

文章编号: 1001-0920(2011)02-0187-04

SSUKF-WNN 算法及其在飞行器气动力建模中的应用

甘旭升¹, 端木京顺², 丛 伟²

(1. 西京学院, 西安 710123; 2. 空军工程大学 工程学院, 西安 710038)

摘要: 针对传统小波网络算法的不足, 提出一种基于改进无迹 Kalman 滤波(UKF)的小波网络算法. 该算法使用一种基于简化球形分布 Sigma 点的 UKF(SSUKF)来训练小波网络的参数, 以提高小波网络的学习性能和训练质量. 飞行器气动力建模算例表明, 相对于 BP 算法和 EKF 算法, SSUKF 算法训练的小波网络收敛速度更快, 估计精度更高, 计算量更小. 同时也为飞行器的气动力建模提供了一种有效可行的手段.

关键词: 小波网络; Kalman 滤波; 气动力; 飞行器

中图分类号: TP183; V211

文献标识码: A

SSUKF-WNN algorithm and its applications in aerodynamic modeling of flight vehicle

GAN Xu-sheng¹, DUANMU Jing-shun², CONG Wei²

(1. Xijing College, Xi'an 710123, China; 2. Engineering College, Air Force Engineering University, Xi'an 710038, China. Correspondent: GAN Xu-sheng, E-mail: ganxusheng123@163.com)

Abstract: For the shortcoming of traditional wavelet neural network(WNN), a WNN algorithm based on modified unscented Kalman filter(UKF) is proposed. The algorithm uses an UKF based on Sigma point of simplex spherical distribution(SSUKF) to train the parameters of WNN, which can improve the learning ability and training quality of WNN. The experiment results on aerodynamic modeling of flight vehicle show that, compared with BP and extended Kalman filter(EKF), the WNN trained by SSUKF algorithm has a better ability with features of convergence, precision and calculation, and is also a good method for aerodynamic modeling of flight vehicle.

Key words: wavelet neural network; Kalman filter; aerodynamic force; flight vehicle

1 引言

1992年, Zhang 和 Benveniste^[1]将小波变换与神经网络有机结合, 优势互补, 提出了小波网络. 其基本思想是用小波基函数代替 Sigmoid 函数作为激励函数, 并通过仿射变换建立起小波变换与网络系数之间的连接. 与传统神经网络相比, 小波网络在处理复杂非线性、不确定、未确知系统等问题上更具优势. 在已有的小波网络算法中, BP 算法应用最为广泛, 可解决诸多领域的实际问题. 但也存在精度不够高、收敛速度慢等缺点, 学者们对此作了大量研究, 并提出如自适应 BP 算法、粒子群算法、遗传算法等改进方案. 此外, 许多学者还研究采用扩展 Kalman 滤波(EKF)训练小波网络, 取得了一定成效^[2-3]. 但由于 EKF 是通过截取系统方程和观测方程的泰勒展开式来完成非线性系统的线性化, 使其存在算法不稳定、需要计算

Jacobian 矩阵等不足. 近年来, 出现了一种使用 UT 变换的线性回归 Kalman 滤波推广算法(UKF), 受到学者们的广泛关注. 与 EKF 相比, UKF 收敛速度快, 估计精度高, 无需计算 Jacobian 矩阵, 运算更为简单, 且具有较强的非线性处理能力^[4-6]. 但 UKF 的计算量与 UT 变换的 Sigma 点数量成正比. 为简化 UKF 运算, 在保证精度的同时, 应尽可能地减少 Sigma 点的个数.

基于此, 本文提出一种基于简化球形分布 Sigma 点 UT 变换^[7]的改进 UKF(SSUKF)算法, 将其用于训练小波网络, 并在飞行器气动力建模应用中得到验证.

2 小波网络状态空间模型

小波网络基本结构如图 1 所示. 其中: 输入为 x_i ($i = 1, 2, \dots, m$); 输出为 y_l ($l = 1, 2, \dots, n$); 尺度因子和平移因子为 a_j, b_j ($j = 1, 2, \dots, h$); 而 w_{ji}, w_{lj} 为输入层至隐含层和隐含层至输出层的连接权值.

收稿日期: 2009-11-12; 修回日期: 2010-03-09.

