. 具体的算法参见文献^[9].

时延参数 τ 的选择影响着预测结果的精度, 如果太小则任意两个分量在数值上非常接近, 以至于无法相互区分, 从而无法提供两个独立的坐标分量; 但如果太大的话, 则两坐标在统计意义上又是完全独立的, 失去了相关性. 因此需要用一定的方法来确定一个合适的时延参数 τ 值. Kim等在文献^[10]中提出了一种简单易用的时延参数 τ 的选择方法: C-C法.

综合文献资料, 本文选择计算嵌入维数很有效的FNN法确定嵌入维数, 以及计算简单易用的C-C法确定时延参数.

2.5 多步预测方法的确定(Determining the multi-step prediction method)

时间序列的多步预测有两种方式. 一种是一步迭代法, 即重复使用一步向前预测若干次, 并把上一次的预测值视作系统输出真值, 应用于下一次预测中. 另一种是直接预测的方法, 即直接建立预测模型 $\hat{y}(T+m) = f(x(T), \dots, x(T-p+m))$.

工程应用中选择哪种方式是由对预测变量精度要求与效率要求间的平衡决定的. 有一部分文献^[11, 12]认为直接预测精度上优于迭代预测, 但这部分工作目前还局限于理论上. 更多的学者, 如Ang等^[13]认为相对于迭代预测, 直接预测还存在很多缺陷, 而学者Marcellino^[14]列举了很多实例论证了这一结论, 其结果显示迭代预测明显胜过直接预测, 尤其是在时延参数 τ 比较大的情况下. 综上所述, 目前的多步预测方法应以迭代方法为优先考虑, 故本文选用迭代法.

3 基于证据理论的多步预测模型(The iterative multi-step predicting model based on theory of evidence)

3.1 证据融合的迭代算法(The iterative combination rule)

当证据随时间依次收集时, 不能按任意的顺序进行信息融合. 但如果按时间顺序融合时, 存储的信息

量将激增. 故当融合计算时, 希望通过 m_{12} 和 m_3 来计算 m_{123} , 不需要存储产生 m_{12} 的信度函数即 m_1, m_2 , 以减小信息存储量. Smets称这一要求为马尔可夫条件^[15], 又称无后效性.

定义 2 假设 $m_i, i = 1, \dots, n$ 是定义在识别框架 Θ 上 t_i 时刻的信度函数, $f_n(m_1, m_2, \dots, m_n)$ 是融合 m_1, m_2, \dots, m_n 的结果, 当且仅当存在函数 \oplus (组合两个BPA为一个BPA), 具有如下形式:

$$f_n(m_1, \dots, m_n) = \oplus(\dots(\oplus(m_1, m_2), \dots), m_n) \quad (5)$$

成立时, 则称 f_n 满足马尔可夫条件.

满足定义2的融合过程称为马尔科夫过程. 根据定义2可知目前的BPA函数包含有其前序信息, 所以用目前的BPA函数代替前BPA函数集合并不会造成信息丢失. 因此只需要对 t 时刻收集的证据与第 $t-1$ 时刻的BPA函数进行融合就得到所需的所有信息, 不需要存储前 $t-1$ 时刻的所有信度函数. 本文为了解决多步迭代预测时存储信息量问题, 将合成规则和无后效性有机地结合.

容易证明, 满足交换性与结合性的Dempster合成规则和TBM都是满足马尔可夫条件的. 在此条件下, 令 $E_{I(i)} = \{e_1, e_2, \dots, e_i\}$ 表示前 i 个证据的集合, $m_{j, I(i)}$ 表示 $E_{I(i)}$ 支持 F_j 的BPA函数值, $m_{\Theta, I(i)}$ 表示未分配的BPA函数值, 本文选用TBM作为合成规则, 由此根据其定义, 得到证据理论的迭代算法:

$$m_{j, n} = \oplus(\dots(\oplus(m_1, m_2), \dots), m_n), \quad (6)$$

$$m_{\Theta, \oplus(i+1)} = 0, \quad (7)$$

$$\sum_{j=1}^N m_{j, \oplus(i+1)} + m_{\Theta, i+1} = 1. \quad (8)$$

其中: $j = 1, 2, \dots, N, i = 1, 2, \dots, n-1$.

