

一种基于动态模糊神经网络的飞行数据模型辨识方法

张亮，张凤鸣，惠晓滨，毛红保
(空军工程大学 工程学院，陕西 西安 710038)

摘要：针对飞行数据的特点,提出了一种基于动态模糊神经网络(DFNN)的飞行数据模型辨识方法。该方法采用在线学习方式,通过动态增加和删除神经元节点的策略实现网络结构学习,采用递推最小二乘法实现网络权值的在线调整,以最终得到一个结构简单、泛化能力强的神经网络。以某特定时间段的飞参数数据为仿真样本,将该DFNN用于参数关联模型的辨识,实验结果表明该辨识方法收敛速度快、泛化能力强。

关键词：动态模糊神经网络;飞行数据;模糊规则;辨识

中图分类号：TP183 文献标识码：A 文章编号：1009-3516(2006)06-0016-03

军用飞机上的飞行参数记录系统,实时记录了发动机、飞机运动及航行姿态等诸多重要参数,如何有效利用这些数据辨识出飞行数据模型,对实现飞机的状态监控、故障诊断具有重要的意义^[1]。飞行数据模型一般具有非线性和时变性,因此,辨识的关键在于如何辨识出模型的非线性和时变性。本文针对飞行数据的特点,提出了一种基于动态模糊神经网络(Dynamic Fuzzy Neural Networks, DFNN)的飞行数据模型辨识方法,该模型适合实时在线辨识。

1 DFNN 的结构

基于 Mamdani 模糊规则的模糊神经网络结构如图 1 所示^[2]。网络共有 4 层,即输入层、EBF 层(Ellipsoidal Basis Function Layer)、归一化层和输出层。为研究方便,只考虑了多输入单输出系统,结果可以推广到多输入多输出系统。

第 1 层为输入层。每个节点代表一个输入变量,其中 x_i , $i = 1, 2, \dots, r$ 为输入变量。

第 2 层为 EBF 层。每个节点代表一条模糊规则,它的作用是实现输入变量的模糊化和匹配模糊规则前件。文中分别采用高斯函数计算输入变量的隶属度、积运算计算模糊规则适应度。第 j 个节点的输出为

$$\varphi_j = \exp\left[-\sum_{i=1}^r (x_i - c_{ij})^2 / \sigma_{ij}^2\right] \quad (1)$$

式中: $j = 1, 2, \dots, u$; c_{ij}, σ_{ij} 分别为相应高斯函数的中心和宽度; u 为 EBF 层节点数。

第 3 层为归一化层。第 j 个节点的输出见式(2)。

第 4 层为输出层。采用加权平均反模糊化的方法,网络输出 y 见式(3)。

$$\psi_j = \frac{\varphi_j}{\sum_{j=1}^u \varphi_j} = \frac{\exp\left[-\sum_{i=1}^r \frac{(x_i - c_{ij})^2}{\sigma_{ij}^2}\right]}{\sum_{j=1}^u \exp\left[-\sum_{i=1}^r \frac{(x_i - c_{ij})^2}{\sigma_{ij}^2}\right]}, j = 1, 2, \dots, u \quad (2) \quad y = \sum_{j=1}^u \omega_j \psi_j = \frac{\sum_{j=1}^u \omega_j \exp\left[-\sum_{i=1}^r \frac{(x_i - c_{ij})^2}{\sigma_{ij}^2}\right]}{\sum_{j=1}^u \exp\left[-\sum_{i=1}^r \frac{(x_i - c_{ij})^2}{\sigma_{ij}^2}\right]} \quad (3)$$

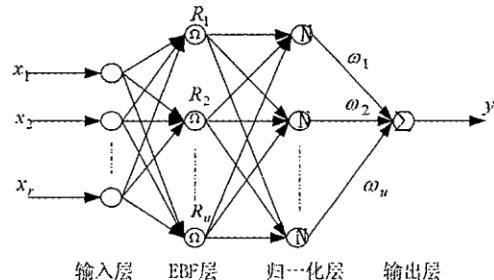


图 1 模糊神经网络结构

收稿日期:2006-01-05

基金项目:军队科研基金资助项目

作者简介:张亮(1982-),男,江西吉安人,博士生,主要从事智能信息处理与智能决策研究;

张凤鸣(1963-),男,重庆梁平人,教授,博士生导师,主要从事系统工程与智能决策等研究.

