

用集成过程神经网络预测民航发动机振动趋势*

雷 达, 钟诗胜

(哈尔滨工业大学机电工程学院 哈尔滨, 150001)

摘要 提出了一种集成过程神经网络预测模型用于民航发动机振动信号趋势预测。首先,对 AdaBoost. RT 算法的误差函数进行了改进,并采用自适应调整策略在训练过程中自动调节算法的分类阈值;然后,以改进的 AdaBoost. RT 算法为集成学习框架构建集成过程神经网络(process neural network,简称 PNN)预测模型。通过对两组实际民航发动机振动信号序列的预测对集成模型的预测效果进行了评估。结果表明,在具有更加简单网络结构的情况下,集成 PNN 模型的预测效果好于单一 PNN 模型。此外,提出的改进 AdaBoost. RT 算法的效果优于原始 AdaBoost. RT 以及仅改进了阈值调整方法的 AdaBoost. RT 算法。对比结果表明,提出的集成 PNN 模型适用于民航发动机振动信号变化趋势预测。

关键词 航空发动机; 振动信号; 趋势预测; 集成学习; AdaBoost. RT; 过程神经网络

中图分类号 TH183; TH263.6

引 言

对排气温度、转子振动等健康状态参数进行监测和趋势预测是民航发动机健康状态监控的重要内容。时间序列分析、人工神经网络(artificial neural network,简称 ANN)^[1]和过程神经网络^[2]等方法都被用来对民航发动机健康状态参数变化趋势进行预测。PNN 由于模拟了实际生物神经元的时间聚合特性,能够有效处理实际系统中存在的时间累积效应,具有较好的预测效果^[3-4]。

目前,一般通过建立全局模型的方法进行发动机健康状态参数预测,即采用全部的训练样本建立一个单一预测模型进行预测。然而,全局模型可能难以完整描述发动机健康状态参数时间序列的某些局部特性,且模型结构比较复杂。例如,ANN 和 PNN 等神经网络模型在实际应用中难以确定合适的网络结构,网络训练有可能陷入局部最优,导致难以获得最佳的预测精度。集成学习通过组合一组“弱学习机”,即非最佳预测效果的学习机获得更高的预测精度。AdaBoost 就是一种有效的集成学习算法^[5]。AdaBoost 赋予上一次学习中错误样本更大的权重,按照权值从训练样本中选择一部分“硬”样本训练新的学习机,使得各个学习机适应于当前

选择的局部样本。通过不同学习机对不同局部样本的学习,AdaBoost 可以克服全局模型的不足,在不追求单个学习机最佳预测精度的同时获得较好的总体预测效果。可见,采用集成学习模型可以减少模型优化的相关工作,容易获得比单一模型更好的预测效果。

有鉴于此,笔者针对民航发动机振动信号趋势预测问题,对面向回归问题的 AdaBoost. RT^[6]算法进行了改进,以改进的 AdaBoost. RT 算法作为集成学习框架,以 PNN 作为弱学习机构建集成 PNN 预测模型对民航发动机振动信号进行趋势预测。

1 过程神经网络

前馈过程神经网络模型是最为常用的过程神经网络模型,图 1 即为一种典型的三层前馈过程神经网络模型。该模型的隐层由过程神经元^[2]组成,而输出层由普通神经元组成。过程神经元以时变函数作为输入,以模拟生物神经元的持续输入刺激,其连接权也为时变函数,通过积分算子来实现时间聚合运算。

假设输出层的激励函数为线性函数 $g(z) = z$,则图 1 所示的过程神经网络模型的系统输出为

* 国家高技术研究发展计划(“八六三”计划)资助项目(2012AA040911-1);国家自然科学基金资助项目(60939003)
收稿日期:2013-01-21;修回日期:2013-05-02




图1 过程神经网络模型

Fig. 1 PNN model

$$y = \sum_{j=1}^m v_j f \left(\sum_{i=1}^n \int_0^T \omega_{ij}(t) x_i(t) dt - \theta_j^{(1)} \right) - \theta^{(2)} \quad (1)$$