3.2 时序证据的滑动窗口累积融合(Combination based on sliding widow)

迭代算法除了存储信息量问题, 还存在累积误差问题. 累积误差对预测结果的影响较大, 考虑到本文的模型误差主要来源于证据. 针对这类问题的处理, 目前大都采用去相关性或采用加权融合的思想, 如利用先验知识对证据合成规则进行改进或使用改进的加权合成规则来进行相关证据融合推理^[15, 16]. 然而在实际应用中, 很难获得时序列之间相关性的先验知识, 也很难求得相关性的定量表示. 本文采用对时序证据信息“滑动窗口”截取处理的方法, 减小时序证据信息的累积相关性, 并讨论“滑动窗口”数据大小的自适应选取.

定义3^[17] 基本概率赋值比值

$$\begin{cases} q_{1i} = (m_1(A_i) + m_1(\Theta)) / (m_1(A_1) + m_1(\Theta)), \\ q_{1n} = m_1(\Theta) / (m_1(A_1) + m_1(\Theta)), \end{cases} \quad (9)$$

递推累积融合窗口大小的确定是很复杂的, 一般情况下, 若时序证据间相关性弱, 且最大BPA函数低, 则证据命题的基本概率赋值比高, 进而需要累积融合的窗口越大. 由此可定义“滑动窗口”数据大小的自适应选取粗略计算公式如下:

$$W \geq C / \ln q_{\min}, \quad (10)$$

其中 C 可以根据实际情况进行定义. 取 $C = 1$ 时, 相应的累积窗口大小 W 与 q_{\min} 的关系如表1所示. 表1显示, 基本概率赋值比越大, 需要累积融合的窗口越大, 即可处理的时序证据信息越多.

表1 BPA函数比与相应窗口大小
Table 1 Relationship of q_{\min} and W

q_{\min}	0.32	0.43	0.54	0.65	0.78	0.81	0.85	0.93	0.96
W	2	3	4	5	8	13	18	28	57

因此对时序证据进行“滑动窗口”截取处理, 并对窗口内的时序证据进行累积融合的过程为: 设“窗口”大小为 W , 首先, 对时序证据中的前 W 批数据形成的 W 个时序证据迭代累积融合, 求出融合结果并记录; 然后, 顺序移动窗口到第 $2 \sim (W+1)$ 个时序证据函数, 下一次移动到第 $3 \sim (W+2)$ 个时序证据函数, 直到窗口移到最后的 W 个时序证据函数, 分别对窗口内证据函数进行迭代累积融合, 并记录下结果; 最后, 利用这些结果统计出最终的结论.

3.3 多步预测结果获取(The multi-step output)

在工程实际中, 真实系统的输出 $\hat{y}(t)$ 往往是精确的数值, 在这种情况下, 就希望能够得到与信度分布形式的 $e(\hat{y}(t))$ 等价的数值型输出. 通过引入效用期望, 就可以实现信度分布输出向数值输出的变换^[6]. 假设 $u(F_n)$ 是识别框架 $F_n, n = 1, \dots, N$ 的效用. 如果 F_j 与 F_i 相比, 决策者偏好于评估等级 F_j , 那么 $u(F_i) < u(F_j), u(F_n)$ 一般通过专家先验知识或客观知识获取^[6].

为了实现信度函数与数值型输出的变换, 文献[18]引入最大、最小、平均效用, 假设评估等级 F_n 的效用为 $u(F_n)$, 那么输出评估 $e(\hat{y}(t))$ 的期望效用就可以定义如下:

$$u(e(\hat{y}(t))) = \sum_{n=1}^N \hat{\beta}_n(t) u(F_n), \quad (11)$$

$\hat{\beta}_n(t)$ 表示 $\hat{y}(t)$ 被评估为 F_n 的信度下界值, 可根据公

式(1)获取, 而 $(\hat{\beta}_n(t) + \hat{\beta}_F(t))$ 是其上界值, 可根据公式(2)获取.

