

基于 K -均值聚类与粒子群核极限学习机的推力估计器设计*

赵姝帆¹, 李本威¹, 宋汉强², 逢珊³, 朱飞翔¹

(1. 海军航空大学 航空基础学院, 山东 烟台 264001;

2. 海军装备研究院, 上海 200436;

3. 鲁东大学 信息与电气工程学院, 山东 烟台 264025)

摘要: 鉴于航空发动机直接推力控制与健康管理工作需要高精度及高实时性的推力估计器, 提出了一种基于 K -均值聚类与粒子群优化的核极限学习机推力估计方法。采用 K -均值聚类对全工况范围内的测量数据进行聚类, 在每一个子类中, 通过核极限学习机建立推力估计器, 采用粒子群算法对核极限学习机的核参数和惩罚系数进行优化, 利用了核极限学习机稳定性好、非线性拟合能力强的特点, 实现了对发动机推力的估计。经涡扇发动机台架试车数据训练与测试表明, 本推力估计方法平均预测时间为 0.27ms, 实时性满足机载在线状态评估和直接推力控制需求, 且在估计精度上较现有方法存在一定优势。

关键词: 航空发动机; 推力估计器; K -均值聚类; 粒子群核极限学习机; 直接推力控制

中图分类号: V233.7 文献标识码: A 文章编号: 1001-4055 (2019) 02-0259-08

DOI: 10.13675/j.cnki.tjjs.180049

Thrust Estimator Design Based on K -Means Clustering and Particle Swarm Optimization Kernel Extreme Learning Machine

ZHAO Shu-fan¹, LI Ben-wei¹, SONG Han-qiang², PANG Shan³, ZHU Fei-xiang¹

(1. Aviation Foundation College, Naval Aviation University, Yantai 264001, China;

2. Naval Academy of Armament, Shanghai 200436, China;

3. College of Information and Electrical Engineering, Ludong University, Yantai 264025, China)

Abstract: In order to achieve direct thrust control and health management of aero-engines, the thrust estimator with high precision and high real-time is needed. A design method for thrust estimator was proposed, which was based on K -means clustering and particle swarm optimization (PSO) kernel extreme learning machine (KELM). Firstly, the K -means method was used to cluster the measured data in the whole behavior range. Then the thrust estimator model was established by KELM in each sub-class, and PSO was utilized to search the best kernel parameter and penalty coefficient. The stability and non-linear fitting ability of KELM were fully utilized to estimate engine thrust. Finally, the training and testing results of turbofan engine bench test data show that the average forecast time of thrust estimation method is 0.27ms, which meets the requirements of direct thrust control and airborne on-line state assessment, and it is more accurate than the existing methods.

Key words: Aero-engine; Thrust estimator; K -means clustering; Particle swarm optimization kernel extreme learning machine; Direct thrust control

* 收稿日期: 2018-01-20; 修订日期: 2018-02-24。

基金项目: 国家自然科学基金 (51505492); 山东省自然科学基金 (ZR2016FQ19); 泰山学者建设工程专项经费资助。

通讯作者: 赵姝帆, 博士生, 研究领域为航空发动机健康管理。E-mail: lightoffreedom@163.com

1 引言

航空发动机控制系统的主要任务就是保证能够有效控制发动机的推力。然而,由于飞行中推力是不可直接测得的,传统的控制方式都是基于传感器的间接推力控制,它通过控制能间接反映推力的转速、压比等测量参数,以达到间接控制推力的目的^[1]。为确保发动机安全,通常留有较大的裕度,导致发动机性能潜力无法充分发挥。如果可以快速、准确地得到发动机当前状态下的推力,一方面可采用直接推力控制,更好地发挥出发动机的性能;另一方面,还可为健康管理系统对发动机进行状态评估提供依据。因此,研究航空发动机推力估计方法具有重要的实际意义。

当前,基于数据驱动的推力估计器主要采用人工神经网络^[2](Artificial Neural Networks, ANN),支持向量机^[3](Support Vector Machine, SVM)和最近的极限学习机^[4](Extreme Learning Machine, ELM)等方法。姚彦龙等^[5]研究了基于神经网络的推力估计器,并将其应用于直接推力控制,但神经网络存在着参数选择无依据、训练时间较长、易陷入局部最优和泛化性不易控制等问题。赵永平等^[6]对支持向量机进行了多种改进并设计了推力估计器,避免了神经网络算法的缺点。极限学习机是黄广斌等^[7]于2006年提出的一种单隐层前馈神经网络,与传统的神经网络和支持向量机相比,泛化能力和学习效率都大幅提升。其基本思想是:预先设置好隐层节点数,在训练时随机生成输入权值和隐层偏置,最后通过求解隐层输出矩阵的 Moore-Penrose 广义逆得到输出层权值,完成训练,无需迭代计算。国内外研究人员非常重视极限学习机的发展,最近,李本威等^[8]使用快速寻找密度极点聚类将发动机台架测试数据分类,在每一个子类中建立基于极限学习机的推力估计器,并采用粒子群算法(Particle Swarm Optimization, PSO)对其进行优化,取得了良好的效果。然而,输入权值和隐层偏置的随机赋值会导致极限学习机的性能不稳定,泛化不理想。

