

文章编号: 1000-8055(2024)12-20220311-11

doi: 10.13224/j.cnki.jasp.20220311

基于颤振样本识别和颤振度分析的 颤振边界预测方法

陈鸣峰, 周 丽

(南京航空航天大学 航空航天结构力学及控制全国重点实验室, 南京 210016)

摘 要: 提出一种基于机器学习的颤振边界预测方法, 能够在风速到达亚临界状态前进行颤振速度的预测。从风洞响应信号中提取颤振信号特征, 根据飞行状态的不同建立分类模型; 接着分别在不同颤振样本下建立回归模型, 用于颤振度分析。进行预测时, 根据待测数据的分类表现, 将颤振度分析的结果进行加权计算, 得到当前风速对应的颤振度, 再计算出颤振风速。在进行机器学习的算法选择时, 使用朴素贝叶斯算法、支持向量机法、K 近邻算法等机器学习算法进行分类模型的构建, 用线性回归、支持向量机法、高斯过程回归等进行回归模型的构建。结果显示: K 近邻算法在分类算法中表现最优, 而高斯过程回归算法在回归算法中表现最优。通过试验数据的交叉验证, 该方法可以通过颤振样本识别和颤振度分析, 在离颤振边界较远时, 较为准确地预测出颤振临界速度。

关 键 词: 颤振边界预测; 机器学习; 特征提取; 颤振样本识别; 颤振度分析

中图分类号: V216.2⁺4

文献标志码: A

Flutter boundary prediction method based on flutter-sample identification and flutter-degree analysis

CHEN Mingfeng, ZHOU Li

(State Key Laboratory of Mechanics and Control for Aerospace Structures,
Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China)

Abstract: A flutter boundary prediction method based on machine learning was proposed, which can predict the flutter speed before the wind speed reaches the subcritical state. The flutter signal features were firstly extracted from the wind tunnel response signals, and the classification model was established according to different flight states. Then, regression models were established under different flutter-samples for flutter-degree analysis. To predict the flutter boundary, the results of flutter-degree analysis were weighted to obtain the flutter degree corresponding to the current wind speed according to the classification performance of the response data, and then the flutter wind speed was calculated. In the selection of machine learning algorithms, machine learning algorithms such as Naive Bayes, Support Sector Machine and k-Nearest Neighbor were performed to construct the classification model, while Linear Regression, Support Vector Machine and Gaussian Process Regression were performed to construct the regression model, which was used for flutter-sample identification and flutter-degree analysis

收稿日期: 2022-05-06

基金项目: 国家自然科学基金(52075243); 江苏省高校优势学科建设工程资助项目

作者简介: 陈鸣峰(1998—), 男, 硕士生, 主要从事飞机颤振边界预测研究。E-mail: cmf425@nuaa.edu.cn

通信作者: 周丽(1963—), 女, 教授、博士生导师, 博士, 主要从事结构健康监测研究。E-mail: lzhou@nuaa.edu.cn

引用格式: 陈鸣峰, 周丽. 基于颤振样本识别和颤振度分析的颤振边界预测方法[J]. 航空动力学报, 2024, 39(12): 20220311. CHEN Mingfeng, ZHOU Li. Flutter boundary prediction method based on flutter-sample identification and flutter-degree analysis[J]. Journal of Aerospace Power, 2024, 39(12): 20220311.

respectively. The results showed that the k-Nearest Neighbor algorithm performed best in the classification algorithm, while the Gaussian Process Regression algorithm performed best in the regression algorithm. Through cross validation of test data, this method can accurately predict the flutter speed when it was far from the flutter boundary.

Keywords: flutter boundary prediction; machine learning; feature extraction; flutter-sample identification; flutter-degree analysis

颤振是指飞机在气动力、弹性力、惯性力三者耦合作用下产生的一种危险的自激振动,飞机一旦发生颤振,会极大地影响飞机飞行的稳定性,可能会造成灾难性后果。为了避免颤振的发生,相关研究者开展了大量研究,包括颤振计算、颤振风洞试验、飞行颤振试验等,并研究出了多种颤振边界预测方法,包括峰值倒数法、速度-阻尼法、颤振裕度法等^[1]。峰值倒数法是最早被提出并应用的颤振预测方法,于 1935 年由 Von Schlippe 在德国提出^[2],其本质是利用不同速度下阻尼大小的不同获得响应的共振振幅。在风洞试验中,当风速为某一固定值时,利用频率逐渐增加的力激励飞机结构,飞机在某一频率处出现最大响应幅值(maximum response amplitude, MRA);改变风速,绘出最大响应振幅与风速的函数,振动幅值的增大意味着阻尼的减小,当振动幅值在理论上趋近于无穷大时对应的阻尼为零,此时的风速即看成颤振临界速度^[3]。速度-阻尼法是目前为止工程界使用最为普遍的一种颤振边界预测方法。由于颤振发生时,至少有某一阶模态的阻尼变为零,从而造成自激振动引发颤振,可以以阻尼作为颤振是否发生的判据;当风速达到亚临界时,通过观测各阶模态的阻尼随亚临界速度的变化直接外推到阻尼为零的点求出颤振临界速度,物理概念十分清晰^[4-5]。颤振裕度法由 Zimmerman 和 Weissenburger 提出^[6],其基于经典的弯扭二自由度机翼的运动方程,利用 Routh 判据确定系统的稳定条件,并通过采样数据获得极点信息,求解描述颤振裕度的与动压有关的二次多项式拟合外推得到颤振临界点。现有的颤振预测方法都是通过提取或构造能表征系统稳定性的参数,根据其与人速度的拟合来外推出颤振临界速度^[7-8];这不仅对参数提取的精度要求高,而且必须在达到亚临界风速后,才能有较为准确的预测值;且在颤振速度未知的情况下,只能根据工作经验判断风速是否达到了“亚临界”,难以确定预测是否有效。