2 DFNN 的在线学习算法

2.1 增加 EBF 神经元

当第一个样本 (x_1, d_1) 进入网络时,增加第一个 EBF 神经元并初始化,令中心 $c_1 = x_1^\top$,宽度 $\sigma_1 = [\sigma_0, \sigma_1, \dots, \sigma_r]^\top$,其中 c_1, σ_1 为 $r \times 1$ 维向量。当第 n 个样本 (x_n, d_n) 进入网络时, y_n 为实际输出, d_n 为期望输出。

定义 1 系统误差 $|\xi_n| = |d_n - y_n|$, $|\xi_n|$ 越小, 网络的泛化能力越好。

定义 2 EBF 层节点输出的最大值 $\varphi_n = \max_j(\varphi_j), j = 1, 2, \dots, u$ 。 φ_n 越大, 模糊规则覆盖样本的能力越强。根据式(1)可知, 输入变量落在区间 $[c_{ij} - 2\sigma_{ij}, c_{ij} + 2\sigma_{ij}]$ 的概率为 95%, 当输入变量在边界点时, EBF 层节点输出值 $\varphi_j = 0.1354$ 。

从上述定义的 2 个变量出发, 网络结构按下列准则进行修改^[3]。

(a) 当 $|\xi_n| \leq \delta, \varphi_n \geq 0.1354$ 时, 表明网络具有很好的泛化能力, 同时模糊规则可以覆盖该样本, 此时只需要调整输出层权值。

(b) 当 $|\xi_n| \leq \delta, \varphi_n < 0.1354$ 时, 表明网络有很好的泛化能力, 但没有模糊规则覆盖该样本, 此时必须增大 φ_n 。由式(1)和定义 2 可知, 要增大 φ_n , 只需按 $\sigma_{ij}^{\text{new}} = K_e \sigma_{ij}^{\text{old}}$ 增大 σ_{ij} 。

(c) 当 $|\xi_n| > \delta, \varphi_n \geq 0.1354$ 时, 表明网络有模糊规则能够适应该样本, 但没有很好的泛化能力, 需增加神经元以提高网络的泛化能力, 该新增神经元参数的具体设置见文献[3]。

(d) 当 $|\xi_n| > \delta, \varphi_n < 0.1354$ 时, 表明网络既没有很好的泛化能力又没有模糊规则能够覆盖该样本, 此时先按 $\sigma_{ij}^{\text{new}} = K_e \sigma_{ij}^{\text{old}}$ 对 σ_{ij} 进行调整, 直到 $\varphi_n \geq 0.1354$, 如果此时 $|\xi_n|$ 依然大于 δ , 则按准则(c)进行调整。 $\sigma_{ij}^{\text{new}} = k_e \sigma_{ij}^{\text{old}}$ 。其中, k_e 的取值一般为 1~1.5 之间的常量。

2.2 冗余节点的删除和输出层权值的调整

文中采用 ERR(Error Reduction Ratio) 方法^[4]对冗余节点进行删除, 其主要思路是计算各个 EBF 层节点(模糊规则)对输出的贡献率, 并删除贡献率极低的模糊规则。采用递推最小二乘法进行权值更新^[5], 同时为减少计算量并反映非线性系统的时变特性, 本文采取了一种“移动窗”的方法, 即当样本容量超过阈值 l_s 时, 新样本进入, 最旧的样本剔除。

上述 DFNN 在线学习算法, 误差是收敛的, 证明类似于文献[3]。

3 实验研究

以辨识左发动机的振动值与左发喷口位置、左发油门、左发 T4 和迎角之间的关联模型为例。在对上述飞行参数进行归一化的基础之上, 定义 DFNN 的输入分别为左发喷口位置、左发油门、左发 T4 温度和迎角, 输出为左发动机的振动值。以某飞行架次 1 501 s~1 600 s 时间段的 100 组数据为训练样本, 1 601 s~1 650 s 时间段的 50 组数据为检验样本进行实验研究。同时为检验算法的性能, 对在线训练方式下的 DFNN 算法与离线训练方式下的 FNN 算法进行了对比分析。

令 $\delta = 0.015$, $k_e = 1.12$, $l_s = 20$, 分别对应于 2 种不同训练方式, 训练样本的期望输出和辨识输出对比如图 2 所示, 检验样本的期望输出和辨识输出对比见图 3, 训练样本输出的均方差、期望输出的均方差和训练所占用 CPU 的时间见表 1。

