

DOI:10.11918/202103065

改进的输出误差法用于不稳定飞机参数辨识

汪志刚¹, 李爱军^{1,2}, 王力浩¹, 孙小锋¹

(1. 西北工业大学 自动化学院, 西安 710072; 2. 陕西省飞行控制与仿真技术重点实验室(西北工业大学), 西安 710072)

摘要:为解决输出误差法在不稳定飞机参数辨识过程中的数值发散问题以及初值依赖问题,设计了一种结合神经网络、粒子群优化算法以及 Levenberg-Marquardt 算法的系统辨识方法。首先,为解决输出误差法的数值发散问题,以神经网络拟合待辨识系统的动力学特性。不同时刻的飞行试验数据用于训练神经网络,训练好的网络可以直接对下一时刻的运动状态进行预测,从而避免对不稳定运动方程的求解。其次,基于粒子群优化算法搜索 Levenberg-Marquardt 算法中的最佳阻尼因子,并以改进的 LM 算法替代输出误差法中的高斯-牛顿算法。接下来,改进的 LM 算法与训练好的神经网络结合得到了一种新的参数辨识算法。最后,基于不稳定飞机的闭环仿真飞行试验数据对提出的算法进行了验证。研究结果表明:与传统的最小二乘法和人工稳定的输出误差法的估计结果相比,所采用的算法具有更高的估计精度;同时,所提出的算法中可以随机选取待辨识参数的初值,克服了输出误差法对参数初值的依赖。本文的研究成果可以直接用于其他不稳定非线性动力学系统辨识领域,经过修改后还可以用于其他非线性优化领域。

关键词: 不稳定飞机; 参数辨识; Levenberg-Marquardt 算法; 粒子群算法; 神经网络

中图分类号: N945.14

文献标志码: A

文章编号: 0367-6234(2022)12-0065-08

Improved output error method for parameter identification of unstable aircraft

WANG Zhigang¹, LI Aijun^{1,2}, WANG Lihao¹, SUN Xiaofeng¹

(1. School of Automation, Northwestern Polytechnical University, Xi'an 710072, China; 2. Shaanxi Province Key Laboratory of Flight Control and Simulation Technology (Northwestern Polytechnical University), Xi'an 710072, China)

Abstract: Considering the problems of numerical divergence and initial value dependence of the output error method in parameter identification of unstable aircraft, a system identification method combining neural network, particle swarm optimization algorithm, and Levenberg-Marquardt (LM) algorithm was designed. First, in order to solve the numerical divergence problem of the output error method, the neural network was utilized to approximate the dynamic characteristics of the system to be identified. The flight test data at different moments were used to train the neural network. The trained network could directly predict the motion state at the next moment, so as to avoid solving the unstable motion equation. Then, the particle swarm optimization algorithm was adopted to search the best damping factor in LM algorithm, and the improved LM algorithm was used to replace the Gauss-Newton algorithm in the output error method. Next, the improved LM algorithm was combined with the trained neural network to form a new parameter identification algorithm. Finally, the proposed algorithm was verified based on the closed-loop simulation flight test data of unstable aircraft. Research results show that compared with the estimation results of the traditional least square method and output error method with artificial stabilization, the proposed algorithm had higher estimation accuracy, and it could randomly select the initial value of the parameters to be identified, which overcomes the dependence of the output error method on the initial value of the parameters. The research results of this paper can be directly used in the identification of other unstable nonlinear dynamic systems, as well as other nonlinear optimization fields after modification.

Keywords: unstable aircraft; parameter identification; Levenberg-Marquardt algorithm; particle swarm optimization; neural network

系统辨识技术基于飞行试验中飞行运动和控制

变量的测量值,建立输入输出量间的关系。飞机系统辨识是飞机研发过程中的一个重要环节,对控制律的设计、飞行模拟器的设计和飞行包线的扩展都有重要的意义^[1]。飞机系统辨识技术分为频域辨识和时域辨识,频域辨识方法建立系统的线性模型,时域识别方法可用于提取线性模型和非线性模

收稿日期: 2021-03-17

基金项目: 航空科学基金(20180753005, 201958053003)

作者简介: 汪志刚(1996—),男,博士研究生;

李爱军(1972—),男,教授,博士生导师

通信作者: 汪志刚, wang_zhigang@mail.nwpu.edu.cn

型^[2]。目前最常用的时域飞机系统辨识方法是方程误差法以及输出误差法。方程误差法是一种直接方法,受自变量中的测量噪声影响,其估计结果是有偏差的。输出误差法基于极大似然原理,通过最小化测量值和模型输出的均方差来估计参数,其估计结果是渐近无偏的。针对稳定飞机,输出误差法是最常用的参数辨识方法之一^[3]。