作者简介: 甘旭升(1972-), 男, 博士, 从事飞行安全、智能算法等研究; 端木京顺(1968-), 男, 教授, 博士生导师, 从事飞行安全等研究.




图 1 小波网络基本结构

对该网络训练即是对网络参数 θ_k (包括 w_{ji}, w_{lj}, a_j, b_j) 进行最优估计, 以寻求最佳的网络参数. 因此, 以 θ_k 作为网络系统的状态变量, 输出作为网络的测量方程, 小波网络的状态空间模型可表述为

$$\begin{cases} \theta_k = \theta_{k-1} + w_k, \\ z_k = h(\theta_k, u_k) + v_k. \end{cases} \quad (1)$$

其中: u_k 为网络输入; z_k 为网络输出; $h(\theta_k, u_k)$ 为参数化的非线性函数; w_k, v_k 分别为零均值高斯分布的过程噪声和测量噪声, 方差分别为 Q_k, R_k .

3 SSUKF 算法

UKF 在处理非线性问题时, 其计算量虽与 EKF 同阶, 但精度至少可达到二阶, 而 EKF 只能精确到一阶. 但由于 UKF 的计算量与 UT 变换的 Sigma 点数量成正比, 为简化 UKF 运算, 应尽可能地减少 Sigma 点的个数. 以下给出一种改进的 UKF.

3.1 UT 变换

UT 变换是 UKF 算法的核心和基础, 其基本思想就是选取少量样本作非线性变换, 然后计算其均值和方差, 作为实际随机变量经非线性映射后的均值和方差的近似值. 其中被选取样本称为 Sigma 点. 考虑 n 维随机变量 x , 其均值和方差分别为 \bar{x} 和 P_x . 假设对于给定非线性函数 $y = g(x)$, 若要估计 y 的均值 \bar{y} 和方差 P_y , 则需作以下 UT 变换:

首先计算 $2n + 1$ 个对称分布的 Sigma 点, 即

$$\begin{cases} X_0 = \bar{x}; \\ X_i = \bar{x} + (\sqrt{(n+\lambda)P_x})_i, i = 1, 2, \dots, n; \\ X_i = \bar{x} - (\sqrt{(n+\lambda)P_x})_i, i = n+1, \dots, 2n; \end{cases} \quad (2)$$

其中: $(\sqrt{(n+\lambda)P_x})_i$ 为矩阵均方根的第 i 列, 比例参数 $\lambda = \alpha^2(n+\tau) - n$. 这里: α 为 Sigma 点围绕均值的延伸程度, 通常取 $0 \leq \alpha \leq 1$; τ 为冗余量, 为确保 $(n+\lambda)P_x$ 为半正定矩阵, 对于高斯分布情况, 当状态变量为单变量时, 选择 $\tau = 0$; 多变量时, 选择 $\tau = 3 - n$. 接着通过非线性变换 $Y_i = g(X_i) (i = 0, 1, \dots, 2n)$ 得到变换后的采样点. 最后, 估计得到均值 \bar{y} 和方差 P_y 分别为

$$\bar{y} \approx \sum_{i=0}^{2n} \omega_i^{(m)} Y_i, \quad (3)$$

$$P_y \approx \sum_{i=0}^{2n} \omega_i^{(c)} [Y_i - \bar{y}] [Y_i - \bar{y}]^T. \quad (4)$$

其中权重

$$\omega_0^{(m)} = \lambda / (n + \lambda), \quad (5)$$

$$\omega_0^{(c)} = \lambda / (n + \lambda) + (1 - \alpha^2 + \beta), \quad (6)$$

$$\omega_i^{(m)} = \omega_i^{(c)} = 1 / [2(n + \lambda)], i = 1, 2, \dots, 2n. \quad (7)$$

3.2 SSUT 变换

UT 变换隐含对二阶项的偏差修正, 计算量与 EKF 同级, 优点是它无需计算导数, 即无需计算 Jacobian 矩阵. 另外, UT 变换的计算量与 Sigma 点的个数成正比. 研究表明, 对于 n 维状态可用 $n + 1$ 个最小斜 Sigma 点 (minimal skew sigma) 逼近, 为了减少计算量, 本文提出了基于简化球形分布 Sigma 点的 UT 变换 (SSUT). 其 Sigma 点的选取步骤如下:

Step 1: 选择权值

$$\omega_i = (1 - \omega_0) / (n + 1), i = 1, 2, \dots, n + 1. \quad (8)$$

其中 $0 \leq \omega_0 \leq 1$.

