

一种可用于航空发动机健康状态预测的 动态集成极端学习机模型

钟诗胜, 雷 达

(哈尔滨工业大学 机电工程学院, 哈尔滨 150001)

摘 要: 提出一种动态集成极端学习机模型用于航空发动机健康状态预测. 采用 AdaBoost.RT 集成学习算法对极端学习机(ELM)进行集成, 在训练时采用每个训练样本的近邻样本对 ELM 的局域性能进行评估; 在预测时首先确定新样本在训练样本集中的近邻样本, 然后根据 ELM 在近邻样本上的性能来赋予集成权值实现弱学习机的动态集成. 以燃油流量为指标进行航空发动机健康状态预测, 动态集成 ELM 模型短期预测结果的平均相对误差绝对值(MAPE)为 3.688%, 小于单一 ELM 模型的 3.830% 以及静态集成 ELM 模型的 3.719%; 长期预测结果中动态集成 ELM 模型的 MAPE 为 3.075%, 小于单一 ELM 模型的 4.355% 以及静态集成 ELM 模型的 3.884%. 因此动态集成 ELM 模型更适用于航空发动机健康状态预测.

关 键 词: 航空发动机; 健康状态预测; 集成学习; 动态集成; 极端学习机

中图分类号: V263.6; TP183

文献标志码: A

A dynamic ensemble extreme learning machine model for aircraft engine health condition prediction

ZHONG Shi-sheng, LEI Da

(School of Mechatronics Engineering,
Harbin Institute of Technology, Harbin 150001, China)

Abstract: A dynamic ensemble extreme learning machine (ELM) model was proposed for aircraft engine health condition prediction. The AdaBoost.RT algorithm was used to integrate ELM to construct the ensemble model. During the training process, the neighboring samples of every training sample were employed to evaluate the local performance of ELM. In the prediction process, the neighboring samples of new samples in the training sample set were selected firstly, then the combined weights of ELM were determined by the performance on the neighboring samples, implementing the dynamic ensemble of the weak learning machine. Fuel flow was utilized as a health index for aircraft engine health condition prediction. For short term prediction, the mean absolute percentage error (MAPE) of the dynamic ensemble ELM model was 3.688%, less than the MAPE of the single ELM model and the static ensemble ELM model, which were 3.830% and 3.719%, respectively. And for long term prediction, the MAPE of the dynamic ensemble ELM model was 3.075%, also less than that of the single ELM model of 4.355% and the static ensemble ELM model of 3.884%. Thus, the dynamic ensemble ELM model is better for the aircraft engine health condition prediction.

Key words: aircraft engine; health condition prediction; ensemble learning;

收稿日期: 2013-06-01

基金项目: 国家高技术研究发展计划(2012AA040911-1); 国家自然科学基金(60939003)

作者简介: 钟诗胜(1964—), 男, 江西龙南人, 教授、博士生导师, 博士, 主要从事复杂装备健康管理研究.

dynamic ensemble; extreme learning machine

由于具有良好的逼近性能,且无需先验假设,以人工神经网络 (artificial neural networks, ANN) 为代表的智能模型被广泛地应用于航空发动机的健康状态预测^[1-3]. 然而,目前常用的基于 ANN 的全局预测模型往往存在模型复杂、难以优化的问题.

为了克服单一全局建模存在的实际问题,文献[4]从理论上证明了可以通过弱学习机,即不稳定、非最优的学习机的集成来获得良好的学习效果. Boosting 和 Bagging 等集成算法的成功应用也证明了可以通过对弱学习机的集成来获得满意的学习效果^[5-6]. 在采用集成学习算法对复杂系统建模时,采用次优模型作为弱学习机进行集成就能够获得较好的效果,从而可以简化模型优化工作. 集成学习算法的这一特点使得其更易于使用,在实际预测建模时更具适用性.

有鉴于此,本文提出了一种以面向回归问题的 AdaBoost. RT 集成学习算法^[7]为集成学习框架的集成模型对航空发动机进行健康状态预测. 考虑到 ELM^[8]无需迭代训练过程且具有良好的泛化性能,本文采用 AdaBoost. RT 集成学习算法对 ELM 进行集成,构建集成模型. 为充分利用弱学习机的局部性能,本文采用动态集成的方式集成 ELM 以获得更好的预测效果.