在极限学习机的基础上加入核函数形成的核极限学习机(Kernel Extreme Learning Machine, KELM),具有更好的稳定性、更强大的泛化能力以及非线性映射能力。相关研究表明其非线性拟合能力优于相关的支持向量机和极限学习机^[9-10],同时,只需要设置合适的核参数就能获得稳定的性能和更高的准确度。本文提出了基于K-means聚类和优化核极限学

习机的推力估计方法,利用K-means聚类对发动机数据进行分类,在每一个子类中采用KELM设计推力估计器,并选用粒子群算法对核参数进行优化。经发动机台架试车数据训练与验证表明,推力估计器具有较高的精度和实时性。

2 核极限学习机理论与粒子群算法

2.1 标准极限学习机模型

假设有 Q 组训练样本 (X_i, t_i) ($i = 1, 2, \dots, Q$),输入向量 $X_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in R^n$,输出向量 $t_i = [t_{i1}, t_{i2}, \dots, t_{im}]^T \in R^m$,对于一个有 L 个隐层节点的单隐层神经网络可以表示为

$$\sum_{i=1}^L \beta_i g(\mathbf{W}_i \cdot X_j + b_i) = o_j, \quad j = 1, 2, \dots, Q \quad (1)$$

式中 $g(x)$ 为激活函数,可以是任意有界的非衡量连续函数^[11], $\mathbf{W}_i = [\omega_{i,1}, \omega_{i,2}, \dots, \omega_{i,n}]^T$ 为隐层节点与输入节点的权重向量, $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{im}]^T$ 为输出层节点与隐层节点的权重向量, b_i 是第 i 个隐层单元的偏置, $\mathbf{W}_i \cdot X_j$ 表示 \mathbf{W}_i 和 X_j 的内积,其结构如图1所示。

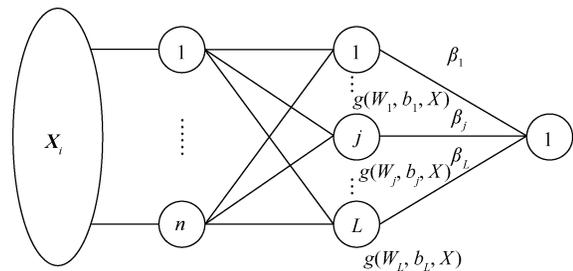


Fig. 1 Extreme learning machine structure

单隐层神经网络学习的目标是使得输出的误差最小,可以表示为

$$\sum_{j=1}^Q \|o_j - t_j\| = 0 \quad (2)$$

即存在 β_i, \mathbf{W}_i 和 b_i ,使得

$$\sum_{i=1}^L \beta_i g(\mathbf{W}_i \cdot X_j + b_i) = t_j, \quad j = 1, 2, \dots, Q \quad (3)$$

其矩阵表示为

$$H\beta = T \quad (4)$$

$$H(\mathbf{W}_1, \dots, \mathbf{W}_L, b_1, \dots, b_L, X_1, \dots, X_Q) = \begin{bmatrix} g(\mathbf{W}_1 \cdot X_1 + b_1) & \dots & g(\mathbf{W}_L \cdot X_1 + b_L) \\ \dots & \dots & \dots \\ g(\mathbf{W}_1 \cdot X_Q + b_1) & \dots & g(\mathbf{W}_L \cdot X_Q + b_L) \end{bmatrix}_{Q \times L} \quad (5)$$

$$\boldsymbol{\beta} = \begin{bmatrix} \boldsymbol{\beta}_1^T \\ \vdots \\ \boldsymbol{\beta}_L^T \end{bmatrix}_{L \times m}, \boldsymbol{T} = \begin{bmatrix} \boldsymbol{t}_1^T \\ \vdots \\ \boldsymbol{t}_Q^T \end{bmatrix}_{Q \times m} \quad (6)$$

式中 \boldsymbol{H} 是隐层节点的输出, $\boldsymbol{\beta}$ 为输出权重, \boldsymbol{T} 为期望输出。输入权值 \boldsymbol{W}_i 和偏置 b_i 均为随机给定, 只需求出输出权值 $\boldsymbol{\beta}$ 的最小二乘解, 便可完成训练^[12]。

$$\hat{\boldsymbol{\beta}} = \boldsymbol{H}^* \boldsymbol{T} = (\boldsymbol{H}^T \boldsymbol{H})^{-1} \boldsymbol{H}^T \boldsymbol{T} \quad (7)$$

式中 \boldsymbol{H}^* 为 \boldsymbol{H} 的 Moore-Penrose 广义逆。在实际工程应用中, 训练样本集一般较大, 为了减少计算量, 同时提高 ELM 的泛化能力, 通常使 $L \ll N$ 。