不稳定飞机的主要特点为:1)飞行试验过程中需要引入控制器;2)求解不稳定飞机的模型输出时,若参数选取稍有不妥,求解过程将发散。如图 1 所示,针对不稳定飞机,系统辨识有两种可能的方法,即闭环辨识和开环辨识^[4]。经典的闭环辨识方法建模飞行员输入 δ_p 与测量值 z 之间的动力学关系,不会产生任何数值问题,因为整个系统是稳定的。此方法的局限是只能得到闭环系统的等价模型,若要从中推导出开环动力学模型,还需要精确的控制器回路动力学模型,而这通常是不容易得到的。




图 1 不稳定飞机的闭环与开环辨识

Fig. 1 Closed-loop and open-loop identification of unstable aircraft

开环辨识方法直接建模飞机舵面输入 δ_e 与测量值 z 之间的动力学关系。然而,输出误差法不能直接应用于不稳定飞机。输出误差法需要求解待辨识系统的运动方程,应用于不稳定的飞机时,会产生数值发散问题,导致参数估计过程失败^[4]。

近年来,随着神经网络学科的发展,神经网络方法逐渐应用于飞机系统辨识领域^[5-7]。Hess^[8]通过神经网络直接建模飞机的气动系数。Ghosh 等^[9]基于前向神经网络,使用 Delta 法和 Zero 法提取飞机的气动导数。Peyada 等^[10]提出了一种新的思想——将神经网络与输出误差法相结合,以神经网络代替飞机动力学模型,并采用高斯-牛顿法最小化网络输出与试验测量值间的均方差,从而进行参数估计。随后多位学者^[11-13]遵循类似的思路,应用不同的网络或者对不同的对象进行辨识。但是,这些文献都是基于高斯-牛顿法来最小化代价函数的。高斯-牛顿法具有固有的缺陷,即容易陷入局部最小值^[2]。本文基于粒子群优化对 LM (levenberg-marquardt) 方法进行了改进,以改进的 LM 算法代替高斯-牛顿法,并与神经网络方法相结合,形成一种改进的输出误差法,用于不稳定飞机的参数辨识。

1 神经网络建模

神经网络由于其强大的非线性映射能力,可以直接应用于对非线性动力学特性建模。网络输入向量选取为动力学系统第 k 时刻的输入量以及状态量,网络输出向量选取为第 $(k+1)$ 时刻的输出量,经过大量样本训练后,神经网络可以依据第 k 时刻(当前时刻)的状态和输入,对第 $k+1$ 时刻(下一时刻)的状态量进行预测。换句话说,神经网络用于近似系统的动力学特性,其作用相当于线性或者非线性动力学系统的运动方程。

本文选择了常用的 BP 神经网络^[4],其网络结构如图 2 所示。




图 2 BP 神经网络结构

Fig. 2 Structure of BP neural network

BP 神经网络分为输入层、隐含层和输出层。 W_1 、 W_2 分别为输入层到隐含层和隐含层到输出层的权重以及偏差矩阵,网络的传播遵循式(1)~(4),其中 $f(x)$ 为非线性 S 形激活函数。 x_r 为网络输入向量, x_1 、 x_2 分别为隐含层和输出层的输入向量, x_h 、 x_o 分别为隐含层和输出层的输出向量。

$$x_1 = W_1 x_r + W_{1b} \quad (1)$$

$$x_h = f(x_1) \quad (2)$$

$$x_2 = W_2 x_h + W_{2b} \quad (3)$$

$$x_o = f(x_2) \quad (4)$$

S 形激活函数选择双曲正切函数:

$$f(x) = \tanh\left(\frac{\gamma}{2}x\right) \quad (5)$$

如上所述,网络输入向量 U 选取为动力学系统 k 时刻的输入以及状态量,网络输出 Z 选取为 $k+1$ 时刻的状态向量。即

$$\begin{cases} U(k) = [u(k), x(k)] \\ Z(k+1) = [z(k+1)] \end{cases} \quad (6)$$

由于不同的试验测量数据的数量级不同,要对网络输入输出数据进行归一化,见式(7),其中 x 为原始的输入或者输出测量数据, $\bar{x}$ 为归一化之后的数据;原始数据的范围为 $(x_{\min}, x_{\max})$;其归一化范围为 $(\bar{x}_{\min}, \bar{x}_{\max})$,本文取为 $(-1, 1)$ 。

$$\bar{x} = \bar{x}_{\min} + \frac{(\bar{x}_{\max} - \bar{x}_{\min})}{(x_{\max} - x_{\min})}(x - x_{\min}) \quad (7)$$

通过连续调整网络参数 $\mathbf{W}_1$ 和 $\mathbf{W}_2$, 可以最大程度地减小网络输出和测量值之间的误差。在第 k 个离散数据点上, 将成本函数选择为第 k 步的局部输出误差, 即

$$E(k) = \frac{1}{2}[\mathbf{Z}(k) - \mathbf{x}_o(k)]^T[\mathbf{Z}(k) - \mathbf{x}_o(k)] \quad (8)$$