为了提高颤振试验的安全性,在距离颤振临

界速度较远时,能预测出颤振临界速度,本文提出了一种基于机器学习的颤振临界速度预测方法。该方法首先识别响应信号的“颤振样本”,接着在各相关的颤振样本下对响应数据进行颤振度分析,即当前速度在各颤振样本对应的“颤振程度”,通过加权计算得出颤振度,用当前风速除以颤振度,得出预测的颤振临界速度。

该方法通过建立“颤振样本”的思想,将亚临界速度前后的响应数据通过“颤振度”的概念绑定为一个整体,用机器学习的方法建立模型,使得亚临界速度前的数据同样可以用于颤振分析中,从而通过对距离颤振临界速度较远的数据进行分析,提前对颤振临界速度进行预测,达到颤振预警的目的;另一方面,本方法从数据库理论出发,建立分类模型和回归模型,不同于利用稳定性判据关于速度的曲线拟合方法进行颤振预测,提出了另一种进行颤振预测的方法,为飞机的颤振预测方法研究提供一定的参考。

1 颤振临界速度预测方法

图 1 为基于颤振样本识别和颤振度分析的颤振临界速度预测方法的流程图。首先,对数据库中达到颤振的响应数据进行预处理,并提取其颤振相关的信号特征;对于分类模型的构建,以颤振样本为标签,将所有发生颤振的数据共同进行训练(n 组),完成颤振样本的分类;对于回归模型的构建,以颤振度为标签,每组颤振数据分别建立对应的回归模型。

以下为关于颤振度的定义:

颤振度是指颤振发生的程度,定义为结构体的当前风速 v_{current} 与真实颤振临界速度 v_{flutter} 的比值,即颤振度 $D = v_{\text{current}} / v_{\text{flutter}}$ 。当结构体不同、飞行状态不同时,颤振临界速度不同,在构建数据库时,无法直接用已知颤振速度的数据来进行未知数据的颤振边界预测,因此定义了颤振度的概念,可以将已知的数据用来预测未知的数据。对于在试验过程中达到颤振的已知数据,




图 1 基于颤振样本识别和颤振度分析的颤振临界速度预测流程图

Fig. 1 Flow chart of flutter boundary prediction based on flutter-sample identification and flutter-degree analysis

以颤振度为标签建立回归模型时;在进行未知数据颤振边界预测时,以颤振度作为预测值,从而结合当前风速来预测颤振临界速度。具体预测方法如下:

当待测数据进入预测系统时,首先进行预处理,提取出其颤振相关的信号特征进入分类模型进行颤振样本的识别,得到与各颤振样本的相似度;根据最低相似阈值选取原则,筛选出相似度较高的颤振样本及各样本对应下的相似度 $\rho_i (i=1,2,\dots,m, m < n)$,并以这 m 种颤振样本对应的回归模型分别进行颤振度分析,得出待测数据当前速度对应各颤振样本的颤振度 $d_i (i=1,2,\dots,m, m < n)$;最后,根据相似度的大小关系进行颤振度的加权计算,得出待测数据的颤振度 $D = \left(\sum_{i=1}^m \rho_i d_i \right) / \sum_{i=1}^m \rho_i (i=1,2,\dots,m, m < n)$,从而用当前速度除以加权得到的颤振度,计算出预测的颤振临界速度 $v_{\text{flutter}} = v_{\text{current}} / D$ 。

2 数据库建立及特征参数提取

以某型飞机机翼的低速风洞试验作为数据来源,如图 2 所示;试验中,对飞机飞行状态做了多次改变,进行颤振吹风试验,从而得出大量颤振响应数据;由于试验限制,共使用 3 组加速度响应传感器,分别布置在发动机垂向、发动机侧向和翼尖处;因此,对应风速下的 3 组传感器响应信号即为本研究的分析数据。

首先,取出 19 组达到颤振的风洞响应信号





图 2 某型飞机机翼的低速风洞试验

Fig. 2 Low speed wind tunnel test of an aircraft wing

并根据飞行状态对其进行分组;由于试验条件限制,风速的增加往往呈阶梯状^[9],为了保证所建立的颤振样本的稳定性,在数据处理过程中应该进行平滑化处理,去除风速过于密集的点,使风速呈现较为平滑的过渡形式,如图 3 所示,同时剔除多余的响应数据,该处理能有效去除采集到的数据中的重复意义的的数据,减少数据规模,提高计算效率;接着,去除试验中采集的颤振后的数据,这包括大于颤振临界速度的数据和风洞停车后采集的多余数据,如图 4 所示,图 4(a)中红色数据点表示大于颤振临界速度的






图 3 阶梯状风速和“平滑化”后风速

Fig. 3 Stepped wind speed and “smoothed” wind speed




图 4 多余数据剔除后风速对比图

Fig. 4 Comparison diagram of wind speed after elimination of redundant data

数据,黄色数据点表示风洞吹风停止后采集的多余数据,最终得到从开始数据采集到颤振发生时刻的响应数据;最后,为了表征颤振信息的信号特征,提取能描述危险模态能量的最大频谱幅值及其对应频率作为特征量^[10-11];通过观察最大频谱幅值关于风速的变化情况,发现其倒数能更好地呈现随着颤振临近的能量变化趋势^[12],如图 5 所示,因此将特征量调整为最大频谱幅值倒数及其对应频率,这样,在 3 组传感器信号下,共得到 6 组颤振特征量。





图 5 频谱幅值及其倒数与风速关系图

Fig. 5 Relationship between spectrum amplitude or its reciprocal and wind speed

3 颤振样本识别

在试验过程中,以机翼某些部件的主要结构参数和飞行姿态作为变量,获得了 19 组飞行状态差别较大的颤振数据;因此,取这 19 组颤振数据为 19 种颤振样本,并以机器学习的方式对其完成分类。

为了完成 19 组颤振样本的分类,共采用 4 种分类算法进行模型构建;以分类的准确度为模型评价的主要评价指标,并绘制受试者工作曲线(receiver operating characteristic, ROC),以曲线下面积(the area under the ROC curve, AUC)为副评价指标^[13-16],来进行分类模型的筛选。在进行分类模型构建时,采用 19:1 划分训练集和验证集,即用 5% 的数据进行模型验证。