2.2 核极限学习机模型

在 ELM 中, 隐层输出权值 $\boldsymbol{\beta}$ 是通过输入权值 w_{ij} 和偏置 b_i 随机赋值计算得到的, 这会造成其输出产生随机波动, 稳定性和泛化能力不理想^[13]。Huang 等^[14] 结合 ELM 与 SVM 的原理, 在 ELM 中加入核函数, 提出了 KELM 算法。令

$$\boldsymbol{h}(x_i) = \left[g(\boldsymbol{W}_1 \cdot \boldsymbol{X}_i + b_1) \cdots g(\boldsymbol{W}_L \cdot \boldsymbol{X}_i + b_L) \right]$$

即有

$$\boldsymbol{H}^T \boldsymbol{H} = \begin{bmatrix} \boldsymbol{h}(x_1) \\ \vdots \\ \boldsymbol{h}(x_Q) \end{bmatrix}_{Q \times L}^T \begin{bmatrix} \boldsymbol{h}(x_1) \\ \vdots \\ \boldsymbol{h}(x_Q) \end{bmatrix}_{Q \times L} = \quad (8)$$

$$\begin{bmatrix} \boldsymbol{h}(x_1) \cdot \boldsymbol{h}(x_1) & \cdots & \boldsymbol{h}(x_1) \cdot \boldsymbol{h}(x_L) \\ \cdots & \cdots & \cdots \\ \boldsymbol{h}(x_L) \cdot \boldsymbol{h}(x_1) & \cdots & \boldsymbol{h}(x_L) \cdot \boldsymbol{h}(x_L) \end{bmatrix}$$

式中都是 $\boldsymbol{h}(x)$ 的内积形式, 可构造核函数来代替 $\boldsymbol{H}^T \boldsymbol{H}$, 即

$$\boldsymbol{\Omega}_{\text{ELM}}(i, j) = \boldsymbol{h}(x_i) \cdot \boldsymbol{h}(x_j) = K(x_i, x_j) \quad (9)$$

$$\boldsymbol{H} \boldsymbol{H}^T = \boldsymbol{\Omega}_{\text{ELM}} = \begin{bmatrix} K(x_1, x_1) & \cdots & K(x_1, x_Q) \\ \cdots & \cdots & \cdots \\ K(x_Q, x_1) & \cdots & K(x_Q, x_Q) \end{bmatrix} \quad (10)$$

$$\boldsymbol{h}(x) \boldsymbol{H}^T = \begin{bmatrix} K(x, x_1) \\ \vdots \\ K(x, x_N) \end{bmatrix} \quad (11)$$

将惩罚系数 C 加入式(7)中, 使 ELM 具有更好的稳定性和泛化性, 计算得到权值向量。

$$\boldsymbol{\beta}^* = \boldsymbol{H}^T \left(\boldsymbol{H}^T \boldsymbol{H} + \frac{\boldsymbol{I}}{C} \right)^{-1} \boldsymbol{T} \quad (12)$$

根据 $f(x) = \boldsymbol{h}(x) \boldsymbol{H}^T \left(\boldsymbol{H} \boldsymbol{H}^T + \frac{\boldsymbol{I}}{C} \right)^{-1} \boldsymbol{T}$, 核极限学习机的解写为

$$f(x) = \begin{bmatrix} K(x, x_1) \\ \vdots \\ K(x, x_N) \end{bmatrix}^T \left(\boldsymbol{\Omega}_{\text{ELM}} + \frac{\boldsymbol{I}}{C} \right)^{-1} \boldsymbol{T} \quad (13)$$

KELM 算法在 ELM 基础上引入核函数, 将随机矩阵 $\boldsymbol{H} \boldsymbol{H}^T$ 转换为核矩阵 $\boldsymbol{\Omega}$, 提高了非线性拟合能力, 同时用核映射代替随机映射, 避免了 ELM 模型输出的随机波动^[15]。核参数和惩罚系数对 KELM 算法性能会有影响, 核参数控制着核函数的作用范围, 惩罚系数控制着模型的稳定性, 为使其在推力估计中具有更优的性能, 必须对核参数和惩罚系数进行寻优。

2.3 粒子群算法

粒子群算法是一种模拟鸟群觅食行为的群智随机搜索算法^[16], 算法将待优化问题的每个解都看成解空间中的一个粒子, 每个粒子搜索过的位置都作为群的知识。粒子群随机生成并初始化之后, 每一次更新便根据个体极值和全体极值来改变各自的速度和位置。

$$v_i(t+1) = w \cdot v_i(t) + c_1 R_1 [P_{\text{best},i} - p_i(t)] + c_2 R_2 [G_{\text{best}} - p_i(t)] \quad (14)$$

$$p_i(t+1) = p_i(t) + v_i(t+1) \quad (15)$$

式中 t 为迭代次数; $v_i(t)$ 和 $p_i(t)$ 分别为粒子 i 第 t 次迭代的速度和位置; $P_{\text{best},i}$ 为粒子 i 的个体历史最优解; G_{best} 为种群历史最优解; R_1 和 R_2 为 $0 \sim 1$ 的随机数; w 为惯性权重; c_1 和 c_2 为加速因子。粒子群算法具有设置参数较少、收敛迅速及易找到全局最优解等优点^[17], 故采用 PSO 算法对 KELM 的核参数和惩罚系数进行寻优, 建立推力估计模型。

