

倾转旋翼机飞控系统的变精度粗糙集-OMELM故障诊断方法

陈晓¹, 王新民¹, 黄誉¹, 王晓燕²

(1. 西北工业大学 自动化学院, 西安 710129; 2. 西安建筑科技大学 机电工程学院, 西安 710055)

摘要: 结合变精度粗糙集(VPRS)和优化极限学习机(OMELM)诊断算法的优点, 将变精度粗糙集引入OMELM中, 提出变精度粗糙集-OMELM故障诊断方法, 用于诊断倾转旋翼机过渡模式下飞控系统的故障. 首先根据采集的倾转旋翼机多故障输出信号的数据特点, 提出一种属性约简算法, 定义了一种新的变精度粗糙熵; 然后从信息论互信息增量的角度定义属性重要性, 构造OMELM分类器并对约简后的属性特征进行故障多分类; 最后以XV-15进行验证, 结果表明所提出的方法平均辨识率高、诊断时间短.

关键词: 倾转旋翼机; 故障诊断; 优化极限学习机; 变精度粗糙集; 互信息

中图分类号: V249

文献标志码: A

Fault diagnosis for tilt-rotor aircraft flight control system based on variable precision rough set-OMELM

CHEN Xiao¹, WANG Xin-min¹, HUANG Yu¹, WANG Xiao-yan²

(1. College of Automation, Northwestern Poly-technical University, Xi'an 710129, China; 2. School of Mechanical and Electrical Engineering, Xi'an University of Architecture and Technology, Xi'an 710055, China. Correspondent: CHEN Xiao, E-mail: candychch@mail.nwpu.edu.cn)

Abstract: Integrating the advantages of the variable precision rough set(VPRS) and optimization method based extreme learning machine(OMELM), a method of variable precision rough set-OMELM is proposed to diagnose the failure of the tilt-rotor aircraft flight control system. An attribute reduction algorithm is presented according to data collection characteristics of fault output signals. The attribute reduction algorithm defines a variable precision rough entropy. The attribute importance is defined from the perspective of mutual information increment in information theory. The OMELM classifier is constructed to classify the reduction attribute feature. Finally, simulation is carried out based on XV-15, and the results show the high average recognition rate and the short diagnosis time of the proposed method.

Keywords: tilt-rotor aircraft; fault diagnosis; optimization method based extreme learning machine; variable precision rough set; mutual information

0 引言

倾转旋翼机是一种具有直升机、固定翼和过渡3种飞行模式的新型航空器, 通过机翼两端发动机短舱的倾转, 可以在直升机和固定翼模式之间过渡转换. 转换过程中倾转旋翼机的动力学特性及操纵控制系统比较复杂^[1], 若此时飞控系统发生故障, 而不能及时准确地诊断将会影响飞机的正常飞行, 甚至会发生机毁人亡的空难事故. 为此, 开展倾转旋翼机飞控系统的故障诊断研究十分重要.

上世纪50年代初, 美国国家航空航天局(NASA)和贝尔公司着手研究倾转旋翼XV-3验证机、XV-15验证机和鱼鹰V-22型号机. 随着XV-15、V-22倾转旋

翼机技术的日趋成熟, 近年来国内外众多学者开始对倾转旋翼机进行研究, 主要集中在动力学建模^[2-4]、气动弹性分析^[5-7]和飞行控制^[8-10]等方面. 目前, 对于倾转旋翼机飞控系统的故障诊断尚无人涉足, 仅Kim团队研究了倾转旋翼无人机飞控系统的容错控制^[11], 这表明了故障诊断和容错控制是倾转旋翼机未来的研究趋势.

故障诊断方法早期分为基于数学模型、基于知识和基于信号处理的方法^[12]. 近年来, 随着理论研究的深入和相关领域的发展, 各种新的诊断方法层出不穷, 原来的故障诊断分类方法已不再适用. 最新的分类方法是李晗等^[15]在文献[13-14]的研究基础上将故

收稿日期: 2013-11-08; 修回日期: 2014-04-08.

作者简介: 陈晓(1982-), 女, 博士生, 从事飞行器飞行控制、故障诊断及评估的研究; 王新民(1951-), 男, 教授, 博士生导师, 从事飞行控制技术及故障重构等研究.

障诊断方法分为定量分析、定性分析和基于数据驱动的方法3大类,并指出每种诊断方法各有其优势和特点,同时也存在着局限性,单一的诊断方法有时难以及时准确地完成对复杂对象的诊断.对于实际系统,混合应用不同的故障诊断方法^[16]是当今研究的一个热点和主流方向.

极限学习机(ELM)是由Huang等^[17]根据摩尔-彭罗斯(MP)广义逆矩阵理论提出的一种机器学习算法,通过计算隐含层输出矩阵的MP广义逆,一步即可解析求出学习网络的输出权值,并提供良好的泛化能力和极快的学习速度,然而ELM也存在固有缺陷.为了完善ELM算法的学习性能,Huang等^[18-21]陆续提出了在线贯序极限学习机(OS-ELM)、凸增量极限学习机(CI-ELM)、强化的增量极限学习机(EI-ELM)和优化极限学习机(OMELM).自2011年,ELM便作为故障诊断领域的一种新方法开始被国内外学者关注和研究^[22].

故障诊断一般属于小样本诊断,实际系统中采集到的数据常常包含噪声.虽然OMELM的诊断技术有所提高,能够解决传统ELM在小样本数据集上学习能力低的缺点,但是对于噪声污染的样本,如果特征向量选取得不恰当,会直接影响OMELM诊断的准确性^[21].另一种故障诊断新方法——变精度粗糙集(VPRS)^[23]能够约简属性特征,删除不必要或者不重要的属性,相比传统粗糙集,具有较强的抗噪能力^[24].