1 极端学习机

ELM 本质上是一种扩展的单隐层前馈神经网络,但 ELM 的隐层权值可以任意给定,而输出层权值可以直接计算得到,因此,ELM 不需要迭代训练过程. 此外,ELM 不仅趋向最小训练误差,而且能够使得输出层权值的范数最小,从而使得 ELM 具有良好的泛化性能.

给定 N 个输入,对于具有 L 个隐层神经元,且隐层神经元激励函数为 $g(\cdot)$,只包含一个输出的 ELM 模型,给定输入 $\mathbf{x}_j$ 与输出 o_j 之间的映射关系可以表示为

$$o_j = \sum_{i=1}^L \beta_i G(\mathbf{w}_i, \mathbf{x}_j, b_i) = \sum_{i=1}^L \beta_i g(\mathbf{w}_i \cdot \mathbf{x}_j + b_i) \quad j = 1, \dots, N \quad (1)$$

其中 $\mathbf{w}_i$ 是连接第 i 个隐层神经元到输入之间的权值向量,且 $\mathbf{w}_i = [\omega_{i1}, \dots, \omega_{in}]^T$, n 为输入 $\mathbf{x}_j$ 的

维数, β_i 是第 i 个隐层神经元与输出神经元之间的连接权值. 网络的训练目标是最小化输出值与目标值之间的误差,即 $\min(\sum_{j=1}^N \|o_j - t_j\|)$, 其中 t_j 为与输出值 o_j 对应的目标值,可以写为矩阵形式 $\min \|H\beta - T\|$, 其中

$$H = \begin{bmatrix} h(\mathbf{x}_1) \\ \vdots \\ h(\mathbf{x}_N) \end{bmatrix} =$$

$$\begin{bmatrix} G(\mathbf{w}_1, b_1, \mathbf{x}_1) & \cdots & G(\mathbf{w}_L, b_L, \mathbf{x}_1) \\ \vdots & & \vdots \\ G(\mathbf{w}_1, b_1, \mathbf{x}_N) & \cdots & G(\mathbf{w}_L, b_L, \mathbf{x}_N) \end{bmatrix}_{N \times L} \quad (2)$$

$$\beta = [\beta_1, \dots, \beta_L]^T \quad (3)$$

$$T = [t_1, \dots, t_N]^T \quad (4)$$

由于 ELM 的隐层参数 $\mathbf{w}_i$ 和 b_i 可以随机选择,ELM 的唯一未知参数为输出权值 β . ELM 的训练过程可以视为寻求等价线性系统最小二乘解的过程,且 ELM 定义的等价线性系统为

$$\|H\beta - T\| = \min_{\beta} \|H\beta - T\| \quad (5)$$

其最小范数解为

$$\hat{\beta} = H^+ T \quad (6)$$

其中 H^+ 为矩阵 H 的 Moore-Penrose 逆. 最小范数解保证了 ELM 在获得最小训练误差的同时输出权值绝对值最小,从而使得 ELM 具有更好的泛化能力,ELM 的广泛应用也证明了其优良性能^[9-10].

尽管 ELM 的隐层权值可以直接给定,但 ELM 对于初始权值敏感,其学习效果受初始权值影响而不稳定,因此 ELM 也可看作是一类弱学习机. 文献[11]就采用 ELM 作为弱学习机构建集成模型对钢水温度进行预测,且效果良好.

2 AdaBoost. RT 集成学习算法

AdaBoost. RT 是一种基于 AdaBoost 算法^[5]的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,并引入一个分类阈值 φ 将回归问题转化为分类问题,从而可以依照 AdaBoost 算法的流程进行模型训练. 鉴于其直观性和简便性,AdaBoost. RT 得到了广泛的应用^[11-13]. AdaBoost. RT 集成学习算法的基本流程如下:

1) 输入

给定 N 个训练样本 $[(\mathbf{x}_j, r_j)]_{j=1}^N$, $r_j \in \mathbf{R}$ 为输入对应的目标值;确定一组弱学习机 $[f_m(\mathbf{x})]_{m=1}^M$;

确定最大迭代次数 T 以及分类阈值 φ ; 其中, 若每次迭代只训练一个学习机, 则 $T=M$.