3 全包线推力估计器设计

航空发动机的主要作用是为飞行器提供推力, 传统的控制方式都是基于传感器的间接推力控制, 它通过控制能间接反映推力的转速、压比等测量参数, 以达到间接控制推力的目的^[18]。但转速与推力之间是一个复杂的非线性关系, 同时受到高度和马赫数的影响, 通过转速间接控制推力的方式往往不够精确, 为此发动机必须保留较大的安全裕度, 而使其潜能不能得到充分开发^[19]。目前, 随着计算机技术的发展, 航空发动机已普遍采用数字控制, 数字控制系统为实现直接推力控制提供了硬件基础, 推力估计器可以当作一个虚拟传感器, 通过发动机测量参数得到当前推力, 一方面实现对发动机推力的直接控制, 另一方面用于健康管理^[20], 如图 2 所示。

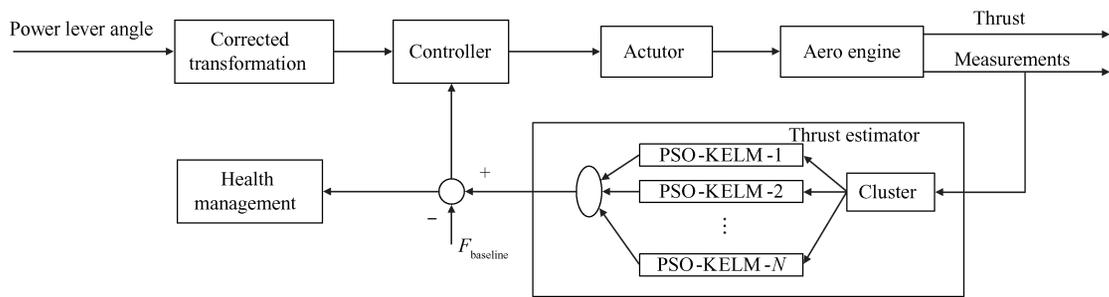


Fig. 2 Thrust estimator based on K -means clustering and PSO-KELM algorithm

推力估计的本质是寻找输入参数与推力之间的映射关系,由于航空发动机是一个高度非线性的复杂系统,随着飞行条件和工作状态的变化,该映射关系也将发生变化,因此在全包线范围内设计一个推力估计器进行估计,精度常常不太理想。本文在推力估计器的设计中,采用 K -means 方法将训练样本进行聚类,在每一个子类中结合 KELM 设计推力子估计器,模型结构如图 3 所示,并采用 PSO 算法对 KELM 的参数进行优化,得到特定的推力映射关系,实现对推力的精确估计。

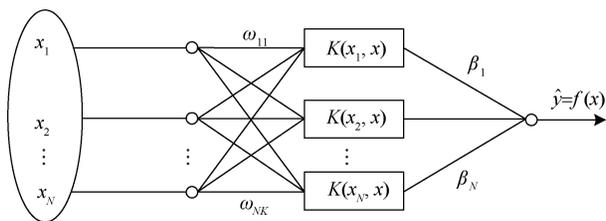


Fig. 3 Thrust estimator structure of KELM

模型中 x_i 代表用于预测模型学习的相关输入变量,这里采用与发动机推力相关的特征参数;若将前两个时刻的推力估计值作为 t 时刻的输入来体现发动机的动态性能,便可得到动态推力估计器,动态推力估计器也可采用 KELM 方法进行训练,本文仅设计稳态推力估计器。相比 ELM,无需设置隐藏层节点数,具有更好的非线性拟合能力;训练时利用 PSO 算法依照适应度函数寻找核参数和惩罚系数,从而得到最优推力估计值。

粒子群寻优核极限学习机(PSO-KELM)的具体步骤如下:

Step 1 选取包含推力值的发动机测量数据,进行数据预处理,将其归一化到 $[0, 1]$,采用机理分析与相关性分析方法确定核极限学习机的输入特征参数 $X_i = [X_{i1}, X_{i2}, \dots, X_{iN}]$ 。

Step 2 对输入特征参数采用 K -means 方法进行聚类,将测量数据分为 K 个子类,子类数目 K 由肘部

法则确定,在每个子类中划分训练数据集和测试数据集。

Step 3 在每个子类中设计基于 KELM 算法的推力估计器,选取 KELM 模型的核函数,代入训练数据集数据进行训练,并采用 PSO 算法优化得到 KELM 的核参数和惩罚系数,具体优化过程如图 4 所示。

PSO 的寻优目标为最大化适应度函数 $J_{fitness}$,即

$$J_{fitness} = \frac{1}{1 + E_{RMSE}(y, y_d)} \quad (16)$$

$$E_{RMSE}(y, y_d) = \sqrt{\frac{1}{N} \sum_{j=1}^N [y(j) - y_d(j)]^2} \quad (17)$$

式中 $E_{RMSE}(y, y_d)$ 为均方根误差, $y(j)$ 为模型的预测输出, $y_d(j)$ 为期望输出。

Step 4 采用优化得到的 KELM 模型,计算测试数据的输出推力,由评价指标判断估计效果。

在实际推力估计时,首先通过采集到的发动机参数和聚类算法将发动机当前的综合状态归属于推力估计的子类中,再采用该类中的推力子估计器估计发动机的推力。推力子估计器的划分应建立在全包线的飞行数据之上,同一包线区域的数据可能属于不同的子类,特性相近的数据都归为同一子类,因而推力子估计器模型精度较高。