3.1 分类算法

3.1.1 分类决策树

决策树可看作一个树状预测模型,它是由结点和有向分支组成的层次结构。树中包含 3 种结点:根结点、内部结点、叶子结点。决策树只有一个根结点,是全体训练数据的集合;树中每个内部结点都是一个分裂问题:指定了对实例的某个属性的测试,它将到达该结点的样本按照某个特

定的属性进行分割, 并且该结点的每一个后继分支对应于该属性的一个可能值。每个叶子结点是带有分类标签的数据集合, 即为样本所属的分类。决策树有计算速度快、计算量小和便于理解和实现的特点; 但在处理大样本集时, 易出现过拟合现象, 降低分类的准确性^[17]。

在应用分类决策树对颤振样本进行分类时, 发现当最大分裂数约为 400、采用 Gini 指数作为分裂准则时, 分类效果达到最好, 分类准确度达到 66.5%, 平均 AUC 达到 0.913。

3.1.2 朴素贝叶斯分类

朴素贝叶斯分类模型的分类过程如下^[18]:

1) 把每个数据样本都用 n 维特征向量 $X = \{a_1, a_2, \dots, a_n\}$ 来表示, 分别描述对 n 个条件属性 $\{A_1, A_2, \dots, A_n\}$ 的 n 个度量。同时假设类变量 $C = \{C_1, C_2, \dots, C_m\}$ 。

2) 给定一个未知的数据样本 X , 朴素贝叶斯分类模型会将未知的样本 X 分配给类 C_i , 当且仅当 $P(C_i|X) > P(C_j|X)$, $1 \leq i, j \leq m, j \neq i$, 这样, 把 X 归为类别 C 的过程就转化为了求解 $P(C_i|X)$ 最大值的过程。其中使 $P(C_i|X)$ 最大的类 C_i 称为最大后验假设。

3) 根据贝叶斯定理得

$$P(C_j|X) = \frac{P(X|C_j)P(C_j)}{P(X)} \quad (1)$$

由于 $P(X)$ 对于所有的类为常数, 称为证据因子, 用于使所有类的先验概率之和为 1, 因此 $P(C_i|X)$ 取最大值只需满足 $P(X|C_i)P(C_i)$ 达到最大即可。由于先验概率 $P(C_i)$, ($i = 1, 2, \dots, n$) 未知, 通常假设这些类是等概率的, 即 $P(C_1) = P(C_2) = \dots = P(C_m) = 1/m$, 这时最大化 $P(C_i|X)$ 等价于最大化 $P(X|C_i)$ 。

4) 由于朴素贝叶斯分类算法包含条件属性相互独立的假设, 计算 $P(X|C_i)$ 的过程可以表示为

$$P(X|C_i) = \prod_{k=1}^n P(a_k|C_i) \quad (2)$$

概率 $P(a_1|C_i), P(a_2|C_i), \dots, P(a_n|C_i)$ 可以由训练样本估计求出。

5) 对未知样本进行分类。对每个类 C_i , 计算 $P(a_k|C_i)P(C_i)$, 当且仅当 $P(X|C_i)P(C_i) > P(X|C_j)P(C_j)$, $1 \leq i, j \leq m, j \neq i$ 时, 样本 X 属于类别 C_i , 分类结束。

朴素贝叶斯算法有算法形式简单、可扩展性

强、性能稳定的优点; 但算法假设中属性之间条件独立, 忽视了数据变量之间的相关性, 同时没有考虑各特征属性对于分类决策的影响权重, 会影响分类的准确性。

朴素贝叶斯分类算法对颤振样本的分类效果较差, 采用 epanechnikov 核函数时分类效果相对较好, 分类准确度为 38.0%, 平均 AUC 为 0.739。

3.1.3 支持向量机法

支持向量机 (support vector machine, SVM) 法, 由 Vapnik 等人于 1995 年提出^[19]。SVM 法的目的在于寻找一个超平面 $H(d)$, 该超平面可以将训练集中的数据分开, 且与类域边界的沿垂直于该超平面方向的距离最大, 故 SVM 法亦被称为最大边缘 (Maximum Margin) 算法。在线性可分情况下, 最优超平面的构建可转化为下面的最优化问题

$$\begin{aligned} \min \phi(w) &= \|w\|^2 \text{ subject to} \\ y_i(w \cdot x_i + b) &\geq 1, \quad i = 1, 2, \dots, l \end{aligned} \quad (3)$$

其中 w 为全向量, $\phi(w)$ 为向量函数。 x_i 为第 i 个训练样本, $y_i = \pm 1$, b 为常数。

利用 Lagrange 优化方法可以把上述最优超平面问题转化为其对偶问题

$$\begin{aligned} \max W(\alpha) &= \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j (x_i \cdot x_j) \\ \text{subject to} \quad &\sum_{i=1}^l \alpha_i y_i = 0; \quad \alpha_i \geq 0, \quad i = 1, 2, \dots, l \end{aligned} \quad (4)$$

其中 α_i 为 Lagrange 乘子。式 (4) 是一个不等式约束下二次函数寻优的问题, 存在唯一解。解中只有一部分 (通常是少部分) α_i 不为 0 对应的样本就是支持向量。求解上述问题, 得到最优分类函数 $f(x) = \text{sgn}\{(\omega \cdot x) + b\} = \text{sgn}\left\{\sum_I \alpha_i y_i (x_i \cdot x) + b\right\}$, 其中 I 表示支持向量。

在线性不可分的情况下, 可以在式 (3) 条件中增加一个非负的松弛项 ζ_i , 式 (3) 变为

$$\begin{aligned} \min \phi(w) &= \frac{1}{2} \|w\|^2 + C \left[\sum_{i=1}^l \zeta_i \right] \text{ subject to} \\ y_i(\omega \cdot x_i + b) + \zeta_i &\geq 1, \quad i = 1, 2, \dots, l \end{aligned} \quad (5)$$