Step 2: 计算向量

$$\begin{cases} X_i^j = \begin{bmatrix} X_0^{j-1} \\ 0 \end{bmatrix}, i = 0; \\ X_i^j = \begin{bmatrix} X_i^{j-1} \\ 1 \\ \sqrt{j(j+1)\omega_1} \end{bmatrix}, i = 1, 2, \dots, j; \\ X_i^j = \begin{bmatrix} 0_{j-1} \\ j \\ \sqrt{j(j+1)\omega_1} \end{bmatrix}, i = j + 1. \end{cases} \quad (9)$$

$j = 2, 3, \dots, n.$

其中: $X_0^1 = 0, X_1^1 = -1/\sqrt{2\omega_1}, X_2^1 = 1/\sqrt{2\omega_1}$. 则称上述 Sigma 点集合为 X_{sigma} . 由此可以看出, 与 UT 变换相比, SSUT 变换的 Sigma 点个数由 $(2n + 1)$ 个降为 $(n + 2)$ 个, 大大减少了计算量.

3.3 UKF 算法

假设非线性离散系统定义为

$$\begin{cases} x_k = f(x_{k-1}) + w_k, \\ y_k = h(x_k, u_k) + v_k. \end{cases} \quad (10)$$

其中: x_k 为系统未知状态; y_k 为系统测量输出; w_k 和 v_k 分别为零均值过程噪声和测量噪声, 方差分别为 Q_k 和 R_k .

对于上述系统, 基于 SSUT 的 UKF (SSUKF) 算法步骤如下:

Step 1: 初始化, 即

$$\hat{x}_0 = E[x_0], \quad (11)$$

$$P_0 = E[(x_0 - \hat{x}_0)(x_0 - \hat{x}_0)^T]. \quad (12)$$

Step 2: 计算 Sigma 点, 即

$$x_{k-1} = \hat{x}_{k-1} + \sqrt{P_{k-1}} X_{\text{sigma}}. \quad (13)$$

Step 3: 时间更新, 即

$$x_{k|k-1} = f(x_{k-1}) + w_k, \quad (14)$$

$$\hat{x}_k^- = \sum_{i=1}^{n+1} \omega_i x_{i,k|k-1}, \quad (15)$$

$$P_k^- = \sum_{i=0}^{n+1} \omega_i [x_{i,k|k-1} - \hat{x}_k^-][x_{i,k|k-1} - \hat{x}_k^-]^T + Q_k, \quad (16)$$

$$y_{k|k-1} = h(x_{k|k-1}, u_k) + v_k, \quad (17)$$

$$\hat{y}_k^- = \sum_{i=0}^{n+1} \omega_i y_{i,k|k-1}. \quad (18)$$

Step 4: 测量更新, 即

$$P_{k|k-1}^{yy} = \sum_{i=0}^{n+1} \omega_i [y_{i,k|k-1} - \hat{y}_k^-][y_{i,k|k-1} - \hat{y}_k^-]^T + R_k, \quad (19)$$

$$P_{k|k-1}^{xy} = \sum_{i=1}^{n+1} \omega_i [x_{i,k|k-1} - \hat{x}_k^-][y_{i,k|k-1} - \hat{y}_k^-]^T, \quad (20)$$

$$K_k = P_{k|k-1}^{xy} (P_{k|k-1}^{yy})^{-1}, \quad (21)$$

$$\hat{x}_k = \hat{x}_k^- + K_k (y_k - \hat{y}_k^-), \quad (22)$$

$$P_k = P_k^- - K_k P_{k|k-1}^{yy} K_k^T. \quad (23)$$

4 小波网络的 SSUKF 算法

由 SSUKF 估计 WNN 参数 (即 SSUKF-WNN), 可以借鉴文献 [2-3] 中 EKF 训练 WNN 参数的方法, 即由式 (1) 代替 (10), 进而运用 SSUKF 算法估计网络参数 θ_k . 图 2 为 SSUKF-WNN 算法流程, 其中 MSE 代表网络训练的均方根误差.