4 试验分析与验证

4.1 数据预处理

为验证本文所提出的 PSO-KELM 推力估计器的有效性,采用混合排气双轴涡扇发动机在某次台架试车中的测试数据进行实例验证。台架试车期间,台架测试系统测取了某型涡扇发动机气路相关参数共 25 个,包含发动机各截面的压力、温度、燃油流量、油门杆角度、导叶角度和喷口直径等,剔除明显坏点以及推力为 0 的数据后,进行处理的数据共 11245 组。

为增强推力估计器的泛化能力,同时增加估计

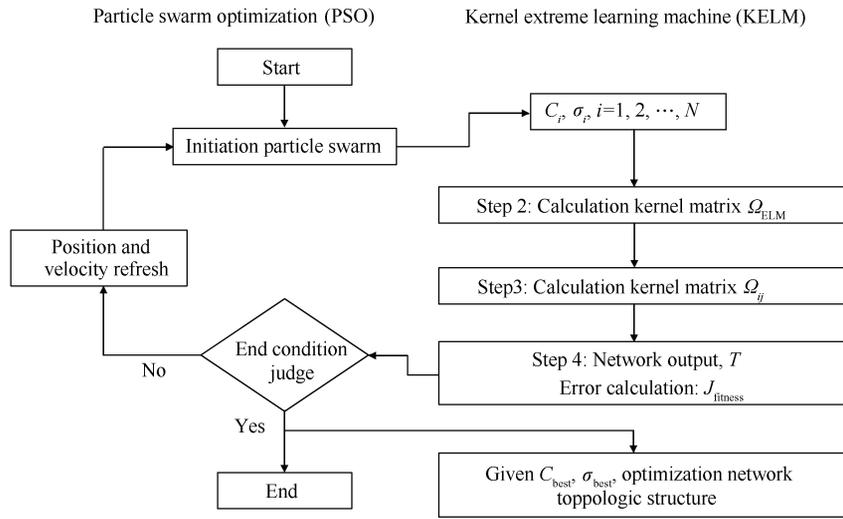


Fig. 4 PSO-KELM algorithm scheme

精度,避免出现奇异值,采用线性函数归一化(Min-Max scaling)对数据进行处理。

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (18)$$

式中 X_{norm} 为归一化后的数据, X 为原始数据, X_{max} 和 X_{min} 分别为原始数据中的最大值和最小值。

发动机台架测量参数较多,但不能将所有的测量参数都作推力估计器的输入量。由于发动机参数之间存在着相关性,太多的参数可能存在冗余,从而导致推力估计器泛化能力下降。本文选出与推力紧密相关的7个特征参数,分别为燃油流量 W_f , 进气总压 p_0^* , 高压转子换算转速 N_{2cor} , 燃烧室进口总压 p_3^* , 低压涡轮出口总压 p_4^* , 低压涡轮出口总温 T_4^* , 尾喷口喉部直径 D_{pe} 。台架试车采样频率为 50Hz, 油门杆角度与推力的变化情况如图 5 所示, 图中均为归一化后的数据, 全加力状态的推力值为 1, 最大状态推力值为 0.6, 横坐标为采集数据的序列数, 从中可以看到各稳态数据以及连接稳定状态的动态数据。

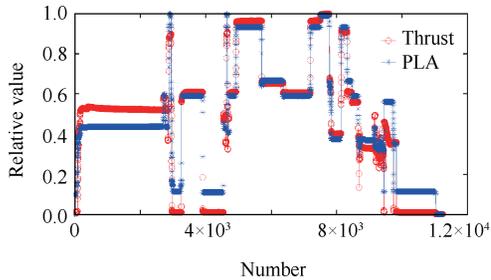


Fig. 5 Bench test data of thrust and PLA

4.2 K-means 聚类

K-means 聚类根据统计决策思想,按照最近邻聚

类的原则,对设定的 K 个类,产生 K 个质心,同一类的数据分布在质心周围,同时在统计意义上保证类间距离最大^[21]。由于发动机各部件间的共同工作关系,选出的特征参数之间相关性依然较强, Mahalanobis 距离具有在一切非奇异线性变换中保持不变的特点,采用其代替常用的 Euclidean 距离消除强相关性对聚类结果的影响,距离 $d(x_i, x_j)$ 定义为

$$V = \frac{1}{m-1} \sum_{i=1}^m (x_i - \bar{x})(x_i - \bar{x})' \quad (19)$$

$$d(x_i, x_j) = \sqrt{(x_i - x_j)' V^{-1} (x_i - x_j)} \quad (20)$$

采用选取出的 7 个特征参数进行聚类,聚类数目从 1 依次设置为 20, 计算其平均畸变程度,如图 6 所示。可以看到聚类数目在到达 4 时,再增加聚类数平均畸变程度已不再明显地下降,而减小聚类数平均畸变程度将显著上升,根据肘部法则可以确定其聚类数为 4。