得到广义最优分类超平面。广义最优分类面的对偶问题与线性可分情况下几乎完全相同, 只是条件变为; $C \geq \alpha_i \geq 0, i = 1, 2, \dots, l$ 。于是, 构建

最优超平面的问题就转化为二次规划问题。

支持向量机算法最终转化为二次凸规划问题,既解决了维数灾难问题,又保证了算法的全局最优性和解的唯一性。在应用支持向量机对颤振样本进行分类时,采用高斯核函数构造的支持向量机分类精度最高,分类准确率为 72.0%,平均 AUC 为 0.975。

3.1.4 K 近邻算法

K 近邻(*k*-nearest neighbor, KNN)算法依靠距离划分未知样本类别,通过寻找多个离测试样本最邻近的训练样本,以该样本的多数类别作为最终类别,该方法有复杂度低、无需参数估计的优点,KNN 算法主要靠周围有限的邻近的样本,而不是靠判别类域的方法来确定所属类别,因此对于类域的交叉或重叠较多的待分样本集来说,KNN 算法较其他方法更合适。但是在对计算样本分类时,每一个待分类的样本要与全体已知样本计算距离,才能得到 *k* 个最邻近点,因此计算量较大;且在样本不均衡时,模型预测偏差较大^[20]。

在应用 KNN 算法对颤振样本进行分类时,当 *k* 值取 3 时,分类效果最好,分类准确率为 80.1%,平均 AUC 为 0.961。

3.2 分类模型构建

在进行数据划分时,由于数据量大,传感器采集到的每一小段数据,例如某时刻开始 0.5 s 内采集到的数据提取出的颤振信号特征都可以用来识别其颤振样本,且 19 种颤振样本类别分布均匀,因此无需进行数据不均衡处理;同时由于数据量大的原因,也降低了对分类识别精度的要求。

4 种分类算法的表现各不相同,如表 1 所示。综合两种评价指标来看,kNN 算法最优,在分类准确率达到 80.1% 的同时,平均 AUC 达到 0.961。因此选择 kNN 算法作为颤振样本识别的分类算法。

表 1 各分类算法对于颤振样本识别情况的统计结果
Table 1 Statistical results of classification algorithm for flutter-sample identification

各类算法	评价指标	
	准确度/%	AUC
分类决策树	66.5	0.913
朴素贝叶斯	38.0	0.739
支持向量机法	72.0	0.975
K 近邻算法	80.1	0.961

4 颤振度分析

颤振度对应着颤振数据中的归一化风速, $D = v_{\text{current}}/v_{\text{flutter}}$,风速 0 m/s 对应颤振度为 0,风速达到颤振临界速度对应颤振度为 1;颤振度分析,即在对应的颤振样本下,分析当前风速下的信号对应的颤振度,从而推出颤振临界速度。在建立回归模型时,共采用 4 种回归算法;以方均根平均误差(root mean squared error, RMSE)、平均绝对误差(mean absolute error, MAE)、拟合优度(R-squared)为回归模型的评价指标,来进行回归模型的筛选^[18-19]。在进行回归模型构建时,采用 19 : 1 划分训练集和验证集,即用 5% 的数据进行模型验证。由于每组数据均对应了一种“颤振样本”,即一个回归模型,因此在进行模型评价时,取各评价参数的均值作为评价指标。

4.1 回归算法

4.1.1 线性回归

线性回归(Line Regression)是利用数理统计中回归分析^[21-23],来确定两种或两种以上变量之间相互依赖的定量关系的一种统计分析方法。给定由 *d* 个属性值描述的实例 $X = (x_1, x_2, \dots, x_d)$,其中 x_i 是 *X* 属性的第 *i* 个值,多元线性回归模型为

$$f(x) = w^T X + b \tag{6}$$

式中 $w = (w_1, w_2, \dots, w_d)$ 。*b* 为误差,服从均值为 0 的正态分布。

经过机器学习得到 *w* 和 *b*,线性回归模型就确定了。线性回归模型形式简单、易于建模,运用广泛。

在应用线性回归模型进行颤振度分析时,平均 RMSE 为 0.059 6,平均 MAE 为 0.037 9,平均 R-squared 为 0.93。

4.1.2 回归决策树

回归决策树与分类决策树类似,区别在于,回归决策树的每个结点(不一定是叶子结点)都会得到一个预测值,以年龄为例,该预测值等于属于这个结点的所有人年龄的平均值。分枝时穷举每个属性值的每个阈值找最好的分割点,但衡量标准不再是最大熵,而是最小化均方差。也就是被预测出错的人数越多,错得越离谱,均方差就越大,通过最小化均方差能够找到最可靠的分枝依据。回归决策树使用最大均方差划分结点;每个结点样本的均值作为测试样本的回归预测值。

在应用回归决策树构造模型进行颤振度分析

时, 平均 RMSE 为 0.038 6, 平均 MAE 为 0.025 3, 平均 R-squared 为 0.97。

4.1.3 支持向量机法

支持向量机回归的基本思想是通过一个非线性映射 ϕ , 将数据 X 映射到高维特征空间 F , 并在这个空间进行线性回归。即

$$\begin{aligned} f(x) &= [\omega \cdot \phi(x)] + b \\ \phi: R^n &\rightarrow F, \quad \omega \in F \end{aligned} \quad (7)$$

其中 b 是阈值。这样, 在高维特征空间的线性回归便对应于低维输入空间的非线性回归, 免去了在高维空间 $\omega \cdot \phi(x)$ 的计算。由于 ϕ 是固定不变的, 因此影响 ω 的有经验风险的总和 R_{emp} , 以及使其在高维空间平坦的 $\|\omega\|^2$, 则有

$$\begin{aligned} R(\omega) &= R_{\text{emp}} + \lambda \|\omega\|^2 = \\ &\sum_{i=1}^l e[f(x_i) - y_i] + \lambda \|\omega\|^2 \end{aligned} \quad (8)$$