2) 初始化

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

3) 迭代

根据权值分布对训练样本进行采样得到训练样本集, 并训练弱学习机;

计算误差 $\epsilon_t = \sum D_t(i), i: \left| \frac{f_t(\mathbf{x}_i) - y_i}{y_i} \right| > \varphi$;

设置 $\beta_t = \epsilon_t^n$, n 的值可以为 1, 2 或者 3, 本文取为 1;

更新权值 D_t

$$D_{t+1}(i) = \frac{D_t(i)}{Z_t} \times \begin{cases} \beta_t & \left| \frac{f_t(\mathbf{x}_i) - y_i}{y_i} \right| \leq \varphi \\ 1 & \text{其他} \end{cases}$$

式中 Z_t 为标准化因子.

4) 输出

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

3 动态集成 ELM 模型

AdaBoost, RT 集成学习算法一般采用静态权值对弱学习机进行集成, 弱学习机的集成权值在学习机完成训练时已经确定. 静态集成的不足在于静态权值一般通过弱学习机的整体误差来确定, 而忽略了弱学习机的局部性能. 动态集成则根据弱学习机在某个局部空间的性能来赋予弱学习机集成权值, 因此每个弱学习机的集成权值不再固定, 而是随着弱学习机的局部性能而变化^[14-15], 这样就可以克服静态集成的不足. 大量研究也表明动态集成通常能取得优于静态集成的效果^[16-17].

采用动态权值进行弱学习机集成包括 3 个步骤: ①确定近邻样本; ②近邻样本上的学习机性能评估; ③确定集成权值. 下面从以上 3 个方面来介绍本文提出的动态集成 ELM 模型.

1) 确定近邻样本

本文采用 k -NN(nearest neighbor)算法来确定近邻样本, 并采用 Chebyshev 距离来进行近邻样本的选择. 给定空间中的两个点 P 和 Q , 记其坐标分别为 $(p_1, \dots, p_i, \dots, p_n)$ 和 $(q_1, \dots, q_i, \dots, q_n)$, 显然 p_i 和 q_i 分别表示点 P 和点 Q 的第 i 个

坐标, 则 P, Q 之间的 Chebyshev 距离为

$$D_{(P, Q)} = \max_i |p_i - q_i| \quad (7)$$

2) 学习机性能评估

本文受文献[18]启发, 采用近邻样本的平均误差来评估学习机的性能, 以对数据噪声进行一定的抑制. 对于给定的第 i 个训练样本, 在计算第 z 个学习机的训练误差 $\epsilon_z(i)$ 的基础上按照式(8)计算其在第 i 个训练样本近邻样本上的局域误差

$$f_{\text{perz}}(i) = \sum_{k \in \mathbf{P}(i)} \epsilon_i(k) D'_i(k) \quad (8)$$

其中 $\mathbf{P}(i)$ 为第 i 个训练样本的近邻样本, $D'_i(k)$ 为近邻样本的标准化权值, $D'_i(k) = \frac{D_i(k)}{\sum_{l \in \mathbf{P}(i)} D_i(l)}$.

3) 确定集成权值

对于第 z 个学习机的集成权值, 根据该学习机在所有的近邻样本上的平均误差来确定. 对第 z 个学习机 $f_z(\mathbf{x})$, 按照式(8)计算其对每个训练样本的局域误差. 对于给定的新样本 $\mathbf{x}_{\text{new}}$, 采用 k -NN算法找到 $\mathbf{x}_{\text{new}}$ 在训练样本中的近邻样本 $\mathbf{P}(\mathbf{x}_{\text{new}})$, 记第 j 个近邻样本到 $\mathbf{x}_{\text{new}}$ 的距离为 d_{s_j} , 则第 z 个学习机对于近邻样本的平均误差为

$$\overline{f_{\text{perz}}}[\mathbf{P}(\mathbf{x}_{\text{new}})] = \sum_{j \in \mathbf{P}(\mathbf{x}_{\text{new}})} \frac{1}{d_{s_j}} f_{\text{perz}}(j) \quad (9)$$

其中 d_{s_j} 为标准化后的近邻样本到 $\mathbf{x}_{\text{new}}$ 的距离, 并且有 $d_{s_j}' = \frac{d_{s_j}}{\sum_{l \in \mathbf{P}(\mathbf{x}_{\text{new}})} d_{s_l}}$. 从而, 第 z 个学习机对样本 $\mathbf{x}_{\text{new}}$ 的集成权值 ω_z 可以表示为

$$\omega_z = \frac{\{\overline{f_{\text{perz}}}[\mathbf{P}(\mathbf{x}_{\text{new}})]\}^{-1}}{\sum_{t=1}^M \{\overline{f_{\text{perz}}}[\mathbf{P}(\mathbf{x}_{\text{new}})]\}^{-1}} \quad (10)$$

从上述步骤可以看出, 本文提出的动态集成 ELM 模型需要在训练和输出时两次采用 k -NN 算法找到近邻样本, 前者的目的是进行学习机的局域性能评估, 后者是为了产生集成权值. 为了方便起见, 本文在两次 k -NN 算法近邻样本选择过程中采用同样的参数设置, 即同样的近邻个数和同样的度量距离. 接下来给出本文提出的动态集成学习算法的具体实现步骤.