基于最速下降法, 网络参数 $\mathbf{W}_1$, $\mathbf{W}_2$ 通过式(9)、(10)进行调整:

$$\begin{aligned} \mathbf{W}_2(k+1) &= \mathbf{W}_2(k) - \mu \frac{\partial E(k)}{\partial \mathbf{W}_2} = \\ &\mathbf{W}_2(k) + \lambda f'(x_2)[\mathbf{z}(k) - \mathbf{x}_o(k)]\mathbf{x}_h^T(k) \end{aligned} \quad (9)$$

$$\begin{aligned} \mathbf{W}_1(k+1) &= \mathbf{W}_1(k) - \mu \frac{\partial E(k)}{\partial \mathbf{W}_1} = \\ &\mathbf{W}_1(k) + \lambda f'(x_1)\mathbf{W}_2^T f'(x_2)[\mathbf{z}(k) - \mathbf{x}_o(k)]\mathbf{x}_r^T \end{aligned} \quad (10)$$

激活函数的导数为

$$f'(x) = \frac{\gamma}{2} \left[1 - \tanh^2 \left(\frac{\gamma}{2} x \right) \right] \quad (11)$$

网络参数 $\mathbf{W}_1$, $\mathbf{W}_2$ 通过迭代更新之后, 网络将具有满意的拟合性能, 网络的最终拟合性能通过均方差 (MSE) 进行衡量, 即

$$\text{MSE} = \frac{1}{N} \sum_{k=1}^N \sum_{j=1}^{n_y} [\mathbf{z}_j(k) - \mathbf{x}_{oj}(k)]^2 \quad (12)$$

2 基于粒子群优化改进的输出误差法

本文详细陈述基于粒子群优化改进的输出误差法, 以及应用神经网络和改进的输出误差法进行参数辨识的算法流程。

2.1 粒子群优化

粒子群优化算法 (Particle swarm optimization, PSO) 最初是由 Eberhant 等^[14] 于 1995 年提出的一种基于直接搜索的优化算法。此算法基于个体粒子之间的协作与竞争, 经过数次迭代后实现复杂空间中最优解的搜索。PSO 算法是一种有记忆能力的算法, 对于低维优化问题十分有效^[15]。粒子群中的每个粒子, 都是所求优化问题的一个潜在的解。而粒子的品质由事先设定好的适应度函数来评价。假设在 n 维搜索空间中, 有 m 个粒子, 第 h 个粒子的位置表示为 $\mathbf{x}_h = (x_{h1}, x_{h2}, \dots, x_{hn})^T$, 速度表示为 $\mathbf{v}_h = (v_{h1}, v_{h2}, \dots, v_{hn})^T$, 将 $\mathbf{x}_h$ 代入适应度函数中计算出其适应度值, 以评价其优劣。 $\mathbf{p}_h$ 表示第 h 个粒子的历史最佳位置, $\mathbf{p}_g$ 表示整个粒子群经历过的最优位置。在标准粒子群算法中, 粒子的速度和位置更新

如式(13)、(14), 其中下标 d 表示 $\mathbf{v}_h$, $\mathbf{x}_h$, $\mathbf{p}_h$ 和 $\mathbf{p}_g$ 的第 d 个分量, t 为迭代次数, ω , ξ_1 , ξ_2 分别为 3 个可调参数, r_1, r_2, r_3 为 (0, 1) 之间的 3 个随机数。

$$\begin{aligned} \mathbf{v}_{hd}(t+1) &= \omega r_1 \mathbf{v}_{hd}(t) + \xi_1 r_2 (\mathbf{p}_{hd}(t) - \mathbf{x}_{hd}(t)) + \\ &\xi_2 r_3 (\mathbf{p}_{gd}(t) - \mathbf{x}_{hd}(t)) \end{aligned} \quad (13)$$

$$\mathbf{x}_{hd}(t+1) = \mathbf{x}_{hd}(t) + \mathbf{v}_{hd}(t+1) \quad (14)$$

2.2 传统输出误差算法

神经网络训练完成后, 基于 LM 算法对代价函数进行优化, 使得网络输出和测量输出的均方差最小, 从而对未知参数进行辨识。LM 算法是对高斯-牛顿法的改进, 为解释 LM 算法, 首先简要介绍基于高斯-牛顿法的传统输出误差算法^[3]。

当神经网络训练完成后, 网络可以用来代替系统的运动方程预测系统响应。基于待辨识系统的状态方程以及输出方程, 将网络输入 $\mathbf{U}(k)$ 转化为模型参数的线性或者非线性函数 $\hat{\mathbf{U}}(k, \boldsymbol{\theta})$, 则网络输出即转化成待辨识参数向量 $\boldsymbol{\theta}$ 的非线性函数, 可以将网络输出向量 $\hat{\mathbf{Y}}$ 改写为式(15)。在传统的输出误差方法中, 通过高斯-牛顿法最小化代价函数(16)来求解未知参数。其中 $\mathbf{v}$ 为模型预测 $\hat{\mathbf{Y}}$ 和测量输出 $\mathbf{Z}$ 之间的误差向量。

$$\hat{\mathbf{Y}}(k+1) = g(\hat{\mathbf{U}}(k, \boldsymbol{\theta}), \mathbf{W}_1, \mathbf{W}_2) \quad (15)$$

$$J(\boldsymbol{\theta}, \mathbf{R}) = \frac{1}{2} \sum_{i=1}^N \mathbf{v}_i^T \mathbf{R}^{-1} \mathbf{v}_i + \frac{N}{2} \ln \det(\mathbf{R}) + \frac{n_y N}{2} \ln 2\pi \quad (16)$$

