

文章编号: 1000-8055(2004)01-0061-04

涡扇发动机部件特性的 BP 网络研究

陈 策, 李 军

(空军工程大学 工程学院, 陕西 西安 710038)

摘要: 在发动机特性计算中, 建立了 BP 神经网络对部件特性数据进行识别学习, 实现了特性数据的精确插值和对未知特性数据的推测。通过对网络输出结果的检验与分析, 表明该方法精确实用。

关 键 词: 航空、航天推进系统; 发动机特性计算; 部件特性; 后传播网络

中图分类号: V 235. 13⁺ 1

文献标识码: A

A Study of Turbofan Component Characteristics Based on Back-Propagation Network

CHEN Ce, LI Jun

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

Abstract: In jet engine characteristic computing, Back-Propagation network model was established to study and identify the data of engine component characteristics. Consequently, accurate interpolation of characteristic data and speculation on the unknown characteristic data were achieved. The checkout and analysis of network's output results showed that the present model has better practicability and veracity.

Key words: aerospace propulsion system; engine characteristic computing; engine components characteristic; Back-Propagation network

神经网络对于非线性映射具有任意近似能力, 且实时性较好, 通过样本的学习频度反映了对样本的统计信息, 使推理具有先天的似然性, 网络的加权性又决定了其良好的鲁棒性, 因此基于神经网络的方法非常适合应用于航空发动机领域中复杂系统的建模与辨识^[1,2]。其中后传播网络(Back-Propagation network, 简称 BP 网络), 作为一种多层前馈有导师学习的神经网络, 由于算法简便有效, 因而得到广泛的应用。

在使用发动机部件特性数据进行特性计算时, 会遇到两个问题: 一是如何把特性数据输入计算机, 二是如何获得小转速时的数据。在处理已知的部件特性数据时, 主要采用各种插值的方法。当

采用三次抛物线插值时, 在低转速曲线光滑处能保证较高的精度, 但在高转速曲率较大的地方会造成插值的较大误差; 当采用分段插值时, 如何选择断点又是一个难于解决的问题^[3]。至于小转速时数据的获取, 最好的方法是进行部件特性实验, 但花费较大又难于实现, 通过一般的外插方法进行猜测其准确程度不能保证。

BP 网络可以任意精度实现从输入到输出的非线性映射逼近, 对于不是样本集合中的输入也能给出合适的输出, 这种泛化 (generalization) 功能, 从函数拟合的角度看, 说明了 BP 网络具有插值的功能^[4]。因此通过建立 BP 神经网络对部件特性数据进行识别学习, 将已知的整机试车数据

收稿日期: 2003- 04- 14; 修订日期: 2003- 09- 18

作者简介: 陈策(1979-), 男, 山东济南人, 空军工程大学工程学院 硕士生, 主要从事推进系统原理与控制研究

和部件特性数据作为学习样本,通过训练,实现网络对输入输出的准确映射后,不仅可以对已知数据进行精确插值,而且可以推测未知的特性数据。本文以某型发动机风扇特性数据的识别学习为例,对上述两个问题的解决进行新的尝试。

1 BP 网络模型及其算法实现

BP 网络具有输入层节点、隐含层结点和输出层节点,对于输入信号,先向前传播到隐含层结点经过作用函数后,再把隐节点的输出信息传播到输出结点,最后给出输出结果。节点作用函数通常选择 sigmoid 函数^[5]:

$$f(x) = \frac{1}{(1 + e^{-x})}$$

这个算法的学习过程,由正向传播和反向传播组成。在正向传播的过程中,输入信息由输入层经隐含层处理后直到输出层。在反向传播的过程中,误差信号从输出层沿原来通路返回,并修改各层神经元权值,使得误差信号最小。将第 k 层第 i 个节点记为 I_i^k ,输出记为 o_j^k ,将第 $k-1$ 层 i 节点向第 k 层 j 节点的连接权值记为 ω^{k-1k}_{ij} ,第 k 层 j 节点的期望输出记为 y_{jo} ,各节点的实际输出值为:

$$o_j^k = f\left(\sum \omega^{k-1k}_{ij} o_i^{k-1}\right)$$

连接权值调整为:

$$\omega^{k-1k}_{ij}(t+1) = \alpha \omega^{k-1k}_{ij}(t) - \eta d_j^k o_i^{k-1}$$

k 为输出层时:

$$d_j^k = (o_j^k - y_j) f\left(\sum \omega^{k-1k}_{ij} o_i^{k-1}\right)$$

k 为隐含层时:

$$d_j^k = \sum \omega^{k+1k}_{jf} \left(\sum \omega^{k-1k}_{if} o_i^{k-1} \right)$$