1) 输入

给定 N 个训练样本 $\{(\mathbf{x}_j, r_j)\}_{j=1}^N, r_j \in \mathbf{R}$ 为输入对应的目标值; 给定一组弱学习机 $[f_m(\mathbf{x})]_{m=1}^M$; 确定最大迭代次数 T 、分类阈值 φ ; 确定近邻样本个数 N_n , 确定度量距离.

2) 初始化

设置初始迭代次数 $t=1$, 初始化样本权值

$D_i(i) = \frac{1}{N}, i=1, \dots, N$, 初始化误差 $\epsilon_i = 0$.

3) 迭代

根据权值分布 D_i 采样得到训练样本集, 训练一组弱学习机 $[f_m(\mathbf{x})]_{m=1}^M$, 并选择其中学习效果最好的学习机作为当前的弱学习机; 计算训练样本的训练误差 ϵ_i ;

对于第 i 个训练样本, 采用 k -NN 算法找到其 N_n 个近邻样本, 按照式(8)计算该训练样本的局域误差, 将其作为对于每个弱学习机学习效果的评估, 保存第 z 个学习机训练误差为 f_{perz} ;

计算误差 $\epsilon_i = \sum D_i(i)$, $f_{perz}(i) > \varphi$; 令 $\beta_i = \epsilon_i^n$, 本文取为 $n=1$;

按照下式更新权值 D_i :

$$D_{i+1}(i) = \frac{D_i(i)}{Z_i} \times \begin{cases} \beta_i & f_{perz}(i) \leq \varphi \\ 1 & \text{其他} \end{cases}$$

4) 输出

对于给定的新样本 $\mathbf{x}_{new}$, 采用 k -NN 算法找到其 N_n 个近邻样本, 然后根据式(9)和式(10)计算每个弱学习机的集成权值, 按照下式输出结果:

$$f(\mathbf{x}_{new}) = \sum_z w_z f_z(\mathbf{x}_{new})$$

4 应用实例

航空发动机具有诸多健康状态指标, 其中燃油流量(fuel flow, FF)是最为重要的健康状态指标之一, 可以通过对 FF 变化趋势的预测来了解航空发动机健康状态的变化状况. 因此, 本文采用 FF 作为航空发动机的健康指标, 从而将航空发动机的健康状态预测问题转化为一个对 FF 时间序列预测的问题, 进而可以采用本文提出的模型进行预测.

本文采用的 FF 数据为国内某航空公司的发动机监控实际数据. 采用的 FF 数据为非等间隔采样数据, 不宜直接用于模型训练. 因此, 采用根据一定间隔进行重采样的方法得到等间隔采样的数据进而用于提出模型的训练和测试. 不失一般性, 以 6 个飞行循环为间隔采集到一组 CFM56-C 系列发动机的燃油流量偏差数据(DFB), 记为 $[F_{df}]_{i=1}^{247}$, 该组数据大体上为等间隔采样数据, 由该组数据构成的时间序列如图 1 所示.

接下来构建预测模型的训练样本, 采用前 12 个数据对第 13 个数据进行预测, 从而可以建立一个包含 235 个样本的样本集. 同时进行短期预测和长期预测, 短期预测的测试样本与训练样本同




图 1 F_{df} 时间序列

Fig. 1 F_{df} time series

时生成, 预测时进行一步外推预测; 而长期预测的测试样本的输入则通过一步滚动外推预测的方式动态生成. 对于短期预测, 预测长度为 40; 对于长期预测, 预测长度为 20.