针对以上情况,本文结合变精度粗糙集和OMELM这两种诊断算法的优点,将变精度粗糙集首次引入到OMELM中,根据采集的倾转旋翼机多变量状态故障输出信号的样本数据特点,提出基于变精度粗糙集-OMELM的方法研究倾转旋翼机飞控系统的故障诊断问题.

1 倾转旋翼机

1.1 倾转旋翼机的操纵特性

倾转旋翼机通过发动机短舱倾转带动旋翼轴转动,两侧的旋翼组件既可以当作横列式直升机的双旋翼,又可以当作固定翼的螺旋桨,兼具了普通直升机垂直起降和空中悬停的能力以及一般螺旋桨飞机巡航飞行的能力.它具有3种飞行模式,每种模式对应的操纵特性如表1所示;每种模式对应的旋翼位置如图1所示.

表1 倾转旋翼机3种飞行模式的操纵控制

飞行模式	直升机模式	过渡模式	固定翼模式
短舱倾转角度	0°	(0°, 90°)	90°
俯仰控制	纵向周期变距	混合	升降舵
滚转控制	差动总距	混合	襟副翼
偏航控制	差动纵向周期变距	混合	方向舵
推力控制	总距	混合	油门

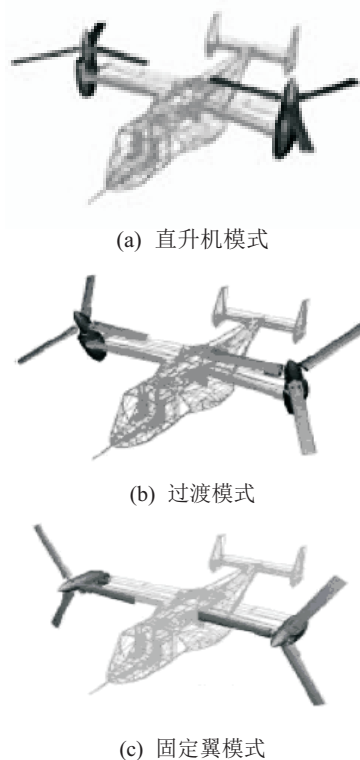


图1 倾转旋翼机3种飞行模式的旋翼位置

从表1可以看出:当发动机短舱倾转0°时,倾转旋翼机以直升机模式飞行,通过控制纵向周期变距、差动总距和差动纵向周期变距产生俯仰、滚转和偏航力矩,控制总距产生拉力;当发动机短舱倾转90°时,倾转旋翼机以固定翼模式飞行,通过控制升降舵、襟副翼和方向舵产生俯仰、滚转和偏航力矩,控制油门产生推力;过渡模式下,发动机短舱倾转在0°和90°之间,此时倾转旋翼机可以从直升机模式过渡到固定翼模式或者从固定翼模式过渡到直升机模式,飞行操纵则利用直升机和固定翼混合控制输入.

1.2 倾转旋翼机的动力学模型

倾转旋翼机的六自由度非线性动力学模型描述为

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

其中

$$x = [u, v, w, \phi, \theta, \psi, p, q, r, x_g, y_g, z_g]^T, \quad (2)$$

$$u = [\theta_0, \theta_{0,c}, \theta_s, \theta_{s,c}, \delta_e, \delta_a, \delta_r, \beta_M, \Omega, XFL]^T. \quad (3)$$

x 、 u 和 y 分别是状态向量、系统控制输入向量和输出向量; $[u, v, w]$ 和 $[p, q, r]$ 分别是飞行速度 v 和转动角速度 ω 在机体坐标轴系各轴上的分量; $[\phi, \theta, \psi]$ 是姿态角,即通常所指的欧拉角; $[x_g, y_g, z_g]$ 是倾转旋翼机在地面坐标系中的位置; $[\theta_0, \theta_{0,c}, \theta_s, \theta_{s,c}]$ 是总距、差动总距、纵向周期变距和差动纵向周期变距; $[\delta_e, \delta_a, \delta_r]$ 是升降舵、襟副翼和方向舵偏角; $[\beta_M, \Omega, XFL]$ 是发动机短舱倾转角,旋翼转速和襟翼偏转角.

2 变精度粗糙集-OMELM故障诊断算法

变精度粗糙集-OMELM故障诊断方法的算法流程如图2所示。

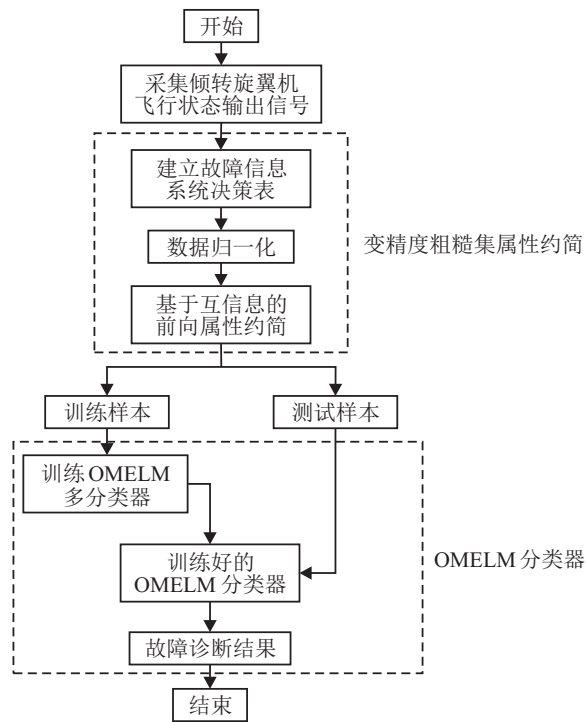


图2 故障诊断算法流程

算法步骤如下。

Step 1: 采集带噪的倾转旋翼机的飞行状态输出信号;