式中 $\mathbf{R}$ 为协方差矩阵, $\mathbf{R}$ 的极大似然估计如式(17)所示。高斯-牛顿法通过式(18)、(19)求解未知参数。

$$\mathbf{R} = \frac{1}{N} \sum_{k=1}^N \mathbf{v}_k \mathbf{v}_k^T \quad (17)$$

$$\boldsymbol{\theta}_{i+1} = \boldsymbol{\theta}_i + \Delta \boldsymbol{\theta} \quad (18)$$

$$\mathbf{F} \Delta \boldsymbol{\theta} = -\mathbf{G} \quad (19)$$

其中 $\mathbf{F}$, $\mathbf{G}$ 分别为 Hessian 矩阵和梯度向量, 即:

$$\mathbf{F} = \sum_{k=1}^N \left[\frac{\partial \mathbf{Y}(k)}{\partial \boldsymbol{\theta}} \right]^T \mathbf{R}^{-1} \left[\frac{\partial \mathbf{Y}(k)}{\partial \boldsymbol{\theta}} \right] \quad (20)$$

$$\mathbf{G} = - \sum_{k=1}^N \left[\frac{\partial \mathbf{Y}(k)}{\partial \boldsymbol{\theta}} \right]^T \mathbf{R}^{-1} [\mathbf{Z}(k) - \mathbf{Y}(k)] \quad (21)$$

式中: $\partial \mathbf{Y}(k) / \partial \boldsymbol{\theta}$ 为输出向量 $\mathbf{Y}$ 对参数向量 $\boldsymbol{\theta}$ 的灵敏度矩阵。其中 $\partial \mathbf{Y}(k) / \partial \boldsymbol{\theta}$ 中的每一个元素通过数值差分方法计算, 如式(21)所示; $\delta \boldsymbol{\theta}_j$ 为参数向量 $\boldsymbol{\theta}$ 的第 j 个分量 $\boldsymbol{\theta}_j$ 上施加的小量扰动, k 表示第 k 时刻, 下标 h 表示输出向量 $\hat{\mathbf{Y}}$ 的第 h 个分量。

$$\left(\frac{\partial \mathbf{Y}(k)}{\partial \boldsymbol{\theta}} \right)_{hj} = \frac{\mathbf{Y}(k, \boldsymbol{\theta} + \delta \boldsymbol{\theta}_j)_h - \mathbf{Y}(k, \boldsymbol{\theta})_h}{\delta \boldsymbol{\theta}_j} = \frac{g(\hat{\mathbf{U}}(k-1, \boldsymbol{\theta} + \delta \boldsymbol{\theta}_j), \mathbf{W}_1, \mathbf{W}_2)_h - g(\hat{\mathbf{U}}(k-1, \boldsymbol{\theta}), \mathbf{W}_1, \mathbf{W}_2)_h}{\delta \boldsymbol{\theta}_j} \quad (22)$$

传统输出误差法中,输出向量 $\hat{Y}$ 通过求解运动方程获得。引入神经网络后,以网络预测替代求解运动方程。但是基于高斯-牛顿法的求解过程对未知参数的初值较为敏感,容易陷入局部极小值。常用的解决方法是依据先验信息,将未知参数初值设置在其真值附近。但是实际工程中不一定能获得未知参数的先验信息,从而限制了高斯-牛顿法的应用范围。

2.3 粒子群改进的 LM 算法

LM 算法由 Levenberg^[16] 和 Marquardt^[17] 提出,其结合了高斯-牛顿法和最速下降法,LM 算法在两个梯度方向上优化代价函数,因此包含更宽的收敛范围^[4]。与高斯-牛顿法相比,LM 算法中添加了一个非负阻尼因子 λ ,其参数迭代计算如式(23)、(24)所示,其中,Hessian 矩阵 F 和梯度向量 G 按照式(20)、(21)计算,与高斯-牛顿法一致。当阻尼因子接近于 0 时,LM 算法的性能与高斯-牛顿法一致;而当阻尼因子充分大时,LM 算法的性能接近于最速下降法。

$$\boldsymbol{\theta}_{i+1} = \boldsymbol{\theta}_i + \Delta \boldsymbol{\theta}$$

(23)

$$(\boldsymbol{F} + \lambda \boldsymbol{I}) \Delta \boldsymbol{\theta} = -\boldsymbol{G}$$