不失一般性, 假设 F_1 得到决策者的最小偏好, F_N 得到决策者的最大偏好, 则 $e(\hat{y}(t))$ 最大、最小、平均效用的具体计算如下:

$$\begin{aligned} u_{\max} &= \sum_{n=1}^{N-1} \hat{\beta}_n(t) u(F_n) + (\hat{\beta}_N(t) + \hat{\beta}_F(t)) u(F_N), \quad (12) \\ u_{\min} &= \end{aligned}$$

$$(\hat{\beta}_1(t) + \hat{\beta}_F(t)) u(F_1) + \sum_{n=2}^N \hat{\beta}_n(t) u(F_n), \quad (13)$$

$$u_{\text{avg}} = \frac{u_{\max}(e(\hat{y}(t))) + u_{\min}(e(\hat{y}(t)))}{2}, \quad (14)$$

由此, 定义预测的数值型输出结果 $\hat{y}(t)$ 可以按下式计算:

$$\hat{y}(t) = u_{\text{avg}}(e(\hat{y}(t))), \quad (15)$$

根据公式(12)~(14)可得预测结果 $\hat{y}(t)$ 具体如下:

$$\hat{y}(t) = \sum_{n=1}^N \hat{\beta}_n(t) u(F_n) + \frac{u(F_1) + u(F_N)}{2} \hat{\beta}_F(t), \quad (16)$$

如果总体的评估结果是完整的、精确的, 则有 $\hat{\beta}_F(t) = 0$, 预测结果 $\hat{y}(t)$ 的计算可以简化为

$$\hat{y}(t) = \sum_{j=1}^N \hat{\beta}_j(t) u(F_j), \quad (17)$$

此时, 已可获得 t 时刻的预测数据, 多步预测结过可根据2.5节中描述的迭代算法继续获得.

4 应用实例(Practical issue)

在本节的应用实例中, 系统的漂移数据是某型单轴DGT出厂后进行性能可靠性试验获取的. 对于DTG漂移试验, 相关的技术参数包括采样周期 τ , 当地重力加速度 g , 及地理纬度 R . 本文根据C-C算法选取 $\tau = 2.8736 \text{ h}$, 取常值 $g = 979.4121 \text{ cm/s}^2$, 通过延迟坐标法共获取到33个逐日漂移误差系数的实测数据.

假设当前的漂移量 y_t 与距它最近的漂移 y_{t-1} 是相关的, 进一步扩展为与历史值 y_{t-2}, \dots, y_{t-m} 是相关的. 下一时刻的陀螺仪漂移量在一定程度上依赖于当前陀螺仪的状态. 令 $(y_{t-1}, y_{t-2}, \dots, y_{t-m})$ 作为本文预测模型的输入向量:

$$\hat{y}(t) = \hat{y}_t = f(y_{t-1}, y_{t-2}, \dots, y_{t-m}), \quad (18)$$

其中 $\hat{y}(t)$ 是一个标量, 描述DTG在 t 时刻的漂移量.

漂移数据分为训练数据和测试数据. 在本文预测模型中, 由FNN算法选取较优的嵌入维数 $m = 5$, 所以式(18)可以描述如下:

$$\hat{y}(t) = \hat{y}_t = f(y_{t-1}, y_{t-2}, y_{t-3}, y_{t-4}, y_{t-5}), \quad (19)$$

在式(19)中, 原始的输入输出数据是数值数据的形式, 为了验证本文预测模型预测能力, 就需要将数值数据等价变换为信度分布结构的形式. 对于DTG故障预报问题, 假设陀螺仪的故障状态可以划分为如下3类: “Small” (F_1), “Medium” (F_2), 及 “Large” (F_3). 由此, 定义如下的陀螺仪故障状态识别框架:

$$F = \{F_j, j = 1, 2, 3\} = \{\text{Small}, \text{Medium}, \text{Large}\},$$

本文模型的预测在这个识别框架上进行, 而该识别框架的量化及属性信息的变换可以参考文献[8]给出的效用函数和信息等价变换技术.