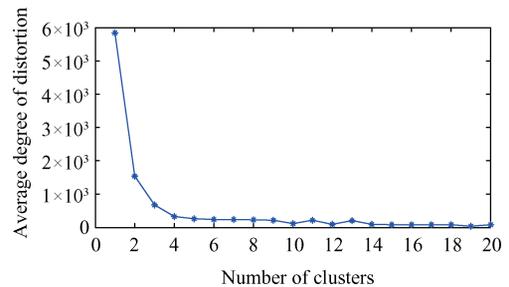


Fig. 6 Average degree of distortion

采用选取的特征参数和聚类数对试车数据进行聚类,在以相对燃油流量、高压转子相对换算转速和燃烧室入口总压构成的三维空间中,数据仅有较低程度的交叉,如图 7 所示。这些交叉主要集中在交界

处,这也符合实际情况,发动机过渡状态的数据主要集中在这一区域,发动机的推力在不断变化,同时存在一定程度的滞后,与稳定状态下的推力有一定的区别,到了7维空间中,这种交叉将更加微小。

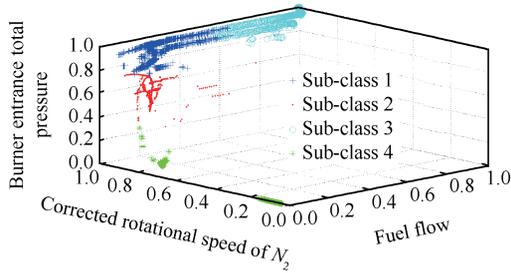


Fig. 7 Clustering distribution result

聚类之后的各子类数据分布状况如表1。从聚类结果中发现,各子类的数据大多数在时间坐标上是相连的,这是由于发动机在稳定工况下,特征参数基本保持不变;而过渡态的数据点归于相近的子类中,导致出现间隔。同时,从4个子类的推力、高压换算转速和燃油流量分布情况发现,子类1大致对应发动机的最大状态,子类2大致对应巡航状态,子类3大致对应加力状态,子类4大致对应慢车状态,这也证明了K-means聚类的正确性。在单台发动机试车数据的聚类分析中,由于台架试车方式和数据量的原因,将过渡态的数据单独聚类出来将导致聚类数目过多,当过渡态数据量足够多时便可自动将其单独聚为一类。

4.3 推力估计结果与验证

将各子类中87.5%的数据作为训练数据,12.5%的数据作为测试数据。选取径向基RBF作为KELM的核函数,采用PSO算法对惩罚系数C和核参数σ进

行优化,PSO算法的最大迭代次数为200,种群数量为50,加速因子 c_1 和 c_2 均为2,各推力子估计器的优化参数具体情况见表2。

将各子类的训练数据和测试数据分别代入对应的优化推力子估计器进行计算,分别利用均方根误差 E_{RMSE} 和相对误差 E_i 作为评价指标对估计结果进行评价。

$$E_i = \left| \frac{y - y_d}{y_d} \right| \times 100\% \quad (21)$$

从表3中可以看到,推力子估计器1,3和4中,训练数据的精度高于测试数据的精度,这是由于模型学习过训练数据,而未学习过测试数据的缘故;而子估计器2中训练数据相对误差最大值大于测试数据相对误差最大值,但这只是个别现象,主要得看相对误差平均值和标准差。测试精度从高到低,依次为子估计器3,子估计器1,子估计器2,子估计器4。子估计器3的精度最高,这是由于子类3基本对应加力状态,数据较为稳定,受到过渡态的干扰较小;前三组数据精度相差无几,而推力子估计器4误差明显偏大,这是因为子类4基本对应慢车状态,发动机推力值不稳定,和其它参数的关系不太确定,导致误差偏高。除去子类4外控制精度相对误差平均值不大于5%,其估计结果可以作为发动机健康管理的依据。

子类2中测试数据的PSO-KELM推力估计效果如图8所示,推力估计的相对误差如图9所示。可以看到,估计推力与实际推力较小,同时在稳态数据点上估计推力的精度更高。

为验证模型有效性,采用PSO-ELM和PSO-SVM进行对比,ELM选择Sigmoid激活函数,优化参数为隐

Table 1 Sub-class numbers and distribution

Sub-class	Numbers	Fuel flow average	Fuel flow STD	N_{2cor} average	N_{2cor} STD	Thrust average	Thrust STD
1	5556	0.2296	0.0571	0.9504	0.0231	0.5729	0.0642
2	1594	0.1307	0.0407	0.8772	0.0150	0.3562	0.0460
3	1639	0.9429	0.0946	0.9743	0.0143	0.9434	0.0783
4	2456	0.0190	0.0081	0.6357	0.1792	0.0096	0.0056

Table 2 Optimization results of each sub-thrust estimator

Sub-class	Numbers	Numbers of training data	Numbers of test data	σ	C
1	5556	4862	694	972.068	0.273
2	1594	1395	199	728.392	0.066
3	1639	1435	204	1031.909	0.270
4	2456	2149	307	584.062	0.137