(24)

传统的 LM 算法根据代价函数的增减对阻尼因子进行某种调整,例如通过对阻尼因子乘以 10 或除以 10 以保证代价函数的下降^[4]。然而这种调整得到的阻尼因子并不是最佳的,从而限制了算法性能提升的效果。在本文中,LM 算法的每次迭代时采用粒子群算法来求解最佳阻尼因子,即,基于粒子群算法最小化代价函数(25),以确保求解的阻尼因子是局部最优的,或者说是次最优的。需要指出的是,增加粒子群算法的粒子数以及搜索次数后,还可以找到最优的阻尼因子,但是这样会增加计算代价,这是非必要的。本文设置了 20 个粒子,最多搜索 5 次。结果表明这样的设置对于改善 LM 算法的性能是足够的。

$$J(\boldsymbol{\theta}_{i+1}) = J(\boldsymbol{\theta}_i + \Delta \boldsymbol{\theta}) = J_1(\boldsymbol{\theta}_i, \lambda_i, \boldsymbol{F}, \boldsymbol{G}) = J_2(\lambda_i)$$

(25)

2.4 神经网络 LM(NN-LM) 算法流程

最终的神经网络 LM(NN-LM) 参数辨识算法包含了两部分:神经网络训练以及参数估计。整个算法的流程如图 3 所示。




图 3 神经网络 LM(NNLM) 算法流程图

Fig. 3 Flow chart of neural network LM(NNLM) algorithm

算法的求解步骤如下:

1) 从飞行试验数据中提取状态量和输入量,构成神经网络的输入向量 $U(k)$;从飞行试验数据中提取输出量,构成神经网络的输出向量 $Z(k+1)$,例如本文的应用算例中, $U(k)$, $Z(k+1)$ 分别为式(31)、(32);并按照式(9)~(11)进行网络训练。

2) 将网络输入 $U(k)$ 替换为包含飞行试验数据中状态量、输入量以及待辨识参数 θ_i 的新的输入向量 $\hat{U}(k, \theta_i)$,如下文应用算例中的式(33)。并根据神经网络前向传递式(1)~(4)(或者是式(15))进行网络预测,计算网络输出向量 $\hat{Y}(k+1)$ 。

3) 基于传统输出误差法,分别根据式(22)计算

灵敏度矩阵 $\partial Y(k)/\partial \Theta$, 式 (20) 计算 Hessian 矩阵 F , 以及式 (21) 计算梯度向量 G 。

4) 将粒子群中每个粒子的适应度函数取为代价函数 (25), 基于粒子群优化过程, 即式 (13)、(14) 求解局部最优阻尼因子 λ 。

5) 基于 LM 算法, 根据式 (23)、(24) 更新待辨识参数 Θ_i 。

重复步骤 2) ~ 5), 直至算法收敛。

3 不稳定飞机模型与仿真试验数据

本文应用了 De Havilland DHC-2 “BEAVER” 测试机^[4,18]的不稳定短周期模型。“BEAVER” 飞机的短周期状态方程为:

$$\begin{aligned}\dot{w} &= Z_w w + (U_0 + Z_q) q + Z_{\delta_e} \delta_e \\ \dot{q} &= M_w w + M_q q + M_{\delta_e} \delta_e\end{aligned}\tag{26}$$

式中: w 为纵向速度, q 为俯仰角速率, a_z 为纵向加速度, δ_e 为升降舵偏转量。

模型的观测方程为:

$$\begin{aligned}w &= w \\ q &= q \\ \dot{w} &= Z_w w + (U_0 + Z_q) q + Z_{\delta_e} \delta_e \\ \dot{q} &= M_w w + M_q q + M_{\delta_e} \delta_e \\ a_z &= Z_w w + Z_q q + Z_{\delta_e} \delta_e\end{aligned}\tag{27}$$

式中: q, w 为模型的状态变量, δ_e 为输入变量, $q, w, \dot{q}, \dot{w}$ 以及 a_z 为输出变量, U_0 为前向速度, 在仿真中 U_0 取为 44.57 m/s。

在本文的研究中, 这些模型参数构成了待辨识的未知参数向量, 即

$$\Theta = [Z_w, Z_q, Z_{\delta_e}, M_w, M_q, M_{\delta_e}]^T\tag{28}$$

式中 $Z_w, Z_q, Z_{\delta_e}, M_w, M_q, M_{\delta_e}$ 为模型参数, 其标称值见表 1。

系统矩阵 A 如式 (29) 所示, 将 U_0 和表 1 中模型参数的标称值 Θ 代入系统矩阵 A , 可计算出其两个特征值分别为 0.693 4 和 -5.825 0, 其中正的特征值对应着不稳定模态。这种不稳定飞机的仿真飞行试验只能在引入控制器后 (闭环条件下) 进行。文献中对此模型引入了垂直速度比例反馈控制器 (30), 并进行了闭环机动试验, 其中 δ_p 为飞行员输入^[4]。

$$A = \begin{bmatrix} Z_w & U_0 + Z_q \\ M_w & M_q \end{bmatrix}\tag{29}$$

$$\delta_e = \delta_p + Kw\tag{30}$$

表 1 模型参数的标称值以及基于 3 种方法的估计结果
Tab. 1 Nominal values of model parameters and estimated results based on three methods