Step 2: 利用变精度粗糙集对输出信号提取故障特征;

Step 3: 将特征提取后的总样本分为训练样本和测试样本, 基于训练样本学习训练OMELM分类器;

Step 4: 用测试样本检验OMELM分类器的正确性;

Step 5: 将实测故障信号经变精度粗糙集属性约简后, 输入训练好的OMELM多分类器中进行故障诊断, 分类器的输出即为该信号的故障类型。

该算法主要包括两个关键部分: 变精度粗糙集属性约简和OMELM故障分类。后文将详细说明这两大部分。

2.1 变精度粗糙集属性约简

单纯地将变精度粗糙集用于故障诊断中, 大致需要3个步骤: 连续条件属性的离散化、条件属性的约简和诊断规则的获取。由于以下2个原因, 仅需要重点研究变精度粗糙集中的属性约简。

1) 采集倾转旋翼机飞行状态的多变量输出故障信号, 由采集到的样本数据特性可知, 条件属性值均为量化值, 即无数值型属性也无字符型属性, 因此不需要对条件属性进行离散化处理;

2) 优化极限学习机对约简的样本属性特征可以进行快速准确地训练学习, 并将学习后得到的规则用以多故障分类, 因此不需要获取变精度粗糙集中的诊断规则。

信息论中的熵信息能够更加全面地度量知识的不确定性, 揭示了知识粗糙性的实质是其所含信息的多少, 使人们更容易理解知识的本质^[25]。从熵信息的角度研究属性约简, 可以获得高效的属性约简算法。文献^[26]在设计属性约简算法时, 选择基于最小描述长度原则理论的信息熵和条件熵之和的熵度量方法, 而文献^[27]认为该方法不适合用在航空发动机故障诊断中, 从而引入互信息的度量方法。本文根据变精度粗糙集的基本理论^[25]和文献^[27], 借鉴变精度粗糙集的思想, 定义了一种新的变精度粗糙熵, 从信息论中互信息增量的角度定义了属性重要性, 在此基础上提出了基于互信息的前向添加属性约简算法, 并在求核属性集时, 引入变精度粗糙熵修正系数。

假设1 倾转旋翼机输出的多变量飞行状态条件属性的数目为 m , 正常及故障情况下采集的总样本数为 n , 第 i 个样本为 x_i 。

定义1^[24] 故障信息决策系统 T 可以表示为

$$T = (U, A, f). \quad (4)$$

其中: 论域 $U = \{x_1, x_2, \dots, x_n\}$ 是样本对象的集合; 属性集合 A 可以分为飞行状态条件属性集 $C = \{s_1, s_2, \dots, s_m\}$ 和故障类型决策属性集 $D = \{d_1, d_2, \dots, d_n\}$, 并有 $A = C \cup D$, 且 $C \cap D = \emptyset$; 故障信息函数 $f = \{x | x \in R \text{ 且 } x = g_{ij}\}$, $i = 1, 2, \dots, n, j = 1, 2, \dots, m$, g_{ij} 为第 i 个样本对象的第 j 个条件属性值。

上述定义的 T 也可以表示为一张二维决策表, 如表2所示。

表2 故障信息系统决策表 T

U	C				D
	s_1	s_2	\dots	s_m	
x_1	g_{11}	g_{12}	\dots	g_{1m}	d_1
x_2	g_{21}	g_{22}	\dots	g_{2m}	d_2
\vdots	\vdots	\vdots	\ddots	\vdots	\vdots
x_n	g_{n1}	g_{n2}	\dots	g_{nm}	d_n

假设2 设 $Q \subset C$, Q 和 D 对论域 U 的划分分别为 $P(I_Q) = \{X_1, X_2, \dots, X_s\}$ 和 $P(I_D) = \{Y_1, Y_2, \dots, Y_t\}$, $1 \leq i \leq s, 1 \leq j \leq t$ 。

定义2 已知 $T, Q \subset C$, 近似精度因子 $\beta \in (0.5, 1]$, 则变精度粗糙熵 H_β^{VPRS} 定义为

$$H_\beta^{\text{VPRS}}(Q \rightarrow D) = H_\beta^{\text{con}}(Q \rightarrow D) + H_\beta^{\text{inc}}(Q \rightarrow D) = \sum_{i \leq c} \frac{|X_i^{\text{VPRS}}|}{|U|} \log_2 \frac{|U|}{|X_i^{\text{VPRS}}|} + \frac{|U/V_0^{\text{VPRS}}|}{|U|} \log_2 |U|, \quad (5)$$

其中 $H_\beta^{\text{con}}(Q \rightarrow D)$ 和 $H_\beta^{\text{inc}}(Q \rightarrow D)$ 分别为一致规则集合和不一致规则集合的不确定度. 变精度粗糙集的正域 $V_0^{\text{VPRS}} = X_1^{\text{VPRS}} \cup \dots \cup X_c^{\text{VPRS}}, c \leq s$.

对于 $\forall i \leq s$, 当且仅当 $\frac{|X_i^{\text{VPRS}}|}{|X_i|} \geq \beta$ 时, $X_i^{\text{VPRS}} = X_i \cap Y_{r^*} \subseteq V_0^{\text{VPRS}}$, 其中 $|X_i \cap Y_{r^*}| \geq |X_i \cap Y_j|$.