藏层节点数 L 。SVM 采用 C-SVM, 优化参数为核参数 σ 和正则化参数 γ 。三种估计方法的输入、输出结构和参数选择完全一致, 输入均为 7 个特征参数, 输出为推力值。各方法的推力估计误差如表 4 所示。

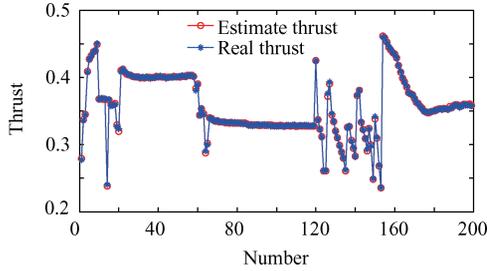


Fig. 8 Real thrust and estimate thrust of sub-class 2

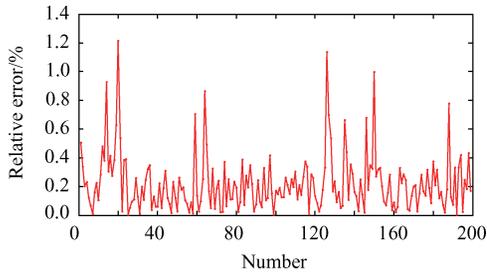


Fig. 9 Relative error of sub-class 2

由估计结果看出, 在四组子类中 PSO-KELM 方法精度最高, PSO-ELM 方法其次, PSO-SVM 方法精度最低, 进一步证明了方法的优势。KELM 和 ELM 比 SVM 更能获取全部数据的信息, 具有更好的泛化性, 而 KELM 由于在 ELM 的基础上引入了核方法, 因而比 ELM 算法具有更好非线性拟合能力和泛化能力, 提高了预测精度。在预测时间方面, SVM 平均预测时间约为 0.95ms, KELM 约为 0.27ms, ELM 接近 0ms, 三种方法都满足控制器设计所要求 2ms 的实时性指标。ELM 的预测时间最短, 这是由于 ELM 预测过程直接为矩阵相乘, 运算速度快很多, 而 KELM 的预测时间略长, 这是由于在 ELM 的基础上增加了核映射, 从而计算量增加计算时间增加, 而同时精度也提高, 综合考虑采用 KELM 算法效果更好。必须指出的是, 设计的推力估计器能有效得到额定状态的推力值, 而长时间使用会导致发动机性能衰退, 由于发动机批次性能衰退具有一定的统计学规律, 若将发动机使用时间加入输入参数并采用长时间工作的试车数据进行训练, 便可实现对非额定航空发动机的推力估计。

Table 3 Sub-thrust estimator relative error analysis

Sub-class	Data type	RMSE	Max	Medium	Min	STD	Mean
1	Training data	1.171×10^{-3}	0.025	9.48×10^{-4}	5.627×10^{-8}	1.479×10^{-3}	1.292×10^{-3}
	Test data	2.597×10^{-3}	0.040	9.44×10^{-4}	5.120×10^{-7}	2.964×10^{-3}	1.437×10^{-3}
2	Training data	8.89×10^{-4}	0.027	1.375×10^{-3}	5.735×10^{-7}	1.933×10^{-3}	1.841×10^{-3}
	Test data	1.020×10^{-3}	0.012	1.798×10^{-3}	3.831×10^{-6}	1.997×10^{-3}	2.638×10^{-3}
3	Training data	1.143×10^{-3}	0.016	6.94×10^{-4}	3.316×10^{-8}	9.88×10^{-4}	9.02×10^{-4}
	Test data	1.423×10^{-3}	0.018	7.60×10^{-4}	1.778×10^{-7}	1.571×10^{-3}	1.076×10^{-3}
4	Training data	4.76×10^{-4}	0.111	4.21×10^{-4}	7.107×10^{-6}	1.865×10^{-3}	4.369×10^{-3}
	Test data	5.09×10^{-4}	0.153	4.3×10^{-5}	1.815×10^{-5}	1.978×10^{-3}	5.177×10^{-3}

Table 4 Sub-thrust estimator relative error analysis

Style	1		2		3		4	
	Max	Mean	Max	Mean	Max	Mean	Max	Mean
PSO-KELM	0.040	1.437×10^{-3}	0.012	2.638×10^{-3}	0.018	1.076×10^{-3}	0.153	5.177×10^{-3}
PSO-ELM	0.058	2.312×10^{-3}	0.013	4.947×10^{-3}	0.057	6.052×10^{-3}	0.173	1.0274×10^{-2}
PSO-SVM	0.073	9.348×10^{-3}	0.018	6.953×10^{-3}	0.098	1.0994×10^{-2}	0.251	5.0497×10^{-2}

5 结论

本文提出了一种基于 K-means 聚类和 PSO-KELM 的推力估计方法, 并采用发动机台架试车数据进行训练与验证, 得到的结论主要有:

- (1) 通过 K-means 方法对推力估计的特征参数进行聚类, 能够有效地将发动机台架试车数据进行分类, 使其满足推力估计器的需要。
- (2) 采用 PSO 优化 KELM 的核参数和惩罚系数, 提高了推力子估计器的估计精度。克服了 ELM 因随