η 是学习速率,可以加快网络的收敛速度,惯性系数 α 决定上次权值对本次权值的影响。

2 部件特性识别 BP 网络的建立

BP 网络是通过将网络输出误差反馈回传 (Error Back Propagation) 来对网络参数进行修正,从而实现网络的映射能力。它把一组样本的 I/O 问题变为一个非线性的优化问题,使用优化中的梯度下降法,用迭代运算求解权相应于学习记忆问题。如果输入节点数为 n ,输出结点数 m ,则网络是从 R^n 到 R^m 的映射,即有:

$$F: R^n \rightarrow R^m$$

$$Y = F(X)$$

对于样本集合 X 和输出 Y ,可认为存在某一映射 G 使:

$$Y_i = G(X_i)$$

$$i = 1, 2, 3, \dots, k$$

建立网络的目的是要求出一个映射 F ,使得在某种意义上, F 是 G 的最佳逼近。所以,希望建立一个部件特性的识别网络^[6],在输入输出数据之间建立一种映射关系,当输入某些已知的整机试车数据时,能够输出部件特性数据。Robert Nielson (见文献[6]) 证明了具有一个隐含层的三层 BP 网络可以有效地逼近任意连续函数,考虑到实际的应用要求,坚持尽可能减小系统规模复杂性的原则,本文就采用一个三层的 BP 网络模型。

选择部分整机试车数据作为输入参数,输入节点共 4 个,包括低压转子换算转速 (pcnl), 发动机相对推力 (F), 发动机相对耗油率 (sfc), 发动机相对进口空气流量 ($cw-2$), 对于风扇特性,输出节点 2 个: 增压比 (P1cl), 风扇效率 (etp), 对于隐含层单元数的确定,根据目前常用的两个公式^[5],输入节点数 n ,输出节点数 m ,则隐含层节点数 n_1 应该为:

$$n_1 = \sqrt{n + m} + a$$

$$a = 1 \sim 10$$

$$n_1 = \lg_2 n$$




图 1 部件特性识别 BP 网络结构图

Fig 1 Framework of BP neural network for the identification of components characteristic

经过反复计算,将 n_1 数目确定为 10。学习速率 η 设定为 0.5,惯性系数 α 设定为 1.0。网络结构如图 1 所示。

3 网络工作结果分析

在网络学习阶段,选取低压转子换算转速 (pcnl) 及其相对应的发动机相对推力 (F), 发动机相对耗油率 (sfc), 发动机相对进口空气流量

($cw2$) 作为输入, 增压比 (P_{Ic1}), 风扇效率 ($etlp$), 作为理想输出进行学习。在每一换算转速下, 由部件特性曲线上选择 10 个点作为该换算转速对应的学习样本。

为了对内插精度进行检验, 首先选择换算转速 ($pcnl$) 分别等于 0.5, 0.6, 0.7, 0.8, 0.9, 0.95, 1.0 时, 各自对应的学习样本, 数量共为 70 个, 进行学习。然后输入了 $pcnl=0.85$ 时的一组样本, 这组样本输出了相应的增压比 (P_{Ic1}), 风扇效率 ($etlp$), 把网络输出的这组内插结果与已知的 $pcnl=0.85$ 时部件特性数据进行比较, 见图 2。