其中 $e(\cdot)$ 是损失函数, λ 是调整参数。最小化 $R(\omega)$ 便得到用数据点表示的 ω

$$\omega = \sum_{i=1}^l (\alpha_i - \alpha_i^*) \phi(x_i) \quad (9)$$

其中 α_i 和 α_i^* 是最小化 $R(\omega)$ 的解。将式(9)代入式(7), 得

$$\begin{aligned} f(x) &= \sum_{i=1}^l (\alpha_i - \alpha_i^*) [\phi(x_i) \cdot \phi(x)] + b = \\ &\sum_{i=1}^l (\alpha_i - \alpha_i^*) k(x_i, x) + b \end{aligned} \quad (10)$$

其中 $k(x_i, x) = \phi(x_i) \cdot \phi(x)$ 为核函数, 它是满足 Mercer 条件的任何对称的核函数对应于特征空间的点积。核函数的种类较多, 有多项式函数、RBF 函数、高斯核函数、Sigmoid 函数等。

在应用支持向量机法构造模型进行颤振度分析时, 平均 RMSE 为 0.050 2, 平均 MAE 为 0.029 8, 平均 R-squared 为 0.95。

4.1.4 高斯过程回归

高斯过程(Gaussian Process)是一种普遍存在和重要的随机过程, 其任意维有限变量的联合分布服从高斯分布^[24-25]。给定一个训练数据集 $D: \{X_i, t_i\}_{i=1}^N$, N 为数据训练样本数, X_i 为对应 t_i 时刻的向量。高斯过程中随机变量的联合概率分布函数为

$$\begin{aligned} P(t|C(X_m, X_n; \Theta), \{X_n\}) &= \\ \frac{1}{Z} \exp \left[-\frac{1}{2} (t - \mu)^T \cdot C(X_m, X_n; \Theta)^{-1} (t - \mu) \right] \end{aligned} \quad (11)$$

其中 X_m 、 X_n 分别为数据集的第 m 、 n 个向量, $C(X_m, X_n; \Theta)$ 为协方差函数的超参数, μ 为均值向量。

通过对具有高斯噪声的线性回归模型进行贝叶斯分析, 对于一个新的输入向量 X_{N+1} , 利用预测模型预测出与之相对应 t_{N+1} 的概率分布及相应的期望和方差, 可以做出 t_{N+1} 的预测。假设该预测模型有如下的函数形式 $t_n = y(X_n) + v_n$, 其中 $y(X_n)$ 是模型参数, v_n 是预测误差, 那么该模型的预测形式可以写为

$$\begin{aligned} P(T_N | \{X_n\}, A, B) &= \\ \int P(T_N | \{X_N\}, y, v) P(y|A) P(v|B) dy dv \end{aligned} \quad (12)$$

其中 $P(y|A)$ 为 $y(x)$ 在其函数空间中的事先概率分布, A 是 $P(y|A)$ 里的一组超参数, 而 $P(v|B)$ 为预测误差的事先概率分布, B 是表示误差 v 的超参数。

令 $T_N = (t_1, t_2, \dots, t_N)$, 则 t_{N+1} 的条件分布可写为

$$P(t_{N+1} | D, A, B, X_{N+1}) = \frac{P(T_{N+1} | \{X_N\}, A, B, X_{N+1})}{P(T_N | \{X_n\}, A, B)} \quad (13)$$

通过式(13)便可以做出 t_{N+1} 的预测。假设该随机过程符合高斯过程的定义, 是一个高斯过程, 那么将 t_{N+1} 的分布函数代入高斯分布公式, 经过简化可以得到

$$\begin{aligned} P(t_{N+1} | D, C(X_n, X_m; \Theta), \Theta, X_{N+1}) &= \\ \frac{1}{Z} \exp \left[-\frac{(t_{N+1} - \hat{t}_{N+1})^2}{2\sigma_{\hat{t}_{N+1}}^2} \right] \end{aligned} \quad (14)$$

其中 $\hat{t}_{N+1}$ 为期望值。因此, 根据其期望和方差可以进行预测。

在应用高斯过程回归模型进行颤振度分析时, 采用指数型核函数时得到的回归模型最优, 平均 RMSE 为 0.030 3, 平均 MAE 为 0.020 2, 平均 R-squared 为 0.98。

4.2 回归模型构建

与建立分类模型时类似的, 由于数据量大、数据随风速变化分布较均匀等原因, 无需进行数据不均衡处理。

4 种回归算法的表现各不相同, 如表 2 所示。从 3 种评价指标来看, 高斯过程回归算法表现均为最优, 平均 RMSE 为 0.030 3, 平均 MAE 为 0.020 2,

表 2 各回归算法对于颤振度分析预测情况的统计结果

Table 2 Statistical results of prediction of each regression algorithm for flutter-degree analysis

各回归算法	评价指标		
	RMSE	MAE	R-squared
线性回归	0.059 6	0.037 9	0.93
回归决策树	0.038 6	0.025 3	0.97
支持向量机	0.050 2	0.029 8	0.95
高斯过程回归	0.030 3	0.020 2	0.98

平均 R-squared 为 0.98。因此选择高斯过程回归算法作为颤振样本识别的回归算法。

5 试验数据验证

在分类模型与回归模型建立完成后,采用交叉验证的方法对本研究方法进行验证。即取出每一组颤振数据,分别进行颤振样本识别和颤振度分析,并将颤振预测的结果与实际颤振风速对比,考察本方法的可靠性。需要注意的是,在进行颤振样本识别时,须重新建立分类模型,用不包括当前待分析数据的另外 18 组颤振数据建立分类模型,来对当前数据进行颤振样本识别,之后再经过颤振度分析,预测颤振临界速度。

5.1 最低相似阈值选取原则

数据完成颤振信号特征量提取和颤振样本识别后,分类系统会根据待测数据与各颤振样本的相似度给出数理统计关系,如表 3 所示,为第 5 组颤振数据(颤振临界速度为 39 m/s)颤振度为 0.6 时进行分类后的相似度统计结果。在与待测数据相关的颤振样本中,需要选择适当的最低相似阈值,来过滤掉与待测数据相关性较差的颤振样本,如颤振样本 2、17、19。选取颤振度达到 0.4、0.6、