由图 2、图 3 和表 1 可知, 在线 DFNN 算法的泛化能力明显高于离线 FNN 算法; 就训练 100 个样本所占用的 CPU 工作时间而言, 在线训练方式比离线训练方式要稍微多一点, 但对于一个新样本, 在线训练所需的时间比离线方式少得多。因此, 文中提出的基于 DFNN 的飞行数据模型辨识方法, 具有良好的泛化能力和较快的响应速度。

表 1 2 种算法性能对比

训练方式	训练样本输出的均方差	检验样本输出的均方差	训练占用 CPU 时间/s
在线 DFNN	0.0735	0.0904	1.203
离线 FNN	0.0617	0.1356	0.937

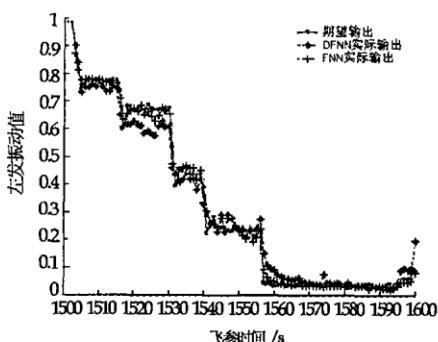


图2 训练样本的期望输出与辨识输出对比图

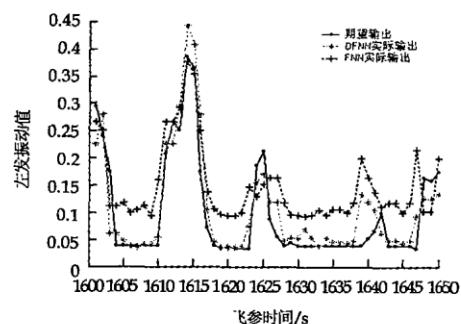


图3 检验样本的期望输出与辨识输出对比图

4 结论

本文研究了一种基于 DFNN 的飞行数据模型辨识方法,该方法实现了网络结构和权值的动态学习,可以很好反映飞行数据的非线性和时变性,同时具有普通模糊神经网络的良好逼近性。由于所得到的网络结构简单,可从 DFNN 中抽取简约的模糊规则,添加到知识库中,从而解决飞行数据知识获取的困难。在仿真中发现,系统的初始值、飞行参数选择等对网络的逼近性和泛化能力比较敏感,这些都有待于进一步研究。

参考文献:

- [1] 张鹏,张建业,李学仁.飞行数据趋势监测在飞机“健康状况”评估中的应用[J].空军工程大学学报(自然科学版),2004,5(3):8~10.
- [2] Wu Shi qian , Meng Joo Er. Dynamic Fuzzy Neural Networks – A Novel Approach to Function Approximation = [J]. IEEE Transactions On Fuzzy Systems, Man and Cybernetics, 2000, 30(2): 358 ~ 354.
- [3] Gang Leng, Girijesh Prasad, Thomas Martin McGinnity. An on - line algorithm for creating self – organizing fuzzy neural networks[J]. Neural Networks, 2004, 17: 1477 ~ 1493.
- [4] Wu Shi qian , Meng Joo Er, Gao Yang. A Fast Approach for Automatic Generation of Fuzzy Rules by Generalized Dynamic Fuzzy Neural Networks[J]. Ieee Transactions On Fuzzy Systems, 2001, 9(4):578 ~ 594.
- [5] 范文兵,陶振麟,张素贞.基于递推正交最小二乘的 RBF 网络结构优化[J].华东理工大学学报,2001,27(5):503 ~ 506.

(编辑:姚树峰)

An Identification Method of Flight Data Model Based on Dynamic Fuzzy Neural Network

ZHANG Liang, ZHANG Feng-ming, HUI Xiao-bin, MAO Hong-bao

(The Engineering Institute, Air Force Engineering University, Xi'an 710038, Shaanxi, China)

Abstract: With regard to the characteristics of flight data, a new identification method of flight data model based on dynamic fuzzy neural network is presented. By on-line learning, the proposed DFNN is learned for a compact network with better generalization ability. The network structure is learned by means of adding or pruning a new neuron, furthermore, the linear parameters as network weights are gained based on the recursive least squares algorithm. Through a great number of observations in a certain sortie, the DFNN method is applied to the identification of the association model of flight data. The test results show that the method is of faster convergence and better generalization.

Key words: dynamic fuzzy neural network; flight data; fuzzy rule; identification