其中: $x_i(t) \in C[0, T]$ 为第 i 个输入函数; $C[0, T]$ 表示由定义在 $[0, T]$ 上的连续函数空间; $\omega_{ij}(t)$ 表示第 j 个隐层神经元与第 i 个输入之间的连接权函数; $\theta_j^{(1)}$ 为第 j 个隐层神经元激励阈值; $\theta^{(2)}$ 为输出层激励阈值; v_j 为第 j 个隐层神经元与输出神经元之间的连接权值; $f(\cdot)$ 为激励函数。

同传统人工神经网络一样,过程神经网络可以采用梯度下降法、Levenberg Marquardt 算法等进行训练。同时,为了简化积分运算,需要将过程神经网络的输入函数和权函数进行正交基展开^[7]。

2 集成过程神经网络预测模型

2.1 改进的 AdaBoost. RT 算法

AdaBoost. RT 是从 AdaBoost 发展而来的一种面向回归问题的集成学习算法。AdaBoost. RT 计算训练样本的相对误差,引入一个分类阈值 φ 将回归问题转化为分类问题,从而依照 AdaBoost 框架进行模型训练。由于其使用的直观性和简便性,AdaBoost. RT 得到了广泛的应用^[8-9]。因此,笔者采用 AdaBoost. RT 作为集成过程神经网络模型的基本框架。

由于 AdaBoost. RT 使用的是相对误差,因此在实际使用中具有较小值的训练样本,在绝对误差较小的情况下也可能产生较大的相对误差,导致算法可能集中于具有较小值的样本,从而失效。为克服上述不足,构造误差函数为

$$l_t(i) = \text{are}(i) + \text{loss}(i) \quad (2)$$

其中: $l_t(i)$ 表示第 t 个弱学习机对第 i 个样本的训练误差。

$\text{are}(i)$ 通过相对误差变换得到,有

$$\begin{cases} \text{are}(i) = \frac{2}{1 + e^{-2\text{are}(i)}} - 1 \\ \text{are}(i) = \left| \frac{f(x_i) - y_i}{y_i} \right| \end{cases} \quad (3)$$

其中: $\text{are}(i)$ 为相对误差; $f(x_i)$ 为输入 x_i 时弱学习机的估计值; y_i 为对应的目标值。

由式(3)可知, $\text{are}(i) \in [0, 1]$ 。

$\text{loss}(i)$ 为第 i 个训练样本的绝对误差与所有训练样本绝对误差最大值的比值,其计算方式为

$$\text{loss}(i) = \frac{|f(x_i) - y_i|}{\max_{i=1, \dots, N} (|f(x_i) - y_i|)} \quad (4)$$

显然 $\text{loss}(i) \in [0, 1]$, 且 $\text{loss}(i)$ 与样本绝对误差的大小正相关,绝对误差越大,则 $\text{loss}(i)$ 越大。不难看出,当某个训练样本的绝对误差较小而相对误差较大时,式(2)的误差函数可以保证该样本的最终训练误差具有合理的度量,从而避免算法向小值样本集中。

另外,分类阈值 φ 的大小直接影响 AdaBoost. RT 的使用效果,过大或者过小的 φ 都会对算法的预测效果造成影响,导致难以选择合适的 φ ^[10]。笔者提出一种根据误差变化自适应调整阈值的改进方法。首先,赋予 φ 一个合适的初始值;然后,让 φ 随着实际训练误差的变化而自适应调整,具体为

$$\varphi = \begin{cases} \varphi + \varphi \max \left(\left| \frac{\epsilon_t - \epsilon_{t-1}}{\epsilon_{t-1}} \right|, 0.5 \right) & (\epsilon_t > \epsilon_{t-1}) \\ \varphi - \varphi \max \left(\left| \frac{\epsilon_t - \epsilon_{t-1}}{\epsilon_{t-1}} \right|, 0.5 \right) & (\epsilon_t < \epsilon_{t-1}) \end{cases} \quad (5)$$

其中: ϵ_t 和 ϵ_{t-1} 分别为相邻两次的学习误差; $\max(\cdot)$ 表示取最大值。

如果训练误差变大,则应当增加 φ 值,反之则减小 φ 值。另外,为了保证算法的有效性,应当对 φ 的取值范围进行限定。当 φ 值大于训练误差 l_t 的最大值或者小于 l_t 的最小值时,笔者取 φ 为 l_t 的中值。