因为借鉴了变精度粗糙集^[25]的思想, $H_\beta^{\text{VPRS}}(Q \rightarrow D)$ 具有一定的噪声容忍度, 可以兼顾不一致性和随机性, 所以不确定性量度有更佳的性质. $H_\beta^{\text{VPRS}}(Q \rightarrow D)$ 越大, 规则集合的不确定度越大, 当 $H_\beta^{\text{VPRS}}(Q \rightarrow D)$ 取最大值 $\log_2 |U|$ 时, 规则集合的不确定度达到最大.

定义 3^[25] 已知 $T, B \subset C$, 则在 B 中添加一个属性 $s \in C$ 之后, 互信息的增量 ΔI 为

$$\Delta I = I(B \cup \{s\}; D) - I(B; D) = H(D|B) - H(D|B \cup \{s\}). \quad (6)$$

其中: $I(x; y)$ 表示 x, y 的互信息; $H(y|x)$ 表示已知 x 时, y 的条件熵.

互信息增量 ΔI 变化的大小可以反映条件属性对决策属性的重要度. 增量越大, 说明在已知属性 B 的条件下, 属性 s 对决策 D 越重要, 为此可以根据 ΔI 度量 s 的属性重要性.

定义 4 已知 $B \subset C$, 则对于任意属性 $s \in C - B$ 的重要性 $\text{SGF}_\beta^{\text{VPRS}}(s, B, D)$ 定义为

$$\begin{aligned} \text{SGF}_\beta^{\text{VPRS}}(s, B, D) = & H_\beta^{\text{VPRS}}(D|B) - H_\beta^{\text{VPRS}}(D|B \cup \{s\}) = \\ & H_\beta^{\text{VPRS}}(B \rightarrow D) - H_\beta^{\text{VPRS}}(B \cup \{s\} \rightarrow D). \end{aligned} \quad (7)$$

基于互信息的前向添加属性约简算法是以故障信息系统 T 的决策表核属性集为起点, 以属性重要性 $\text{SGF}_\beta^{\text{VPRS}}$ 为启发式信息, 逐步选择最重要的属性添加到核属性集中, 直到互信息 $I(B; D)$ 与 $I(C; D)$ 相等. 在求核属性集时, $H_\beta^{\text{VPRS}}(Q \rightarrow D)$ 通常是一个非整的正实数. 因此, 对于任意的 $Q' \subset Q$, 引入变精度粗糙修正系数 $\varepsilon \in [0.95, 1]$, 若 $H_\beta^{\text{VPRS}}(Q' \rightarrow D)$ 满足

$$\frac{H_\beta^{\text{VPRS}}(Q \rightarrow D)}{H_\beta^{\text{VPRS}}(Q' \rightarrow D)} \geq \varepsilon, \quad (8)$$

则可以认为 $H_\beta^{\text{VPRS}}(Q' \rightarrow D)$ 等于 $H_\beta^{\text{VPRS}}(Q \rightarrow D)$.

具体的算法步骤如下.

输入: 故障信息系统 $T = (U, A, f)$, 变精度粗糙修正系数 $\varepsilon \in [0.95, 1]$, 变精度因子 $\beta \in (0.5, 1]$;

输出: 条件属性 C 的一个相对约简 B .

Step 1: 为了消除由变量量纲的不同带来的一些不合理影响, 将 C 中变量标准化, 即

$$s_i^* = \frac{s_i - E(s_i)}{D(s_i)}, i = 1, 2, \dots, m. \quad (9)$$

Step 2: 计算 $I(C; D)$.

Step 3: 求取 C 的 D 核 $\text{CORE}_D(C)$.

Step 3.1: $i = 1$, 令 $Y = C, \text{CORE}_D(C) = \emptyset$;

Step 3.2: 令 $Z = H_\beta^{\text{VPRS}}(C \rightarrow D)$;

Step 3.3: 任取 $y \in Y, Z' = H_\beta^{\text{VPRS}}(C - \{y\} \rightarrow D)$;

Step 3.4: 如果 $Z/Z' \geq \varepsilon$, 则 $\text{CORE}_D(C) = \text{CORE}_D(C) \cup \{y\}$;

Step 3.5: $Y = Y - \{y\}$;

Step 3.6: $i = i + 1$, 若 $i > m$, 则终止, 否则转入 **Step 3.3**.

Step 4: 求取 C 的属性约简 B .

Step 4.1: 令 $B = \text{CORE}_D(C)$;

Step 4.2: 对 $s_i^* \in C - B, 1 \leq i \leq |C - B|$, 计算 $\text{SGF}_\beta^{\text{VPRS}}(s_i^*, B, D)$;

Step 4.3: 取

$$\text{SGF}_\beta^{\text{VPRS}}(s_r^*, B, D) = \max_{i=1}^{|C-B|} \text{SGF}_\beta^{\text{VPRS}}(s_i^*, B, D),$$

若有多个属性都达到最大值, 则从中选取一个与 B 组合数最少的属性作为 s_r^* , 令 $B = B \cup \{s_r^*\}$;

Step 4.4: 若 $I(B; D) = I(C; D)$, 转入 **Step 4.5**, 否则转入 **Step 4.2**;

Step 4.5: B 即为所求的约简属性.

2.2 优化极限学习机 OMELM 故障分类

假设 3 倾转旋翼机正常及故障情况下的故障模式共有 k 类, 每类采集的样本数为 $l_i (i = 1, 2, \dots, k)$, 训练样本数为 n_1 , 每类中选出的训练样本个数为 $l'_i (i = 1, 2, \dots, k)$, 则有 $n = \sum_{i=1}^k l_i, n_1 = \sum_{i=1}^k l'_i$.