表 3 第 5 组试验数据分类结果统计

Table 3 Statistics of classification results of the fifth group of test data

颤振样本	相似度/%	颤振样本	相似度/%
1	11.39	11	3.96
2	0	12	6.44
3	0	13	20.79
4	0.49	14	0
6	6.93	15	0
7	38.61	16	0
8	4.46	17	3.96
9	0.99	18	0
10	1.98	19	0

0.8、0.9 的数据,考察最低相似阈值为 3%、5%、7%、9%、12%、15% 时的颤振预测情况,以此来选择最优的最低相似阈值。

取颤振度达到 0.6(对应实时风速为 $0.6 \times 39 = 23.4 \text{ m/s}$)的数据为例,当最低相似阈值取 7% 时,第 1、7、13 组的相似度大于最低相似阈值,纳入颤振预测的计算;由于数据点是离散点,没有恰好为 23.4 m/s 的风速,故取最接近此风速的数据 23.37 m/s 作为待测数据中的最大风速;分别用 1、7、13 组构建的回归模型对待测数据进行预测,分别预测出当前风速对应的颤振度为 0.505 7、0.602 4、0.662 2,根据表 3 的分类结果进行加权计算得出预测的颤振度为 $(0.505 7 \times 11.39 + 0.602 4 \times 38.61 + 0.662 2 \times 20.79) / (11.39 + 38.61 + 20.79) = 0.604 4$;则预测的颤振临界速度为 $23.37 / 0.604 4 = 38.67 \text{ m/s}$,对比真实的颤振临界风速为 39 m/s,误差为 0.83%。

以颤振预测误差为评价指标,各最低相似阈值下的颤振预测情况如表 4 所示,由表 4 可以看出,当最低相似阈值取 7% 时,在低颤振度时的颤振预测精度最高,本研究主要目的在于离颤振临界速度较远时,能对颤振速度有一个较好的预测,因此取 7% 作为最低相似阈值作为过滤标准,来进行颤振样本识别。

表 4 各最低相似阈值下的颤振预测误差统计

Table 4 Statistics of flutter prediction error under each lowest similarity threshold

颤振度	颤振预测误差/%					
	b=3	b=5	b=7	b=9	b=12	b=15
0.4	-8.60	-8.60	-7.94	-9.23	-9.23	-9.23
0.6	-1.73	-2.02	-0.83	-0.83	-3.84	-3.84
0.8	-4.12	-4.97	-5.56	-7.39	-8.34	-8.34
0.9	0.39	0.17	-0.87	-1.10	-1.25	-1.33

5.2 颤振预测误差分析

不同实时风速下的数据进入预测系统时,预测系统会给出不同的颤振度,从而结合当前风速预测出颤振临界速度,即 $v_{\text{current}} / D = v_{\text{flutter}}$ 。因此,当预测有效时,风速与颤振度的关系应该近似呈线性关系。如图 6,作出待测数据预测出的颤振度随风速的关系变化曲线。在风速大于 18 m/s 时,风速与颤振度的线性关系趋于稳定,颤振临界速度预测值在 37 m/s 上下不显著波动,颤振预测结果趋于稳定。这表明了该颤振预测系统有良




图 6 颤振度与风速的关系图

Fig. 6 Relationship between flutter-degree and wind speed

好的稳定性,同时不难看出,该一次函数的系数有其物理意义,即颤振临界速度的倒数, $1/v_{\text{flutter}}$ 。

为了考察系统的预测能力,定义最小有效预测风速:在颤振度分析中,待测数据的风速与预测的颤振度开始保持线性关系时的临界风速值,在达到该值后,认为颤振预测有效,如图 6 中所示的 A 点,15.6 m/s 即最小有效预测风速。如表 5 所示,求出该预测系统下各组颤振数据对应的最小有效预测风速。从表中可以看出,除了极个别数据组,大多组别的最小有效预测风速距离颤振临界速度有 10 m/s 或以上的裕度,说明了该预测系统能较为提前地、在距离颤振临界速度较远、结构较为安全的情况下做出颤振预警。

将各组数据以颤振度为标准,分别对颤振度达到 0.4、0.5、0.6、0.7、0.8、0.9 的数据进行颤振预测,考察其预测误差,来进行本预测系统的有效性验证,如表 6 所示。

由表 6 可以看出,对于颤振临界速度的预测,在保证最小有效预测风速的前提下,63.2%(12/19)的组别可以在距离颤振较远(颤振度小于 0.7,距离颤振临界速度大于 10 m/s)的情况下预测出误差不超过 10% 的临界风速(10% 预测误差对应风速 3~4 m/s),其中大多数预测误差在 3 m/s 以内,对于颤振的提前预警有较为明显的效果。当颤振度大于 0.7 时,误差有一定程度的增加,说明该预测系统在颤振临近时预测精度有所降低,这是由于本预测系统是基于建立颤振样本的思想进行的颤振预测,当风速距离颤振临界速度较远时,结构的振动较为稳定,对应构造的颤振样本也较为稳定,当风速距离颤振临界速度较近时,结构的振动趋于发散,对应构造的颤振样本稳定性也有所降低,因此预测精度有所降低;这说明了本预

表 5 最小有效预测风速统计情况
Table 5 Statistics of minimum effective predicted wind speed

数据组别	最小有效预测风速/(m/s)	颤振临界速度/(m/s)
1	17.7	33.3
2	27.0	38.6
3	29.2	38.6
4	28.3	38.7
5	15.6	39
6	20.0	36.4
7	17.7	35.9
8	11.7	35.8
9	25.2	35.9
10	18.1	37.6
11	13.2	35.2
12	11.1	35
13	12.1	35.1
14	26.6	36.8
15	23.8	36.4
16	26.2	37.4
17	14.9	36.5
18	22.4	37.2
19	24.3	29.7