2.2 集成预测模型构造

以改进的 AdaBoost. RT 算法作为集成框架,以过程神经网络作为弱学习机构建集成预测模型。由于单隐层过程神经网络具有良好的逼近性能,因此笔者采用的过程神经网络模型均为单隐层过程神经网络。集成预测模型的构造过程为:a. 生成一组具有相同网络结构的过程神经网络 $\{\text{PNN}_i\}_{i=1}^M$, 采用随机方法对其权值进行初始化,以保证各个

PNN_i之间存在差异性;b.对模型进行训练,通过试探确定弱学习机最终的隐含层神经元个数和弱学习机个数;c.重新训练集成预测模型,并进行测试和应用。

改进的 AdaBoost. RT 算法步骤如下。

1) 确定输入:给定 N 个训练样本 $\{(x_j, t_j)\}_{j=1}^N, t_j \in R$ 为输入对应的目标值;给定一组弱学习机 $\{f_i(x)\}_{i=1}^T$;确定分类阈值 φ 初始值。

2) 初始化:设置初始迭代次数 $t=1$,初始化样本权值 $D_i(i) = \frac{1}{N}, i=1, 2, \dots, N$,初始化误差 $\epsilon_t = 0$ 。

3) 迭代:根据权值分布 D_i 采样得到训练样本集,调用弱学习机 $f_i(x)$ 对样本进行训练;按照式(2)计算每个训练样本的误差 l_i ,计算误差 $\epsilon_t = \sum D_i(i), i: l_i > \varphi$;计算 $\beta_t = \epsilon_t$ 。

按照下式更新权值 D_i

$$D_{t+1}(i) = \frac{D_t(i)}{Z_t} \times \begin{cases} \beta_t & (l_i \leq \varphi) \\ 1 & \text{其他} \end{cases}$$

其中: Z_t 为标准化因子。

按照式(5)计算新的 φ 值,若 $\varphi \geq \max(l_i)$ 或 $\varphi \leq \min(l_i)$,令 $\varphi = \text{median}(l_i)$, $\min(\cdot)$ 和 $\text{median}(\cdot)$ 分别表示取最小值和中值。令 $t = t + 1$,如果 $t > T$,则输出结果。

4) 输出

$$f(x) = \frac{\sum_t \ln\left(\frac{1}{\beta_t}\right) f_t(x)}{\sum_t \ln\left(\frac{1}{\beta_t}\right)}$$

3 应用实例

3.1 数据预处理与模型建立

民航发动机转子振动状态体现了发动机的健康状态,一般通过与基线的偏差值(百分比)来描述。振动偏差值越大,表明发动机偏离基线越多,发动机的性能可能发生了衰退。因此,有必要对发动机振动信号的变化趋势进行预测。

笔者对国内某航空公司 CFM56 系列某台发动机实际振动监控数据时间序列进行预测。采用该发动机巡航状态的高压转子振动偏差(delta vibration of N_2 ,简称 ΔVN_2)和低压转子振动偏差(delta vibration of N_1 ,简称 ΔVN_1)共两组数据对提出方法进行测试,记为 $\{\Delta VN_2_i\}_{i=1}^{340}$ 和 $\{\Delta VN_1_i\}_{i=1}^{433}$ 。首先,采用 Savitzky-Golay 滤波器^[11]对原始数据进行平滑以消除噪声;然后,采用文献[3]的方法构建过程

神经网络的训练样本。对于 ΔVN_2 ,采用前 7 个数据对第 8 个数据进行预测,并且采用序列的后 15% 的数据作为测试数据,剩余的数据作为训练数据。对于 ΔVN_1 ,采用前 8 个数据对 9 个数据进行预测,采用序列后 20% 的数据作为测试数据,剩余的数据作为训练数据。初始化一组过程神经网络作为弱学习机构建集成预测模型,对集成预测模型进行训练和测试。