机矩阵造成的随机波动,同时由于核函数的加入,具有更好的非线性拟合能力和泛化能力。

(3)经台架试车数据训练与测试表明,本文设计的基于K-means聚类与PSO-KELM的推力估计器平均预测时间为0.27ms,实时性满足直接推力控制和机载在线状态评估的要求,在估计精度方面上较ELM和SVM方法有所提高。

致谢:感谢国家自然科学基金、山东省自然科学基金、泰山学者建设工程专项经费资助。

参考文献:

- [1] 李业波,李秋红,黄向华,等.航空发动机性能退化缓解控制技术[J].航空动力学报,2012,27(4):930-936.
- [2] 陈恬,孙健国.基于相关性分析和神经网络的直接推力控制[J].南京航空航天大学学报,2005,37(2):183-187.
- [3] 刘毅男,张胜修,张超.基于核方法的航空发动机推力估计器设计[J].推进技术,2013,34(6):829-835. (LIU Yi-nan, ZHANG Sheng-xiu, ZHANG Chao. Aero Engine Thrust Estimator Design Based on Kernel Method[J]. *Journal of Propulsion Technology*, 2013, 34(6): 829-835.)
- [4] Huang G B. An Insight into Extreme Learning Machines: Random Neurons, Random Features and Kernels [J]. *Cognitive Computation*, 2014, 6(3): 376-390.
- [5] 姚彦龙,孙健国.基于神经网络逆控制的发动机直接推力控制[J].推进技术,2008,29(2):249-252. (YAO Yan-long, SUN Jian-guo. Aero Engine Direct Thrust Control Based on Neural Network Inverse Control [J]. *Journal of Propulsion Technology*, 2008, 29(2): 249-252.)
- [6] 赵永平,孙健国.最小二乘支持向量回归机在发动机推力估计中的应用[J].航空动力学报,2009,24(6):1420-1425.
- [7] Huang G B, Zhu Q Y, Siew C K. Extreme Learning Machine: Theory and Applications [J]. *Neurocomputing*, 2006, 70(1-3): 489-501.
- [8] 宋汉强,李本威,张赟,等.基于聚类与粒子群极限学习机的航空发动机推力估计器设计[J].推进技术,2017,38(6):1379-1385. (SONG Han-qiang, LI Ben-wei, ZHANG Yun, et al. Aero-Engine Thrust Estimator Design Based on Clustering and Particle Swarm Optimization Extreme Learning Machine [J]. *Journal of Propulsion Technology*, 2017, 38(6): 1379-1385.)
- [9] Deng C W, Huang G B, Jia X U, et al. Extreme Learning Machines: New Trends and Applications [J]. *Science China Information Sciences*, 2015, 58(2): 1-16.
- [10] 裴飞,陈雪振,朱永利,等.粒子群优化核极限学习机的变压器故障诊断[J].计算机工程与设计,2015,(5):1327-1331.
- [11] Huang G B, Bai Z, Chi M V. Local Receptive Fields Based Extreme Learning Machine [J]. *IEEE Computational Intelligence Magazine*, 2015, 10(2): 18-29.
- [12] Huang G B, Chen L. Convex Incremental Extreme Learning Machine [J]. *Neurocomputing*, 2007, 70(16): 3056-3062.
- [13] Zhu Q Y, Qin A K, Suganthan P N, et al. Evolutionary Extreme Learning Machine [J]. *Pattern Recognition*, 2005, 38(10): 1759-1763.
- [14] Huang G B, Wang D H, Lan Y. Extreme Learning Machines: a Survey [J]. *International Journal of Machine Learning & Cybernetics*, 2011, 2(2): 107-122.
- [15] Huang G B, Zhu Q Y, Siew C K. Extreme Learning Machine: a New Learning Scheme of Feedforward Neural Networks [C]. *Budapest: IEEE International Joint Conference on Neural Networks*, 2004.
- [16] Kennedy J, Eberhart R. Particle Swarm Optimization [C]. *Killarney: IEEE International Conference on Neural Networks*, 1995.
- [17] 杨锡运,关文渊,刘玉奇,等.基于粒子群优化的核极限学习机模型的风电功率区间预测方法[J].中国电机工程学报,2015,35(S1):146-153.
- [18] 陈小磊,郭迎清,张书刚.某涡扇发动机智能应急控制系统[J].航空动力学报,2013,28(8):1897-1904.
- [19] 李秋红,孙健国,王前宇.航空发动机推力估计新方法[J].控制理论与应用,2011,28(2):185-191.
- [20] 李本威,朱飞翔,宋汉强,等.基于逆跟踪控制的航空发动机气路健康参数估计修正方法研究[J].推进技术,2016,37(5):966-973. (LI Ben-wei, ZHU Fei-xiang, SONG Han-qiang, et al. Aero-Engine Gas Path Health Parameters Estimation and Correction Method Research Based on Inverse Track Control [J]. *Journal of Propulsion Technology*, 2016, 37(5): 966-973.)
- [21] 赵永平,孙健国,王前宇,等.基于K-均值聚类和约简最小二乘支持向量回归机的推力估计器设计[J].航空动力学报,2010,25(5):1177-1183.

(编辑:梅瑛)