表 2 陀螺仪漂移的参考点
Table 2 The degree of gyro drift

语义	Small(F_1)	Medium(F_2)	Large(F_3)
数值/ $(^\circ) \cdot h^{-1}$	1.0	1.4	2.4

表2给出了识别框架的量化结果. 对于给定的输入向量($y_{t-1}, y_{t-2}, y_{t-3}, y_{t-4}, y_{t-5}$)利用基于规则的等价变换技术, 可以根据表2参考点将输入向量变换到信度分布的识别框架下. 以第10个输入向量(4.59, 4.48, 4.6, 4.35, 4.36)为例, 对于4.59 ($^\circ/h$), 可以变换为如下的信度分布结构:

$$e(4.59) = \{(F_1, 0.1), (F_2, 0.9), (F_3, 0)\},$$

相似地, 其他的值可以变换为如下的形式:

$$e(4.48) = \{(F_1, 0.175), (F_2, 0.825), (F_3, 0)\},$$

$$e(4.6) = \{(F_1, 0), (F_2, 1), (F_3, 0)\},$$

$$e(4.35) = \{(F_1, 0.125), (F_2, 0.875), (F_3, 0)\},$$

$$e(4.36) = \{(F_1, 0.35), (F_2, 0.65), (F_3, 0)\}.$$

其他的输入输出数据的变换与上面的方法相似.

通过窗口自适应选取公式可以获得窗口大小 N . 此外, 等级效用 $u(F_1) > u(F_2) > u(F_3)$, 这一关系表明对 F_1 的偏好优于 F_2 , 并且 F_2 优于 F_3 .

在本文预测模型中, 由FNN算法选取较优的嵌入维数为5, 则33个观测值构造27个样本, 取前18个样本为训练样本, 后9个样本为测试样本. 一步预测的训练和测试结果如图1所示, 两步预测的训练和测试结果如图2所示.

从实例结果图1和图2可以看出, 随着样本的增多, 两步预测较一步预测更贴近真实值, 两者的平均相对误差分别为0.0054和0.0055, 这说明两步预测的累积误差更小.

为了进一步说明本文方法的有效性, 连续进行30次实验取平均误差, 并与采用相空间重构和滑动

窗口的模型(简称为“未改进方法”)的测试误差进行比较, 以均方根误差作为衡量标准, 结果如表3所示. 分析测试误差的结果可以得出: 本文方法的一步预测和两步预测的误差均有所减小. 该结论和本文方法的设计思想是一致的.




图 1 一步预测训练和测试结果

Fig. 1 The training and testing results of one-step predicting model




图 2 两步预测训练和测试结果

Fig. 2 The training and testing results of two-step predicting model

表 3 本文方法与未改进方法误差比较

Table 3 The error compare of two methods

预测步数	本文方法	未改进方法
一步预测	0.1256	0.1358
两步预测	0.2506	0.2939

5 结论(Conclusion)

综上所述, 基于证据理论的多步预测方法不需要事先确定输入输出之间的函数关系, 加入了决策者和专家的知识, 且证据理论算法是非线性融合方法, 因此, 在输入输出函数关系难获得情况下, 基于证据理论的多步故障预报方法是一种处理非线性系统预测问题的较优选择.

参考文献(References):

[1] 陈敏泽, 周东华. 动态系统的故障预报技术[J]. 控制理论与应用, 2003, 20(6): 819 – 824.
(CHEN Minze, ZHOU Donghua. Fault prediction techniques for dynamic systems[J]. *Control Theory & Applications*, 2003, 20(6): 819 – 824.)

[2] DONG M, HE D. Hidden semi-Markov model-based methodology for multi-sensor equipment health diagnosis and prognosis, stochastic and statistics[J]. *European Journal of Operational Research*, 2007, 178(3): 858 – 878.