参数	标称值	NNLM	LS	SOEM
Z_w	-1.424 9	-1.424 8 (0.002 0)	-1.424 9 (0)	-1.426 8 (0.000 1)
Z_q	-1.476 8	-1.479 1 (0.023 1)	-1.476 8 (0)	-1.476 8 *
Z_{δ_e}	-6.263 2	-6.265 6 (0.045 3)	-6.263 2 (0)	-6.171 1 (0.001 0)
M_w	0.216 3	0.216 3 (0.000 2)	0.214 8 (0.000 2)	0.217 0 (0.000 1)
M_q	-3.706 7	-3.707 0 (0.003 1)	-3.690 5 (0.001 9)	-3.720 1 (0.000 1)
M_{δ_e}	-12.784 0	-12.784 3 (0.008 0)	-12.705 6 (0.004 1)	-12.814 8 (0.001 1)

尽管仿真飞行试验是在闭环条件下进行的, 本文对模型参数的估计在开环条件下进行, 将升降舵偏转量 δ_e 视为模型输入, 进行开环辨识, 在辨识过程中并未使用飞行员输入 δ_p 的信息。使用 JATEGAONKAR^[4]设计的输入信号激励仿真模型, 模型的试验数据如图 4 所示。




图 4 “BEAVER” 飞机短周期模型的仿真试验数据
Fig. 4 Simulation test data of short-period model of “BEAVER” aircraft

4 参数辨识结果

本文基于 NN-LM 方法,从仿真数据中提取模型参数。首先,选取神经网络输入向量为仿真模型第 k 时刻的状态及输入为

$$\mathbf{U}(k) = [w(k), q(k), \dot{w}(k), \dot{q}(k), \delta_e(k)]^T \quad (31)$$

式中 $w(k)$ 为 k 时刻的纵向速度采样值。

选取网络输出向量为仿真模型第 $k+1$ 时刻的输出 $\mathbf{Z}(k+1)$ 为

$$\mathbf{Z}(k+1) = [w(k+1), q(k+1), \dot{w}(k+1), \dot{q}(k+1), a_z(k+1)]^T \quad (32)$$

以最速下降法调整网络参数。在神经网络训练完成后,用于替换“BEAVER”模型的运动方程(26),预测 $k+1$ 时刻的模型输出 $\hat{\mathbf{Y}}(k+1)$ 。

接下来,在参数估计的过程中,将神经网络输入向量 $\mathbf{U}(k)$ 中的 $\dot{w}(k), \dot{q}(k)$ 测量值替换为由观测方程(27)计算得到:

$$\begin{aligned} \hat{\dot{w}}(k) &= Z_w w(k) + (U_0 + Z_q) q(k) + Z_{\delta_e} \delta_e(k) \\ \hat{\dot{q}}(k) &= M_w w(k) + M_q q(k) + M_{\delta_e} \delta_e(k) \\ \hat{\mathbf{U}}(k, \boldsymbol{\theta}) &= [w(k), q(k), \hat{\dot{w}}(k), \hat{\dot{q}}(k), \delta_e(k)]^T \end{aligned} \quad (33)$$

网络输入 $\mathbf{U}(k)$ 替换为 $\hat{\mathbf{U}}(k, \boldsymbol{\theta})$ 后,网络输出演变成了参数向量 $\boldsymbol{\theta}$ 的非线性函数,见式(15)。使用粒子群改进的 LM 算法优化代价函数(16),求解模型参数向量 $\boldsymbol{\theta}$,求解结果见表 1。对于本文研究的不稳定飞机模型,传统的输出误差法无法用于参数估计, JATEGAONKAR^[4] 应用最小二乘法以及输出误差法的几种变体对其参数进行了估计,表 1 列出了其中两种方法,分别为最小二乘法(LS)和人工稳定的输出误差法(SOEM),与本文的估计结果用作对比。其中括号内的数值表示参数估计的标准差, SOME 方法中, Z_q 的估计值有“*”标注,表示在参数估计过程中, Z_q 需要设置为已知参数。由表 1 可知, NN-LM 方法的求解结果更接近参数标称值,并且此方法不需要设置任何的已知参数。

综上所述,传统的输出误差法需要参数的先验信息,将参数初值设置在标称值附近,否则算法将发散或者收敛至局部极小值点。而改进的 LM 算法具有更宽的收敛范围,即不需要参数的先验信息。本文参数估计过程中,所有的未知参数向量 $\boldsymbol{\theta}$ 均以 $[-2, 2]$ 范围内的随机数初始化,从不同的初始值开始迭代时算法均可以收敛。图 5、6 为选取不同随机初始值时,参数 Z_{δ_e} 和 M_w 的收敛过程。可以看