表 6 颤振预测误差统计情况
Table 6 Statistics of flutter prediction error

组别	颤振预测误差/%					
	D=0.4	D=0.5	D=0.6	D=0.7	D=0.8	D=0.9
1			-5.37	-8.20	-5.88	-6.81
2				-4.87	-7.77	-0.44
3					-9.15	-10.94
4					-5.51	-12.53
5	-7.94	3.71	-0.83	-0.02	-5.56	-0.87
6			-4.05	4.70	-0.48	-7.52
7		-5.21	-6.60	-4.61	-5.32	-6.69
8	-7.99	-5.64	-6.91	-6.40	1.99	-5.98
9					-4.44	-5.64
10			-6.35	-7.22	-9.36	-18.02
11	-7.56	-8.24	-5.03	-6.41	-10.46	-8.26
12	-10.78	4.62	-5.95	-0.35	-4.5	-10.61
13	-8.12	-4.37	-5.4	-5.82	-7.14	-11.56
14					-8.94	-9.80
15				-6.95	-5.96	-3.36
16					-11.20	-4.07
17		-3.76	-6.35	-2.57	-6.09	-12.3
18					-10.59	-12.45
19						-3.88

注:空白位置表示该颤振度对应的速度小于最小有效预测风速。

测系统依赖于稳定的颤振样本的建立,其最佳预测风速为系统达到最小有效预测风速后且稳定性较好的风速区间。

6 结 论

本文提出了一种基于机器学习技术的颤振临界速度预测方法,不同于传统的“稳定性判据-速度”曲线拟合的方法,该方法通过建立颤振样本和进行颤振度分析的方式,提取能表征颤振特征的特征量-频谱的最大幅值倒数及对应频率,来进行机器学习并依此完成颤振临界速度的预测;通过风洞颤振试验数据的验证,有以下结论:

1) 在分类算法和回归算法的选择过程中,优化参数并选择出最优的机器学习算法: K 近邻算法和高斯过程回归算法来完成分类模型和回归模型的建立;分类准确度达到 80.1%,曲线下面积达 0.961;回归模型的平均 RMSE 为 0.030 3,平均 MAE 为 0.020 2,平均 R-squared 为 0.98。

2) 在建立颤振样本时,通过不同颤振度下的预测误差的对比,设立了最低相似阈值选取原则,提高了距离颤振临界速度较远时的预测精度。

3) 进行颤振预测时,在颤振度随风速的变化关系中,提取出能表征颤振临界速度的参数,即近似一次关系的系数 k ,其倒数即为颤振临界速度;同时,以此设立最小有效预测风速,作为颤振预测有效的判断准则,提高了预测方法的可信度和实用性。

4) 不同于传统的颤振预测方法在单组试验数据中进行参数提取、模态识别等进行颤振预测;该方法进行了大量数据的特征提取和数据建模,通过数据的颤振样本识别和颤振度分析来达到颤振预测,对数据处理的精度要求相对较低,有更强的容错能力,预测结果较为稳定。

5) 该方法能在距离颤振临界速度较远时(距离颤振速度 10 m/s 以上)完成颤振预测,且预测误差较小(不超过 3~4 m/s),可以在风洞试验中提前给出颤振预警,提高了试验的安全性,有较强的实用性。

同时,该方法有以下局限:

1) 受到数据局限性的影响,应用本方法时,数据建模的阶段需要大量达到颤振的试验数据,而颤振试验的危险性使得对于颤振数据大量的需求较难满足;较少的数据会使得数据库中的“颤振样本”较少,从而预测与库中数据相关性较差的新

数据时误差较大。

2) 该方法在颤振临近时预测精度不够高,当试验需求接近或达到颤振时,该方法没有很好的预测效果,该情况下可以考虑结合应用本方法与传统的颤振预测方法。由本方法预测出颤振风速的大致区间,达到预警目的,再由传统的颤振预测方法在颤振临近时完成相对准确的颤振预测。

3) 本研究基于低速风洞试验的数据,在试验中,取某型飞机机翼作为试验对象,一端固支,不同于实际飞行时无外部约束的飞行状态;同时风速受风洞控制,取缓慢上升的变化,不同于实际大气紊流中的飞行气流变化;因此在风洞试验中建立的颤振样本更加稳定,该方法在应用到飞行试验时效果有待探究。

综上所述,本文提出了一种新的颤振预测方法,该方法能在距离颤振临界速度较远时做出颤振预测,有效地达成提前预警的目的,能有效提高风洞试验的安全性,但在靠近颤振较近时预测不够精确,有一定的局限性,需要进一步的研究。

参考文献:

- [1] 李扬,周丽. 颤振边界预测的系统稳定性分析方法[J]. 航空动力学报, 2018, 33(4): 980-988.
LI Yang, ZHOU Li. Flutter boundary prediction research depending on system stability analysis methods[J]. Journal of Aerospace Power, 2018, 33(4): 980-988. (in Chinese)
- [2] LIND R. Flight-test evaluation of flutter prediction methods[J]. Journal of Aircraft, 2003, 40(5): 964-970.
- [3] 肖军,周新海,谷传纲,等. 二维叶栅气固耦合颤振分析[J]. 航空动力学报, 2006, 21(1): 106-111.
XIAO Jun, ZHOU Xinhai, GU Chuangang, et al. Flutter analysis of 2-D cascades under gas-solid coupled conditions[J]. Journal of Aerospace Power, 2006, 21(1): 106-111. (in Chinese)
- [4] 张伟伟,钟华寿,肖华,等. 颤振飞行试验的边界预测方法回顾与展望[J]. 航空学报, 2015, 36(5): 1367-1384.
ZHANG Weiwei, ZHONG Huashou, XIAO Hua, et al. Review and prospect of flutter boundary prediction methods for flight flutter testing[J]. Acta Aeronautica et Astronautica Sinica, 2015, 36(5): 1367-1384. (in Chinese)
- [5] IOVNOVICH M, NAHOM T, PRESMAN M, et al. Assessment of advanced flutter flight-test techniques and flutter boundary prediction methods[J]. Journal of Aircraft, 2018, 55(5): 1877-1889.
- [6] ZIMMERMAN N H, WEISSENBURGER J T. Prediction of flutter onset speed based on flight testing at subcritical speeds[J]. Journal of Aircraft, 1964, 1(4): 190-202.
- [7] 李扬,周丽,杨秉才. 基于自然激励技术的颤振边界预测[J]. 航空动力学报, 2016, 31(11): 2744-2749.
LI Yang, ZHOU Li, YANG Bingcai. Flutter boundary prediction based on natural excitation technique[J]. Journal of Aerospace Power, 2016, 31(11): 2744-2749. (in Chinese)
- [8] 仲继泽,徐自力. 基于动网格降阶算法的机翼颤振边界预测[J]. 振动与冲击, 2017, 36(4): 185-191.