- [3] 周志杰, 胡昌华, 周东华. 基于非解析模型的动态系统故障预报技术[J]. 信息与控制, 2006, 35(5): 603 – 608.
(ZHOU Zhijie, HU Changhua, ZHOU Donghua. Fault prediction techniques for dynamic systems based on non-analytical model[J]. *Information and Control*, 2006, 35(5): 603 – 608.)
- [4] SMETS P, KENNES R. The transferable belief model[J]. *Artificial Intelligence*, 1994, 66(2): 191 – 234
- [5] YANG J B, SINGH M G. An evidential reasoning approach for multiple-attribute decision making with uncertainty[J]. *IEEE Transactions on Systems, Man, and Cybernetics*, 1994, 24(1): 1 – 18.
- [6] YANG J B. Rule and utility based evidential reasoning approach for multi-attribute decision analysis under uncertainties[J]. *European Journal of Operational Research*, 2001, 131(1): 31-61.
- [7] CAO L Y. Practical method for determining the minimum embedding dimension of a scalar time series[J]. *Physica D*, 1997, 110(11): 43 – 50.
- [8] ALBANO A M, MUENCH J, SCHWARTZ C, et al. Singular-value decomposition and the Grassberger-Procaccia algorithm[J]. *Physical Review A*, 1988, 38(6): 3017 – 3026.
- [9] KENNEL M B. Determining embedding dimension for phase-space reconstruction using a geometrical construction[J]. *Physical Review A*, 1992, 45(6): 3403 – 3411.
- [10] KIM H S, EYKHOLT R, SALAS J D. Nonlinear dynamics, delay times, and embedding windows[J]. *Physica D*, 1999, 127(3): 48 – 60.
- [11] COX D R. Prediction by exponentially weighted moving averages and related methods[J]. *Journal of the Royal Statistical Society*, 1961, 23: 414 – 422.
- [12] ATIYA A F, SHOURA S M E, SHAHEEN S I, et al. A comparison between neural-network forecasting techniques-case study: river flow forecasting[J]. *IEEE Transaction on Neural Networks*, 1999, 10(2): 402 – 409.
- [13] ANG A, PIAZZESI M, WEI M. What does the yield curve tell us about GDP growth?[J]. *Journal of Econometrics*, 2006, 131(2): 359 – 403.
- [14] MARCELLINO M, STOCK J, WATSON M W. A comparison of direct and iterated multistep AR methods for forecasting macroeconomic time series[J]. *Journal of Econometrics*, 2005, 135(3): 499 – 526.
- [15] 王永成. 目标属性信息相关时融合识别的实现方法[J]. 兵工学报, 2005, 26(3): 338 – 342.
(WANG Yongcheng. Method of implementation of fusing correlated attribute information in target recognition[J]. *Acta Armamentarii*, 2005, 26(3): 338 – 342.)
- [16] 孙怀江, 杨静宇. 一种相关证据的合成方法[J]. 计算机学报, 1999, 22(9): 1004 – 1007.
(SUN Huaijiang, YANG Jingyu. A combination method for dependent evidences[J]. *Chinese Journal of Computers*, 1999, 22(9): 1004 – 1007.)
- [17] 王前东, 陈怀新, 南建设. 时序证据的加窗累积D-S组合推理方法[J]. 电讯技术, 2009, 49(1): 54 – 58.
(WANG Qiangdong, CHEN Huaxin, NAN Jianshe. Window-adding cumulation fusion method based on the D-S evidence reasoning[J]. *Telecommunication Engineering*, 2009, 49(1): 54 – 58.
- [18] SMETS P. Analyzing the combination of conflicting belief functions[J]. *Information Fusion*, 2007, 8(4): 387 – 412.
- [19] XU D L, LIU J, YANG J B, et al. Inference and learning methodology of belief-rule-based expert system for pipeline leak detection[J]. *Expert Systems and Applications*, 2007, 32(1): 103 – 113.
- [20] NIU G, YANG B S. Dempster-Shafer regression for multi-step-ahead time-series prediction towards data-driven machinery prognosis[J]. *Mechanical Systems and Signal Processing*, 2009, 23(3): 740 – 751.

作者简介:

洪 贝 (1982—), 女, 博士研究生, 目前研究方向为故障预报、信息融合, E-mail: hongbei1983@163.com;

胡昌华 (1966—), 男, 教授, 博士生导师, 目前研究方向为潜在通路分析、故障诊断;

姜学鹏 (1979—), 男, 讲师, 目前研究方向为控制理论与应用。