出,参数初值选取不同时,算法均可在 7 步内收敛,参数初始值离标称值较远时,算法收敛较慢,参数初始值离标称值较近时,算法收敛较快。




图 5 参数 Z_{δ_e} 收敛过程以及对应的标准差

Fig. 5 Convergence process of Z_{δ_e} and corresponding standard deviation




图 6 参数 M_w 收敛过程以及对应的标准差

Fig. 6 Convergence process of M_w and corresponding standard deviation

将 3 种方法估计的参数代入运动方程(26),得到 3 种估计模型,并且由仿真试验中的升降舵偏转驱动 3 种模型,模型的输出如图 7 所示。并结合 Theil 不等系数(Theil's inequality coefficient, TIC)^[19]来评价 3 种模型的输出量对试验值的拟合效果。输出量的 TIC 定义如式(34),其中 z_i 为仿真试验测量值, y_i 为模型的输出值, N 为离散测量数据点的个数。TIC 值越低表示模型输出与试验测量值符合度越高, TIC 值低于 0.25~0.30 代表了较好的拟合效果^[4]。3 种模型的各个输出量的 TIC 值见表 2。

$$\text{TIC}_i = \frac{\sqrt{\frac{1}{N} \sum_{k=1}^N [z_i(t_k) - y_i(t_k)]^2}}{\sqrt{\frac{1}{N} \sum_{k=1}^N [z_i(t_k)]^2} + \sqrt{\frac{1}{N} \sum_{k=1}^N [y_i(t_k)]^2}},$$

$i = 1, 2, \dots, n_y$ (34)

由图 6 可以看出,基于 NN-LM 方法辨识的模型可以很好地拟合仿真试验数据,效果优于传统的最小二乘法 (LS) 和人工稳定的输出误差方法 (SOEM)。由表 2 中的 TIC 值可以看出,对于 NN-LM 辨识出的模型,其各个输出量的 TIC 值均低于 LS 方法和 SOME 方法,且远小于 0.25,说明了此模型的输出对试验测量值的拟合效果更好。




图 7 3 种估计模型的升降舵驱动结果

Fig. 7 Elevator driving results of three estimation models

表 2 3 种模型各个输出量的 TIC 值

Tab.2 TIC values of each output of three models

输出量	NN-LM	LS	SOEM
a_z	0.002 2	0.312 2	0.068 8
w	0.002 4	0.330 8	0.073 8
q	0.001 60	0.239 1	0.050 0
$\dot{w}$	0.000 57	0.089 7	0.017 8
$\dot{q}$	0.000 31	0.048 3	0.009 5

5 结 论

1) 基于飞行试验数据训练前向神经网络,以神经网络代替飞机的运动方程来预测飞机响应,从而避免了输出误差法中求解运动方程的要求。因而可以应用于不稳定飞机以及大迎角飞行条件下的飞机参数辨识。同时,相比于求解运动方程,计算网络输出的运算成本更小,因此 NN-LM 算法对于稳定飞机的参数辨识也具有一定的优势。

2) NN-LM 算法基于粒子群优化,求解 LM 算法的最佳阻尼因子,放宽了高斯 - 牛顿法对参数初值的依赖,待辨识参数的初值可随机选取。本文的算例中,未知参数向量均以随机数初始化,从不同的初始值开始迭代时算法均可以收敛。

3) NN-LM 算法保留了输出误差法的精确性。仿真结果表明,改进后的算法可以成功辨识出不稳定飞机的参数。与传统算法相比,NN-LM 算法得到的 TIC 值更低,说明 NN-LM 算法辨识出的模型可以更好地拟合试验测量值,估计效果有明显改善。

4) NN-LM 算法本质上是对高斯 - 牛顿法的改进,因此还适用于其他的非线性方程求解问题。接下来将进一步围绕稳定以及不稳定飞机的气动系数建模来开展研究。基于 NN-LM 算法,从真实以及仿真的飞行试验数据中提取气动导数,与风洞试验结果进行对比和补充。

参考文献

[1] SIMMONS B M, MCCLELLAND H G, WOOLSEY C A. Nonlinear model identification methodology for small, fixed-wing, unmanned aircraft[J]. Journal of Aircraft, 2019, 56(3): 1056. DOI: 10.2514/1.C035160

[2] 郑宇昕. 最优输入设计方法及其在飞行器参数辨识中的应用[D]. 长沙: 国防科技大学, 2018

ZHENG Yuxin. Optimal input design method and aircraft parameter identification [D]. Changsha: National University of Defense Technology, 2018

[3] MORELLI E A, KLEIN V. Aircraft system identification: Theory and practice[M]. Williamsburg, VA: Sunflyte Enterprises, 2016. DOI: 10.2514/4.861505