笔者采用平均绝对百分误差(mean absolute percentage error,简称 MAPE)以及均方根误差(root mean square error,简称 RMSE)描述预测误差。MAPE 和 RMSE 的计算公式分别为

$$\text{MAPE} = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - \bar{y}_i}{y_i} \right| \times 100\% \quad (6)$$

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \bar{y}_i)^2} \quad (7)$$

其中: N 为预测长度; y_i 为实际值; \bar{y}_i 为预测值。

3.2 测试结果

为了进行对比,在采用本研究方法进行预测的同时采用单一 PNN、原始 AdaBoost. RT 以及文献[8]的改进 AdaBoost. RT 算法进行预测。为方便起见,记文献[8]的改进 AdaBoost. RT 算法为 Ref 方法。在实验中,本研究方法和 Ref 方法的阈值初始值为 $\varphi = 0.2$,原始 AdaBoost. RT 的阈值 φ 通过试探确定。另外,3 种集成预测模型的迭代次数(弱学习机个数)及弱学习机隐层神经元个数通过试探确定。单一 PNN 的隐层神经元个数通过交叉验证确定。以上方法均采用选定的相同参数设置进行 5 次重复试验,取平均值作为最终预测结果。

各模型对 ΔVN_2 序列的预测结果如图 2~4 所示。模型参数设置和误差见表 1。各模型对 ΔVN_1 序列的预测结果如图 5~7 所示。模型参数设置和误差见表 2。




图 2 采用本研究方法的 ΔVN_2 预测结果

Fig. 2 Prediction results of ΔVN_2 using the proposed method




图 3 采用 Ref 方法的 $\Delta VN2$ 预测结果

Fig. 3 Prediction results of $\Delta VN2$ using the reference method




图 6 采用 Ref 方法的 $\Delta VN1$ 预测结果

Fig. 6 Prediction results of $\Delta VN1$ using the reference method




图 4 采用原始 AdaBoost.RT 方法的 $\Delta VN2$ 预测结果

Fig. 4 Prediction results of $\Delta VN2$ using the original AdaBoost.RT




图 7 采用原始 AdaBoost.RT 方法的 $\Delta VN1$ 预测结果

Fig. 7 Prediction results of $\Delta VN1$ using the original AdaBoost.RT

表 1 模型参数设置和 $\Delta VN2$ 预测误差

Tab. 1 Parameter setting and prediction errors of $\Delta VN2$

模型	φ	学习机数	隐层神经元数	MAPE/%	RMSE/%
PNN	—	1	32	4.520 9	0.005 2
Ref 方法	0.2	6	3	3.884 6	0.004 1
AdaBoost.RT	0.05	5	3	3.829 8	0.004 1
本研究方法	0.2	6	3	3.600 5	0.003 9

表 2 模型参数设置和 $\Delta VN1$ 预测误差

Tab. 2 Parameter setting and prediction errors of $\Delta VN1$

模型	φ	学习机数	隐层神经元数	MAPE/%	RMSE/%
PNN	—	1	23	4.971 6	0.013 8
Ref 方法	0.2	10	5	4.827 7	0.012 9
AdaBoost.RT	0.05	10	5	4.491 7	0.012 4
本研究方法	0.2	10	5	4.294 8	0.012 2




图 5 采用本研究方法的 $\Delta VN1$ 预测结果

Fig. 5 Prediction results of $\Delta VN1$ using the proposed method

可以看出,对于两种不同类型的振动信号时间序列,在不同训练样本和测试样本比例条件下,集成 PNN 预测模型的预测效果都好于单一 PNN 的预测效果,且作为弱学习机的 PNN 的网络结构比单一 PNN 的网络结构简单,证明了通过集成次优 PNN 模型获得较好预测效果的方法是可行的,从而可以有效简化民航发动机健康状态预测建模中模型优化工作。

虽然文献[8]改进算法的预测效果实际上比原始 AdaBoost.RT 的预测效果略差,但该算法只需给定初始阈值,大大减少了阈值优化的相关工作,因

此其改进是有效的。笔者提出的集成预测模型对于两种类型振动信号的预测效果好于未改进的 AdaBoost. RT 算法以及文献[8]的改进算法。这是因为本研究对 AdaBoost. RT 算法的改进采用了更加合理的误差函数和自适应阈值调整方法,易取得较好的预测效果。该结果同时也表明了该模型对于实际发动机振动信号趋势预测具有良好的适应性。