设

$$B = [s_1^* \ s_2^* \ \dots \ s_p^*] = \begin{bmatrix} g_{11} & g_{12} & \dots & g_{1p} \\ g_{21} & g_{22} & \dots & g_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ g_{n1} & g_{n2} & \dots & g_{np} \end{bmatrix} = [s_{(1)}^* \ s_{(2)}^* \ \dots \ s_{(n)}^*]$$

为第 2.1 节变精度粗糙集约简的样本属性特征, p 为约简的条件属性个数.

定义 5 采集的样本集为

$$\mathbf{R} = \{R_1, R_2, \dots, R_k\}. \quad (10)$$

其中

$$\left\{ \begin{aligned} R_1 &= \{s_{(1)}^*, s_{(2)}^*, \dots, s_{(l_1)}^*\}; \\ R_j &= \left\{ s_{\left(\sum_{i=1}^{j-1} l_i + 1\right)}^*, s_{\left(\sum_{i=1}^{j-1} l_i + 2\right)}^*, \dots, s_{\left(\sum_{i=1}^{j-1} l_i + l_j\right)}^* \right\}, \\ & j = 2, 3, \dots, k. \end{aligned} \right.$$

且 $s_{(i)}^* \in R^p$.

对于 k 类故障, 采用优化极限学习机 OMELM 对训练样本集 Z 进行多分类. Bartlett^[28]理论指出, 前馈神经网络训练误差较小时, 网络输出权值的范数值越小, 网络具备的泛化性能越好. 据此, Huang 对传统 ELM 进行改进, 提出了 OMELM 算法. OMELM 的网络训练结构由输入层、隐含层和输出层组成, 如图 3 所示.




图3 OMELM的网络训练结构

本文将各层的功能总结如下.

1) 输入层. 输入层接收来自训练样本集 Z 的值, 节点数目与样本矢量的维数相等, 为 p 个. 第 i 个输入样本为

$$z_i = (z_{i1}, z_{i2}, \dots, z_{ip}), \quad (11)$$

其中 z_{ij} 为第 i 个样本在第 j ($j = 1, 2, \dots, p$) 个节点的输入.

2) 隐含层. 隐含层接收来自输入层及输入权值 w_{ij} 的输入, 激活函数 $K(z)$ 无限可微, 节点数目为 M , b_i ($i = 1, 2, \dots, M$) 为阈值. 其中: M 需要人工设置; w_{ij} 和 b_i 随机生成, 且在训练过程中无需调整.

3) 输出层. 输出层节点数目为 k , 与故障类型数相等. 第 i 个输出样本为

$$t_i = (t_{i1}, t_{i2}, \dots, t_{ik}), \quad (12)$$

其中 $t_{ij} = \sum_{l=1}^M \beta_{lj} K(w_{jl} \cdot z_{il} + b_l)$ 表示第 i 个样本在第 j ($j = 1, 2, \dots, p$) 个节点的输出.

$$t_{ir} = \max_{j=1}^k \{t_{ij}\}, \quad j = r. \quad (13)$$

选择输出层中输出最大者对应的故障类型为诊断结果. 如式 (13), 第 i 个样本输入到 OMELM 中, 对应的第 r 个输出即为诊断的故障类型.

OMELM 网络优化模型的数学表达式为^[21]

$$\begin{aligned} \min \quad & \frac{1}{2} \|\beta\|^2 + C \sum_{i=1}^{n_1} \xi_i. \\ \text{s.t.} \quad & t_i \beta K(z_i) \geq 1 - \xi_i; \\ & \xi_i \geq 0, \quad i = 1, 2, \dots, n_1. \end{aligned} \quad (14)$$

3 仿真结果与分析

仿真实验在 IBM 计算机 (奔腾 4, CPU 3.00 GHz, 内存 2G) 上进行, 编程环境是 Matlab R2009a.

倾转旋翼机在过渡转换时, 短舱倾转会引起飞机模型参数的扰动, 增加模型的不确定性, 导致倾转旋翼机在过渡过程中极其不稳定. 倾转旋翼机飞控系统的任务是控制飞机实现平稳的过渡. 倾转旋翼机在过渡时, 主要变化的是它的前飞速度、俯仰角以及高度等纵向参数, 因此本文主要以倾转旋翼机纵向模型为研究对象, 设计自适应神经网络鲁棒 PID 控制律, 控制结构如图 4 所示.

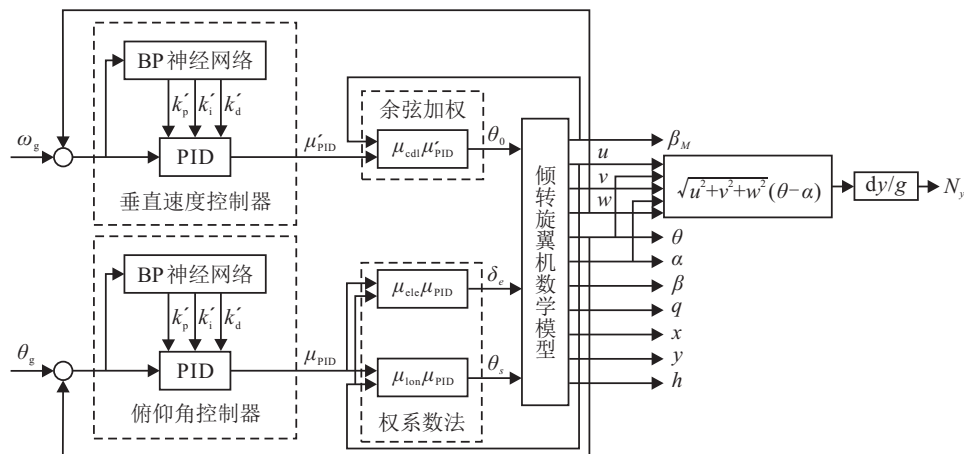


图4 过渡模式控制结构

图 4 中, μ_{coll} 、 μ_{lon} 和 μ_{ele} 分别为总距 θ_0 、纵向周期变距 θ_s 和升降舵 δ_e 的权系数, 各表达式如下:

$$\eta_{coll} = \cos(\beta_M); \quad (15)$$

$$\eta_{ele} = \begin{cases} \left(\frac{u}{u_{cr}}\right)^2, & u_{ini} \leq u < u_{cr}; \\ 1, & u \geq u_{cr}; \end{cases} \quad (16)$$

$$\eta_{lon} = \begin{cases} 1 - \left(\frac{u}{u_{cr}}\right)^2, & u_{ini} \leq u < u_{cr}; \\ 0, & u \geq u_{cr}. \end{cases} \quad (17)$$

其中: β_M 为短舱倾角; u 、 u_{ini} 和 u_{cr} 分别为前飞速度、过渡段初始速度和权值临界速度, 且当 $u \geq u_{cr}$ 时, $\mu_{lon} = 0$, $\mu_{ele} = 1$.

仿真开始时,初始高度为 1500 m,初始前飞速度为 40 m/s,倾转旋翼机由直升机模式过渡到固定翼模式,恒定倾转角速率为 7.5 deg/s,过渡时间为 12 s. 图 5 为倾转旋翼机正常平稳过渡过程以及总距突发故障时,俯仰角的输出变化情况.




图 5 俯仰角的输出变化

从图 5 可知,总距卡死在 -6° 时,俯仰角从第 3 s 开始陡然上升,而加噪之后的俯仰角输出几乎将卡死之前与之后的俯仰角微小变化掩盖. 因此,采集这样的带噪输出信号,样本数据具有一定的不确定性.

3.1 故障注入及信号采集

作动器故障注入过程如下:预先设定作动器的故障位置和故障时刻,未到达该时刻前,系统一直以正常方式运行;到达该时刻后,系统输出逐渐偏离正常位置,直至到达并保持故障位置,即

$$\begin{cases} u(t) = \delta_i(t), & t < t_{\text{fault},i}; \\ u(t) = \bar{\delta}_i(t), & t \geq t_{\text{fault},i}. \end{cases} \quad (18)$$

其中: t 表示系统(仿真)时间, $t_{\text{fault},i}$ 表示第 i 个作动器故障发生时刻, $\delta_i(t)$ 表示系统原始状态, $\bar{\delta}_i(t)$ 表示系统故障后的状态.

假设故障发生时间为 3~12 s. 考虑正常过渡和 3 种故障类型:总距卡死,卡死程度为 -6° ;纵向周期变距损伤,损伤程度为 40%;升降舵卡死,卡死程度为 -8° .

对倾转旋翼机的每个输出信号进行采样,共有

12 个输出信号(前飞速度 u , 垂直速度 w , 侧向速度 v , 俯仰角 θ , 俯仰角速度 q , 迎角 α , 侧滑角 β , 法向过载 n_y , 短舱倾角 β_M , 横向坐标 x , 纵向坐标 y , 高度 h). 设采样周期 $T_s = 12.5$ ms, 采样间隔 $10 T_s$, 在故障发生后的第 1 个采样周期开始采集数据, 正常飞行和每个故障类型均采集 35 组样本, 共采集 140 组. 为保证分类的准确性, 每类随机选取 9 组训练样本, 剩下的 26 组作为测试样本.

3.2 变精度粗糙集-OMELM 诊断结果与分析

将采集的 140 组故障样本按式 (9) 进行数据标准化, 建立故障信息系统决策表, 如表 3 所示.

表 3 故障信息系统决策表

U	C				D
	u	w	\dots	h	
1	0.4014	-0.5691	\dots	0.3403	1
2	0.3208	-0.5749	\dots	0.2233	1
\vdots	\vdots	\vdots	\ddots	\vdots	\vdots
35	0.4819	-0.5696	\dots	0.3418	1
36	-1.6905	1.5634	\dots	-1.5952	2
37	-1.7124	1.6570	\dots	-1.6830	2
\vdots	\vdots	\vdots	\ddots	\vdots	\vdots
70	-1.6933	1.8966	\dots	-1.6979	2
71	0.4376	-0.5667	\dots	0.4712	3
72	0.4568	-0.5755	\dots	0.4770	3
\vdots	\vdots	\vdots	\ddots	\vdots	\vdots
105	0.5271	-0.5595	\dots	0.4127	3
106	0.7479	-0.5665	\dots	0.8689	4
107	0.6109	-0.5832	\dots	0.9054	4
\vdots	\vdots	\vdots	\ddots	\vdots	\vdots
140	0.6705	-0.5759	\dots	1.0640	4

本文参考文献 [23] 中的方法对变精度因子 β 进行取值: β 不同时, 系统对具有分类误差 β 的对象分类质量性能不同, 如表 4 所示.

表 4 对像分类质量对比

分类质量	β		
	0.95	0.80	0.68
$\gamma(C, D, \beta)$	0.0988	0.6523	1.0000

因此, 本文选取 $\beta = 0.68$, 采用 2.1 节提出的基于互信息的前向添加属性约简算法进行属性特征约简, 步骤如下.

Step 1: 将采集的数据标准化, 见表 3;

Step 2: 互信息 $I(C; D) = 1.9856$;

Step 3: 表 3 中 C 的 D 核 $\text{CORE}_D(C) = \{q\}$;

Step 4: 约简属性 $B = \{q, \theta, \alpha\}$.