[4] JATEGAONKAR R V. Flight vehicle system identification: A time-domain methodology[M]. 2nd ed. Reston, VA: American Institute of Aeronautics and Astronautics, Inc., 2015. DOI: 10.2514/4.102790

[5] 郑羽彤. 面向固定翼飞行器的智能辨识算法研究[D]. 长沙: 国防科技大学, 2018

ZHENG Yutong. Research on intelligent identification algorithms based on fixed-wing aircraft[D]. Changsha: National University of Defense Technology, 2018

[6] SINGH S, GHOSH A K. Estimation of lateral-directional parameters using neural networks based modified delta method [J]. The

Aeronautical Journal, 2007, 111 (1124): 659. DOI: 10. 1017/S0001924000004838

[7]黄睿. 基于神经网络的飞行器系统辨识方法研究[D]. 西安: 西北工业大学, 2002

HUANG Rui. Study of aircraft system identification based on neural networks[D]. Xi'an: Northwestern Polytechnical University, 2002

[8]HESS R. On the use of back propagation with feed-forward neural networks for the aerodynamic estimation problem[J]. Flight Simulation and Technologies, 1993, 233. DOI: 10. 2514/6. 1993 - 3638

[9]GHOSH A K, RAISINGHANI S C. Parameter estimation from flight data of an unstable aircraft using neural networks [J]. Journal of Aircraft, 2002, 39(5): 892. DOI: 10. 2514/2. 3012

[10]PEYADA N K, GHOSH A K. Aircraft parameter estimation using a new filtering technique based upon a neural network and Gauss-Newton method[J]. The Aeronautical Journal, 2009, 113(1142): 243. DOI:10. 1017/S0001924000002918

[11]王瑜. 基于神经网络的飞机系统辨识研究[D]. 西安: 西北工业大学, 2012

WANG Yu. Aircraft system identification based on neural network [D]. Xi'an: Northwestern Polytechnical University, 2012

[12]VERMA H O, PEYADA N K. Parameter estimation of unstable aircraft using extreme learning machine [J]. Defence Science Journal, 2017, 67(6): 603. DOI: 10. 14429/dsj. 67. 11401

[13]VERMA H O, PEYADA N K. Estimation of aerodynamic parameters near stall using maximum likelihood and extreme learning machine-based methods [J]. The Aeronautical Journal, 2021, 125(1285): 489. DOI: 10. 1017/aer. 2020. 95

[14]EBERHART R, KENNEDY J. A new optimizer using particle swarm theory [C]//Proceedings of the Sixth International Symposium on Micro Machine and Human Science. Nagoya, Japan: IEEE, 1995: 39. DOI: 10. 1109/MHS. 1995. 494215

[15]高卫峰, 罗宇婷, 原杨飞. 求解非线性方程组的智能优化算法综述[J]. 控制与决策, 2021, 36(4): 769

GAO Weifeng, LUO Yuting, YUAN Yangfei. Overview of intelligent optimization algorithms for solving nonlinear equation systems[J]. Control and Decision, 2021, 36(4): 769. DOI:10. 13195/j. kzyjc. 2020. 0379

[16]LEVENBERG K. A method for the solution of certain non-linear problems in least squares [J]. Quarterly of Applied Mathematics, 1944, 2(2): 164. DOI:10. 1090/qam/10666

[17]MARQUARDT D W. An algorithm for least-squares estimation of nonlinear parameters[J]. Journal of the Society for Industrial and Applied Mathematics, 1963, 11 (2): 431. DOI: 10. 1137/0111030

[18]JATEGAONKAR R V, THIELECKE F. Evaluation of parameter estimation methods for unstable aircraft [J]. Journal of Aircraft, 1994, 31(3): 510. DOI: 10. 2514/3. 46523

[19]RUIST E, THEIL H. Applied economic forecasting [J]. The Swedish Journal of Economics, 1967, 69(1): 83. DOI:10. 2307/3439127

(编辑 张 红)

封面图片说明

2022 年 12 期封面图片来自论文“低轨通信卫星箱式构型设计与散热能力分析”,是长光卫星技术股份有限公司空间环境研究室孔林团队提出的一种面向低轨宽带通信卫星的箱式构型设计。低轨宽带通信卫星具有载荷功率密度大、整星热耗高、轨道热环境复杂等特点,整星散热能力直接影响载荷的工作效能。载荷工作时长与散热能力息息相关。本文通过研究低轨宽带通信卫星在轨外热流特点,创新性的提出了倒梯形延展板箱式卫星结构构型,在同等卫星面积的情况下,大幅提升了整星的散热能力。同时,通过热管网络的优化设计,实现了高功率载荷的等温化,并减小了外热流交替变化对整星散热能力的影响。分析和试验结果表明,在高、低温极端工况下,卫星单机设备均满足温度指标要求,证明了基于热管网络的倒梯形延展板箱式构型的有效性,为低轨宽带卫星的热设计提供了参考。

(图文提供:吴优,孔林,孙强强,等. 长光卫星技术股份有限公司 空间环境工程研究室)