- ZHONG Jize, XU Zili. Wing flutter prediction using a reduced dynamic mesh method[J]. *Journal of Vibration and Shock*, 2017, 36(4): 185-191. (in Chinese)
- [9] 邓海均, 熊波, 罗新福, 等. 连续式跨声速风洞短轴探管设计与试验[J]. *航空动力学报*, 2022, 37(6): 1171-1180.
- DENG Haijun, XIONG Bo, LUO Xinfu, et al. Design and test of short centerline probe in continuous transonic wind tunnel[J]. *Journal of Aerospace Power*, 2022, 37(6): 1171-1180. (in Chinese)
- [10] 郑宇宁. 多源不确定性条件下气动弹性系统颤振可靠性分析方法[J]. *振动与冲击*, 2021, 40(3): 54-62.
- ZHENG Yuning. Flutter reliability analysis method of aeroelastic system under multi-source uncertainty[J]. *Journal of Vibration and Shock*, 2021, 40(3): 54-62. (in Chinese)
- [11] MCNAMARA J J, FRIEDMANN P P. Flutter-boundary identification for time-domain computational aeroelasticity[J]. *AIAA Journal*, 2007, 45(7): 1546-1555.
- [12] 夏存江, 詹于游. 基于改进的 SENet 航空发动机振动预测[J]. *航空动力学报*, 2022, 37(12): 2807-2817.
- XIA Cunjiang, ZHAN Yuyou. Vibration prediction of aeroengines based on enhanced SENet model[J]. *Journal of Aerospace Power*, 2022, 37(12): 2807-2817. (in Chinese)
- [13] LIAKOS K G, BUSATO P, MOSHOU D, et al. Machine learning in agriculture: a review[J]. *Sensors*, 2018, 18(8): 2674.
- [14] JORDAN M I, MITCHELL T M. Machine learning: trends, perspectives, and prospects[J]. *Science*, 2015, 349(6245): 255-260.
- [15] 何清, 李宁, 罗文娟, 等. 大数据下的机器学习算法综述[J]. *模式识别与人工智能*, 2014, 27(4): 327-336.
- HE Qing, LI Ning, LUO Wenjuan, et al. A survey of machine learning algorithms for big data[J]. *Pattern Recognition and Artificial Intelligence*, 2014, 27(4): 327-336. (in Chinese)
- [16] KADEN M, LANGE M, NEBEL D, et al. Aspects in classification learning-review of recent developments in learning vector quantization[J]. *Foundations of Computing and Decision Sciences*, 2014, 39(2): 79-105.
- [17] 邱德红, 陈传波. 融合无监督和监督学习策略生成的多分类决策树[J]. *小型微型计算机系统*, 2004, 25(4): 555-559.
- QIU Dehong, CHEN Chuanbo. Construction of multi-classification decision tree combining unsupervised and supervised learning strategy[J]. *Journal of Chinese Computer Systems*, 2004, 25(4): 555-559. (in Chinese)
- [18] 徐平峰, 王树达, 尚来旭, 等. 基于自助法的高斯贝叶斯网结构学习[J]. *长春工业大学学报*, 2020, 41(4): 313-321.
- XU Pingfeng, WANG Shuda, SHANG Laixu, et al. Structural learning of Gaussian Bayesian networks by bootstrap[J]. *Journal of Changchun University of Technology*, 2020, 41(4): 313-321. (in Chinese)
- [19] 祁享年. 支持向量机及其应用研究综述[J]. *计算机工程*, 2004, 30(10): 6-9.
- QI Hengnian. Support vector machines and application research overview[J]. *Computer Engineering*, 2004, 30(10): 6-9. (in Chinese)
- [20] 黄铭, 孙林夫, 任春华, 等. 改进 KNN 的时间序列分析方法[J]. *计算机科学*, 2021, 48(6): 71-78.
- HUANG Ming, SUN Linfu, REN Chunhua, et al. Improved KNN time series analysis method[J]. *Computer Science*, 2021, 48(6): 71-78. (in Chinese)
- [21] HUANG Guangbin, ZHOU Hongming, DING Xiaojian, et al. Extreme learning machine for regression and multiclass classification[J]. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 2012, 42(2): 513-529.
- [22] 王惠文, 孟洁. 多元线性回归的预测建模方法[J]. *北京航空航天大学学报*, 2007, 33(4): 500-504.
- WANG Huiwen, MENG Jie. Predictive modeling on multivariate linear regression[J]. *Journal of Beijing University of Aeronautics and Astronautics*, 2007, 33(4): 500-504. (in Chinese)
- [23] KIM H J, FAY M P, YU Binbing, et al. Comparability of segmented line regression models[J]. *Biometrics*, 2004, 60(4): 1005-1014.
- [24] 何志昆, 刘光斌, 赵曦晶, 等. 高斯过程回归方法综述[J]. *控制与决策*, 2013, 28(8): 1121-1129, 1137.
- HE Zhikun, LIU Guangbin, ZHAO Xijing, et al. Overview of Gaussian process regression[J]. *Control and Decision*, 2013, 28(8): 1121-1129, 1137. (in Chinese)
- [25] SCHULZ E, SPEEKENBRINK M, KRAUSE A. A tutorial on Gaussian process regression: modelling, exploring, and exploiting functions[J]. *Journal of Mathematical Psychology*, 2018, 85: 1-16.

(编辑: 张 雪)