为了与其他故障诊断算法作比较, 采用辨识率来评价故障诊断的精度, 如下所示:

$$r = \frac{N_{\text{corr}}}{N_{\text{test}}} \times 100\%. \quad (19)$$

其中: r 是辨识率, N_{test} 是每类测试样本数, N_{corr} 是每类测试样本中正确诊断的数目.

对于正常飞行、总距卡死 -6° (故障1)、纵向周期变距损伤40%(故障2)和升降舵卡死 -8° (故障3),分别采用OMELM(方法1)、传统粗糙集-OMELM(方法2)和变精度粗糙集-OMELM(本文方法)对无噪和带噪情况下倾转旋翼机过渡模式作动器的故障进行诊断,诊断辨识率及诊断时间分别见表5和表6.

表5 故障诊断辨识率的对比 %

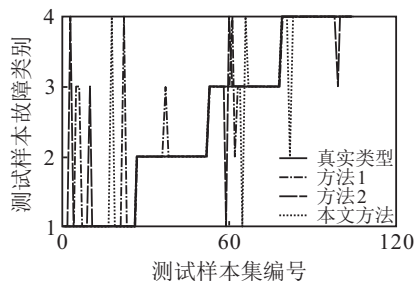
状态	方法1		方法2		本文方法	
	无噪	带噪	无噪	带噪	无噪	带噪
正常飞行	88.46	88.46	92.31	88.46	96.15	92.31
故障1	96.15	92.31	100.00	96.15	100.00	100.00
故障2	92.31	88.46	92.31	88.46	92.31	92.31
故障3	100.00	92.31	96.15	92.31	96.15	96.15
平均辨识率	94.23	90.38	95.19	91.35	96.15	95.19

表6 故障诊断时间的对比 s


情况	方法1	方法2	本文方法
无噪	1.0034	0.5271	0.3327
带噪	1.0116	0.5142	0.3652

诊断时间为训练时间加上测试时间,平均辨识率为测试样本中正确诊断的数目占测试样本总数的百分比.从表5和表6可知:无噪情况下,3种方法的平均辨识率均高于带噪情况,但诊断时间相差无几;无论是无噪还是带噪情况下的故障诊断,由于方法1的输入属性特征维数为12,没有经过属性约简,诊断时间均高于其余两种方法;3种方法均对故障1(总距卡死 -6°)的辨识率最高,对正常飞行和故障2(纵向周期变距损伤40%)的辨识率较差,但本文方法的辨识率均比其他两种方法高,诊断时间也较短.本文方法引入了变精度的思想,定义的熵有一定的噪声容忍度,有更佳的不确定性量度,约简后的特征属性比较少.

为了直观地观察、分析结果,这里以图的形式给出最终的测试集预测结果,如图6所示.



(a) 无噪情况测试结果对比



(b) 带噪情况测试结果对比

图6 测试样本集测试结果对比

测试样本集的故障类别一共有4类,表2中的决策属性D给出了每一类别的取值.图6为无噪和带噪情况下,3种方法在 $26 \times 4 = 104$ 组测试样本集上的测试结果,可以直观地看出本文方法在无噪和带噪情况下对正常飞行、故障1、故障2和故障3的样本误判个数分别为1、0、2、1和2、0、2、1.

4 结论

针对倾转旋翼机过渡转换时飞控系统作动器的故障诊断问题,借鉴变精度粗糙集和信息论中互信息增量的思想,提出了基于互信息的前向添加属性约简算法;构造OMELM多分类器对变精度粗糙集约简的样本特征属性进行故障分类.

仿真时分别采用OMELM(方法1)、传统粗糙集-OMELM(方法2)和变精度粗糙集-OMELM(本文方法)进行故障诊断,由仿真结果可知:

1) 本文方法将倾转旋翼机的12个故障输出信号约简为3个,大大减少了诊断时间.

2) 引入了变精度的思想,定义的熵有一定的噪声容忍度,有更佳的不确定性量度.从信息论互信息增量的角度定义了属性重要性,因此,本文方法的平均辨识率高于其他两种方法.

3) 在倾转旋翼机过渡转换时执行器的故障诊断中,本文方法诊断速度快、时间少、平均辨识率高,对我国未来倾转旋翼机飞控系统的故障诊断研究有一定的参考价值.

参考文献(References)

- [1] 陈恒,左晓阳,张玉琢.倾转旋翼飞机技术发展研究[J].飞行力学,2007,25(1):5-8.
(Chen H, Zuo X Y, Zhang Y Z. Tiltrotor aircraft key technology developing research[J]. Flight Dynamics, 2007, 25(1): 5-8.)
- [2] Kristi Marie Kleinhesselink. Stability and control modeling of tiltrotor aircraft[D]. Washington: Department of Aerospace Engineering, University of Maryland, 2007: 16-65.
- [3] 杨喜立,朱纪洪,黄兴李.倾转旋翼飞机建模与仿真[J].航空学报,2006,27(4):584-587.
(Yang X L, Zhu J H, Huang X L. Modeling and simulation for tiltrotor airplane[J]. Acta Aeronautica et Astronautica Sinica, 2006, 27(4): 584-587.)
- [4] 沙虹伟. Simulink中倾转旋翼机飞行力学模型研究[J].飞行力学,2012,30(5):389-397.
(Sha H W. Research on flight dynamics of tilt rotor aircraft base on Simulink[J]. Flight Dynamics, 2012, 30(5): 389-397.)
- [5] Srinivas V, Chopra I. Validation of a comprehensive aero elastic analysis for tilt-rotor aircraft[J]. J of the American