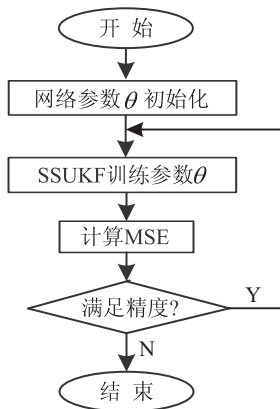


图 2 SSUKF-WNN 算法流程

5 气动力建模实验

5.1 实验设计

飞行器的气动力建模过程极其复杂, 影响因素众多, 程序繁琐, 易出现较大偏差. 传统方法已无法满足飞行器设计的精度要求, 而神经网络技术的出现为飞行器设计提供了一条新途径^[8-9]. 小波网络作为一种新型的神经网络, 同样应适于气动力建模方面的研究.

在本文的气动力建模实验中, 研究对象选定为 DFVLR 的 HFB-320 空中前掠翼模拟机, 实验数据源自 HFB-320 在 13 800 ft 的两个连续机动动作^[10]. 即: 1) 多次升降舵输入激励产生的短时动作; 2) 一次脉冲输入激励产生的 Phugoid 动作. 分析表明, 受大气干扰影响, 在 60 s (取样间隔 0.04 s) 的飞行实测数据中伴随着过程噪声, 这可能增加建模的难度, 也有利于验证模型性能. 则 HFB-320 的纵向气动力模型可表示为

$$C_{D,L,m} = f(\alpha, q, V, \delta_e). \quad (24)$$

其中: $C_{D,L,m}$ 为相对于质心的阻力系数 C_D , 相对于质心的升力系数 C_L 和相对于气动中心的俯仰力矩系数 C_m ; α 为攻角; q 为俯仰角速率; V 为真速; δ_e 为升降舵偏角. 实际上, 式 (24) 中的 SSUKF-WNN 气动力建模过程, 就是以 α, q, V, δ_e 为输入, $C_{D,L,m}$ 为输出, 用 UKF 训练 WNN 参数, 获得能准确反映 HFB-320 纵向气动特性 WNN 模型的过程.

图 3 为建模流程与数据流向图. 由图 3 可知, α, q, V, δ_e 数据需经相容性分析、低通滤波等预处理 (过程从略); 而 C_D, C_L, C_m 无法直接测量, 可通过计算得到. 气动力系数沿飞机体轴 (x, y, z 方向) 分量可由下式得到:

$$C_X = (ma_x - F_{\text{eng}} \cos \sigma_{\text{eng}}) / (\bar{q}S), \quad (25)$$

$$C_Y = (ma_y) / (\bar{q}S), \quad (26)$$

$$C_Z = (ma_z + F_{\text{eng}} \sin \sigma_{\text{eng}}) / (\bar{q}S). \quad (27)$$

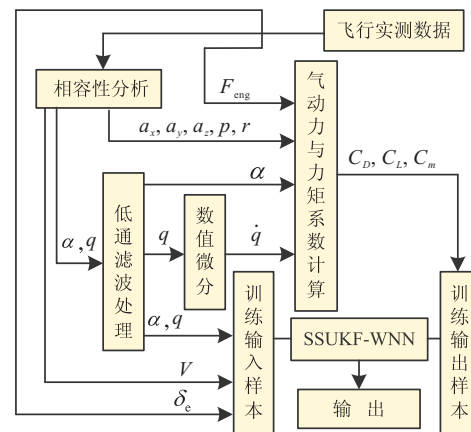


图 3 气动力建模流程与数据流向图

而相对质心的俯仰力矩系数为

$$C_m^{CG} = [I_y \dot{q} + I_{xz}(p^2 - r^2) - (I_z - I_x)pr - F_{\text{eng}}(\cos \sigma_{\text{eng}} z_E + \sin \sigma_{\text{eng}} x_E)] / (\bar{q}Sb). \quad (28)$$

将式 (25)~(28) 代入下式:

$$C_D = -C_X \cos \alpha - C_Z \sin \alpha, \quad (29)$$

$$C_L = C_X \sin \alpha - C_Z \cos \alpha, \quad (30)$$

$$C_m = C_m^{CG} - C_X z_A / l + C_Z x_A / l. \quad (31)$$

其中: a_x, a_y, a_z 为加速度体轴分量; p, r 为倾斜角和偏航角速率; m 为飞机质量; F_{eng} 为推力; σ_{eng} 为引擎倾角; S 为参考面积; \bar{q} 为动压测量值; I_x, I_y, I_z 为惯性矩体轴分量; I_{xz} 为交叉惯性矩; x_E, z_E 为引擎沿 x, y 轴坐标; x_A, z_A 为气动中心坐标; b, l 分别为横侧向和纵向气动系数参考长度.