图 2 BP 网络内插精度检验

Fig 2 Precision checkouts for BP neural network's internal interpolation

图 2 中星号表示已知特性数据点, 圆圈表示用 BP 网络进行内插得到的数据。图 2(a) 的“流量-压比”曲线中, 内插得到的数据点与已知数据点基本吻合, 均方根误差小于 1%。图 2(b) 的“流量-效率”曲线中, 在特性线上斜率急剧增大之前的各个点, 内插数据与已知数据基本吻合, 之后两者之间误差增大, 最大相对误差在 1% 左右。笔者认为这是由于在该阶段的数据点选取不够, 适当增加学习样本数量, 可以进一步提高精度。

为了进行数据外插推测, 选择换算转速 ($pcnl$) 分别等于 0.5, 0.6, 0.7, 0.8, 0.85, 0.9, 0.95, 1.0 时, 各自对应的学习样本, 数量共为 80 个进行学习。输入 $pcnl=0.4$ 和 1.05 时的一组样本, 输出了此时相应的增压比 (P_{Ic1}), 风扇效率 ($etlp$), 此时的外插特性见图 3。分别利用这两组部件特性数据进行发动机特性计算, 计算结果接近于实际整机试车的结果。




图 3 BP 网络外插特性推测

Fig 3 Characteristic predictions of BP neural network's external interpolation

4 结 论

本文以发动机风扇特性为例, 建立部件特性的 BP 网络, 对某一换算转速下的特性线进行内插计算, 经过检验证明该方法精确可靠; 同时也对未知特性数据进行预测, 分别对小转速和大转速下某一特性曲线进行了外插计算, 结果表明该方法准确可行。基于 BP 网络的风扇特性估算方法, 应用方便, 特别适合于计算机编程实现, 而且这种方法也可以应用于高压压气机, 涡轮等部件特性方面。随着试车资料和部件数据的不断丰富及算法的进一步完善, 该方法的准确性和应用范围可

以得到不断改善。

参考文献

[1] 孙斌, 张津, 张绍基 涡扇发动机气路故障定量诊断的BP 网络研究[J]. 推进技术, 1999, 20 (4): 48- 52

[2] ZeddaM , Singh R. Fault Diagnosis of A Turbofan Engine U sing Neural Networks A Quantitative Approach[R]. A IAA - 98- 3602

[3] 邓建中, 葛仁杰, 程正兴, 等 计算方法[M]. 西安: 西安交通大学出版社, 2000

[4] 楼顺天, 施阳 基于MATLAB 的系统分析与设计[M]. 西安: 西安电子科技大学出版社, 2000

[5] 靳蕃 神经计算智能基础[M]. 成都: 西南交通大学出版社, 2000

[6] 张立明 人工神经网络的模型及其应用[M]. 上海: 复旦大学出版社, 1991.

《航空动力学报》期刊影响因子
在航空航天类期刊中排名第二

根据中国科学技术信息研究所 2003 年 10 月出版的《中国科技期刊引证报告》统计结果:《航空动力学报》影响因子为 0. 374, 在该报告航空航天类期刊中排名第二。
排入航空航天类期刊影响因子前 15 名的期刊如下:

航空航天类期刊影响因子排序表

名次	期刊名称	影响因子
1	推进技术	0. 450
2	航空动力学报	0. 374
3	振动、测试与诊断	0. 350
4	航空学报	0. 338
5	宇航学报	0. 255
6	测控技术	0. 217
7	空气动力学学报	0. 216
8	强度与环境	0. 211
9	南京航空航天大学学报	0. 200
10	海军航空工程学院学报	0. 191
11	北京航空航天大学学报	0. 160
12	航空制造技术	0. 160
13	固体火箭发动机	0. 155
14	航天控制	0. 152
15	飞行器测控学报	0. 140

影响因子: 这是一个国际上通行的期刊评价指标, 是 E. 加菲尔德于 1972 年提出的。由于它是一个相对统计量, 所以可公平地评价和处理各类期刊。通常, 期刊影响因子越大, 它的学术影响力和作用越大。具体算法为:

影响因子 =
$$\frac{\text{该刊前两年发表论文在统计当年被引用的总次数}}{\text{该刊前两年发表论文总数}}$$

注: 以上数据及名词解释摘自中国科学技术信息研究所 2003 年 10 月出版的《中国科技期刊引证报告》。