- Helicopter Society, 1998, 43(4): 333-341.
- [6] Dong Ling-hua, Yang Wei-dong, Xia Pin-qi. Multi-body aero elastic stability analysis of tilt-rotor aircraft in helicopter mode[J]. Transactions of Nanjing University of Aeronautics & Astronautics, 2006, 23(2): 161-167.
- [7] 薛立鹏, 张呈林. 动力学参数对倾转旋翼机气弹稳定性的影响[J]. 南京航空航天大学学报, 2011, 43(1): 7-12.
(Xue L P, Zhang C L. Effects of dynamics parameters on tilt-rotor aeroelastic stability[J]. J of Nanjing University of Aeronautics & Astronautics, 2011, 43(1): 7-12.)
- [8] Rysdyk R T, Calise A J. Adaptive model inversion flight control for tilt-rotor aircraft[J]. J of Guidance, Control, and Dynamics, 1999, 22(3): 402-407.
- [9] Eric L H. Active and passive techniques for tilt-rotor[D]. Pennsylvania: College of Engineering, Pennsylvania State University, 2005: 127-143.
- [10] 陈超. 倾转旋翼机过渡过程姿态控制仿真研究[D]. 南京: 南京航空航天大学自动化学院, 2010: 11-64.
(Chen C. Simulation and research on attitude control in transition of tiltrotor aircraft[D]. Nanjing: College of Automatic Engineering, Nanjing University of Aeronautics and Astronautic, 2010: 11-64.)
- [11] Sewook Park, Jonghee Bae, Youdan Kim. Fault tolerant flight control system for the tilt-rotor UAV[J]. J of the Franklin Institute, 2013, 350(9): 2535-2559.
- [12] Frank P M. Fault diagnosis in dynamics systems using analytical and knowledge-based redundancy: A survey and some new results[J]. Automatica, 1990, 26(3): 459-474.
- [13] Youmin Zhang, Jin Jiang. Bibliographical review on reconfigurable fault-tolerant control systems[J]. Annual Reviews in Control, 2008, 32(2): 229-252.
- [14] 周东华, 胡艳艳. 动态系统的故障诊断技术[J]. 自动化学报, 2009, 35(6): 748-758.
(Zhou D H, Hu Y Y. Fault diagnosis techniques for dynamic systems[J]. Acta Automatica Sinica, 2009, 35(6): 748-758.)
- [15] 李晗, 萧德云. 基于数据驱动的故障诊断方法综述[J]. 控制与决策, 2011, 26(1): 1-9.
(Li H, Xiao D Y. Survey on data driven fault diagnosis methods[J]. Control and Decision, 2011, 26(1): 1-9.)
- [16] Ding S, Zhang P, Frank P M. Application of probabilistic robustness technique to the fault detection systems design[C]. Proc of IEEE Conf on Decision and Control. Hawaii: IEEE, 2003: 972-977.
- [17] Huang Guang-Bin, Zhu Qin-Yu, Siew Chee Kheong. Extreme learning machine: Theory and applications[J]. Neuro-computing, 2006, 70(1/2/3): 489-501.
- [18] Liang Nanying, Huang Guangbin, Saratchandran P, et al. A fast and accurate online sequential learning algorithm for feedforward networks[J]. IEEE Trans on Neural Networks, 2006, 17(6): 411-423.
- [19] Huang Guang-Bin, Chen I. Convex incremental extreme learning machine[J]. Neurocomputing, 2007, 70: 3056-3062.
- [20] Huang Guang-Bin, Chen I. Enhanced random search based incremental extreme learning machine[J]. Neurocomputing, 2008, 71: 3060-3068.
- [21] HUANG Guang-bin, DING Xiaojian, ZHOU Hong-ming. Optimization method based extreme learning machine for classification[J]. Neurocomputing, 2010, 74(1/2/3): 155-163.
- [22] 尹刚, 张英堂, 李志宁, 等. 基于在线半监督学习的故障诊断方法研究[J]. 振动工程学报, 2012, 25(6): 637-642.
(Yin G, Zhang Y T, Li Z N, et al. Fault diagnosis method based on online semi-supervised learning[J]. J of Vibration Engineering, 2012, 25(6): 637-642.)
- [23] 索中英, 朱林户, 吴华, 等. 基于变精度粗糙集的航空发动机故障诊断[J]. 航空动力学报, 2008, 23(9): 1842-1846.
(Suo Z Y, Zhu L H, Wu H, et al. Aeroengine fault diagnosis based on variable precision rough sets[J]. J of Aerospace Power, 2008, 23(9): 1842-1846.)
- [24] Ziarko W. Variable precision rough set model[J]. J of Computer and System Sciences, 1993, 46(1): 39-59.
- [25] Dunsch I, Gediga G. Uncertainty measures of rough set prediction[J]. Artificial Intelligence, 1998, 106(1): 109-137.
- [26] 丛蓉, 王秀坤, 刘云飞, 等. 基于变精度粗糙信息熵的特征约简算法[J]. 控制与决策, 2009, 24(2): 297-304.
(Cong R, Wang X K, Liu Y F, et al. Algorithm of feature reduction based on variable precision rough information entropy[J]. Control and Decision, 2009, 24(2): 297-304.)
- [27] 文莹, 肖明清, 王邑. 基于信息熵属性约简的航空发动机故障诊断[J]. 仪器仪表学报, 2012, 33(7): 1773-1778.
(Wen Y, Xiao M Q, Wang Y. Aero-engine fault diagnosis based on information entropy attribute reduction[J]. Chinese J of Scientific Instrument, 2012, 33(7): 1773-1778.)
- [28] Bartlett P L. The sample complexity of pattern classification with neural networks: The size of the weights is more important than the size of the network[J]. IEEE Trans on Information Theory, 1998, 44(2): 525-536.

(责任编辑: 齐 霖)