4 结 论

1) 提出了一种改进的 AdaBoost. RT 集成学习算法,该方法采用改进的误差函数以避免算法在训练中向具有较小值的样本集中,保证了算法的有效性。另外,该方法在训练过程中可以自适应调整分类阈值,使用更为方便。

2) 以过程神经网络作为弱学习机,采用改进的 AdaBoost. RT 算法构建集成模型对民航发动机振动信号变化趋势进行预测,并且与单一 PNN 模型、基于原始 AdaBoost. RT 以及只改进了阈值调整方法的 AdaBoost. RT 算法的集成 PNN 模型进行了对比。结果表明,本研究方法的预测效果好于对比方法,对民航发动机振动信号变化趋势预测具有更好的适应性。

参 考 文 献

- [1] 陈果. 用结构自适应神经网络预测航空发动机性能趋势[J]. 航空学报, 2007, 28(3): 535-539.
Chen Guo. Forecasting engine performance trend by using structure self-adaptive neural network[J]. Acta Aeronautica Et Astronautica Sinica, 2007, 28(3): 535-539. (in Chinese)
- [2] 何新贵,梁久祯. 过程神经网络的若干理论问题[J]. 中国工程科学, 2000, 2(12): 40-44.
He Xingui, Liang Jiuzhen. Some theoretical issues on procedure neural networks[J]. Engineering Science, 2000, 2(12): 40-44. (in Chinese)
- [3] 金向阳,林琳,钟诗胜,等. 航空发动机振动趋势预测的过程神经网络法[J]. 振动、测试与诊断, 2011, 31(3): 331-334.
Jin Xiangyang, Lin Lin, Zhong Shisheng, et al. Prediction of aeroengine vibration trend using process neural network[J]. Journal of Vibration, Measurement & Diagnosis, 2011, 31(3): 331-334. (in Chinese)
- [4] Ding Gang, Zhong Shisheng. Approximation capability analysis of parallel process neural network with application to aircraft engine health condition monitoring[J]. Lecture Notes in Computer Science, 2007, 4493(3): 66-72.
- [5] Freund Y, Schapire R. A decision-theoretic generalization of on-line learning and an application to boosting computational learning theory[J]. Lecture Notes in Computer Science, 1995, 904: 23-37.
- [6] Solomatine D P, Shrestha D L. AdaBoost. RT: a boosting algorithm for regression problems[J]. Neural Networks, 2004, 2: 1163-1168.
- [7] 何新贵,梁久祯,许少华. 过程神经网络的训练及其应用[J]. 中国工程科学, 2001, 3(4): 31-35.
He Xingui, Liang Jiuzhen, Xu Shaohua. Learning and applications of procedure neural networks[J]. Engineering Science, 2001, 3(4): 31-35. (in Chinese)
- [8] Tian Huixin, Mao Zhizhong. An ensemble elm based on modified AdaBoost. RT algorithm for predicting the temperature of molten steel in ladle furnace[J]. IEEE Transactions on Automation Science and Engineering, 2010, 7(1): 73-80.
- [9] Schclar A, Tsikinovsky A, Rokach L, et al. Ensemble methods for improving the performance of neighborhood-based collaborative filtering[C]// Proceedings of the Third ACM Conference on Recommender Systems. New York: [s. n.], 2009.
- [10] Shrestha D L, Solomatine D P. Experiments with AdaBoost. RT, an improved boosting scheme for regression[J]. Neural Computation, 2006, 18(7): 1678-1710.
- [11] Schafer R W. What is a savitzky-golay filter[J]. Signal Processing Magazine, IEEE, 2011, 28(4): 111-117.



第一作者简介: 雷达,男,1984年11月生,博士研究生。主要研究方向为复杂装备健康状态监测与预测方法。曾发表《卷积和离散过程神经网络及其在航空发动机排气温度预测中的应用》(《航空学报》2012年第33卷第3期)等论文。
E-mail:leidame@163.com