5.2 实验分析

为了验证本文算法, 实验分别用 BP-WNN, EKF-WNN, UKF-WNN 和 SSUKF-WNN 算法建立了 HFB-320 纵向气动力模型. 隐节点个数取 15, 激励函数选择 Morlet 小波函数, 训练次数 200, 网络参数初始值取 $[-1, 1]$ 内随机数, 过程噪声方差矩阵对角初始值取 10^{-8} , 测量噪声方差矩阵对角初始值取 10^{-2} . 为了消除输入变量量纲的影响, 建模前对式 (24) 中的输入输出数据进行了标准化处理. 表 1 为各算法建模后输出估计与计算值的均方根误差 (MSE) 对比. 图 4 为 SSUKF-WNN 模型估计值与气动力系数计算值的对比结果. 图 5 为 4 种算法的训练收敛曲线.

通过实验可得到如下结论:

1) EKF-WNN, UKF-WNN 和 SSUKF-WNN 的精度和收敛性都比 BP-WNN 有了显著提高, 这说明基于




图 4 纵向气动力模型的预测结果




图 5 算法训练收敛曲线

表 1 各算法仿真结果对比

参数	算法			
	BP-WNN	EKF-WNN	UKF-WNN	SSUKF-WNN
C_D	0.0101	0.0082	0.0030	0.0021
C_L	0.0145	0.0093	0.0047	0.0058
C_m	0.0235	0.0104	0.0020	0.0026

Kalman 滤波的建模方法, 能有效提高模型的整体性能.

2) 相比之下, UKF-WNN 和 SSUKF-WNN 的整体性能优于 EKF-WNN, 表明 UKF 比 EKF 具有更强的非线性处理能力.

3) UKF-WNN 和 SSUKF-WNN 的性能相当, 但后者是在较少 Sigma 点情况下获得的, 这对于解决大样本问题非常重要, 也说明采用 SSUKF 训练 WNN 是有效的. 另外, 仿真过程中发现过程噪声矩阵的选取对估计结果影响很小, 放宽了 WNN 建模的要求.

4) 使用 SSUKF-WNN 进行飞行实测数据的纵向气动力建模是有效可行的. 另外, 对 HFB-320 方向舵和副翼输入的横侧向气动力建模也得到了相同的结论. 这表明 SSUKF-WNN 的气动力建模方法值得推广应用.

6 结论

针对小波网络的训练问题, 提出了一种基于 SSUKF 的小波网络参数估计算法. 在该算法中, 首先在 Kalman 滤波算法框架内应用一种简化球形分布 Sigma 点的 UT 变换, 即 SSUKF 算法. 该算法不仅继承了 UKF 无需计算 Jacobian 矩阵的优点, 而且计算的 Sigma 点个数也由 $(2n+1)$ 降为 $(n+2)$. 然后, 利用 SSUKF 算法对小波网络的参数进行估计, 完成小波网络训练. 最后, 通过飞行器气动力建模应用实例对算法进行了验证. 仿真结果表明, 该方法能较好地改善小波网络的收敛性能, 提高模型精度, 减小计算量. 同时, 也为飞行实测数据的气动力建模问题提供了一条行之有效的解决途径.

参考文献(References)

- [1] Zhang Q, Benveniste A. Wavelet networks[J]. IEEE Trans on Neural Networks, 1992, 3(6): 889-898.
- [2] Oh J S, Park J B, Choi Y H. Path tracking control using a wavelet neural network for mobile robot with extended kalman filter[C]. Proc of Int Conf on Control, Automation and Systems. Gyeongju, 2003: 1283-1288.
- [3] Kim K J, Park J B, Choi Y H. The adaptive learning rates of extended kalman filter based training algorithm for wavelet neural networks[C]. 5th Mexican Int Conf on Artificial Intelligence. Apizaco, 2006: 327-337.

(下转第 195 页)