同时采用单一 ELM 模型、基于 AdaBoost. RT 的静态集成 ELM 模型、基于 AdaBoost. RT 的动态集成 ELM 模型进行预测. 为方便起见, 分别记上述模型为 ELM, SBoost 以及 DBoost. 模型参数通过试探确定. 为减少参数调整的工作量, 对于两种集成模型, 对作为弱学习机的 ELM 的隐层神经元个数, 只给定一个松散的范围, 每次训练从中选择学习效果最好的作为最终的弱学习机. 最终确定的模型参数如表 1 所示.

表 1 模型参数设置

Table 1 Parameters setting of models

模型	隐层神经元个数	学习机个数	阈值	近邻个数
ELM	20	1		
SBoost	[58 11 14]	5	0.15	
DBoost	[58 11 14]	5	0.15	15

3 种模型的短期预测和长期预测结果分别如图 2 和图 3 所示, 其预测误差则分别见表 2 和表 3.




图 2 短期预测结果

Fig. 2 Short term prediction results




图3 长期预测结果

Fig. 3 Long term prediction results

表2 短期预测误差

Table 2 Short term prediction errors

模型	最大相对误差 绝对值/%	方均根 误差/%	平均相对误差 绝对值/%
ELM	13.303	0.0689	3.830
SBoost	12.397	0.0686	3.719
DBoost	11.042	0.0688	3.688

表3 长期预测误差

Table 3 Long term prediction errors

模型	最大相对误差 绝对值/%	方均根 误差/%	平均相对误差 绝对值/%
ELM	12.205	0.081	4.355
SBoost	8.191	0.072	3.884
DBoost	9.490	0.069	3.075

从上述预测结果不难看出,对于 DFF 时间序列的短期预测和长期预测,两种集成 ELM 模型的预测效果都好于单一 ELM 模型,且作为集成模型弱学习机的 ELM 的网络结构(隐层神经元个数)比单一 ELM 模型更为简单。短期预测时,本文提出的 DBoost 模型预测结果的方均根误差稍大于 SBoost 模型预测结果,而最大相对误差绝对值和平均相对误差绝对值均小于 SBoost 模型预测结果;长期预测时,DBoost 模型预测结果的最大相对误差绝对值稍大于 SBoost 模型预测结果,而方均根误差和平均相对误差绝对值均明显小于 SBoost 模型预测结果,综合上述结果可以认为 DBoost 模型的预测效果优于 SBoost 模型。这与动态集成方法能够充分利用 ELM 的局部性能因而能获得更好预测效果的理论预期是相符合的。从而也可以证明,动态集成 ELM 模型比单一 ELM 模型和静态集成 ELM 模型更适应航空发动机的健康状态预测问题。

在本文预测结果的基础上,可以通过与安全阈值对比等方法对航空发动机的健康状态变化趋势进行评估,从而为航空发动机的调度和维修决策提供支持。

5 结 论

提出了一种可用于航空发动机健康状态预测的动态集成 ELM 模型。该模型以 AdaBoost、RT 集成学习算法为集成框架对 ELM 进行集成。在训练时,通过弱学习机在每个训练样本近邻样本上的学习误差来对其局域性能进行评估。在预测时,对于给定的新样本,首先确定其在训练样本中的近邻样本,然后根据弱学习机在这些近邻样本的性能来赋予弱学习机集成权值,实现根据弱学习机局部性能的动态集成。

对实际航空发动机燃油流量时间序列的预测结果表明,集成一组模型结构更为简单的 ELM 能够取得比单一 ELM 更好的预测效果,而且本文提出的动态集成 ELM 模型具有比静态集成 ELM 模型以及单一 ELM 模型更高的预测精度。另外值得说明的是,尽管本文只给出了以燃油流量作为健康状态指标进行航空发动机的健康状态预测的案例,本文提出的模型也适用于采用排气温度、振动信号等作为健康状态指标的航空发动机健康状态预测,其实施步骤与本文步骤类似,只需适当调整模型参数便可获得满意的预测效果。

参考文献:

- [1] 丁刚,徐敏强,侯立国.基于过程神经网络的航空发动机排气温度预测[J].航空动力学报,2009,24(5):1035-1039.
DING Gang, XU Minqiang, HOU Ligu. Prediction of aeroengine exhaust gas temperature using process neural network[J]. Journal of Aerospace Power, 2009, 24(5): 1035-1039. (in Chinese)
- [2] 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 and Diagnosis, 2011, 31(3): 331-334. (in Chinese)
- [3] 陈果,杨虞微.航空发动机复杂磨损趋势的神经网络多变量预测模型[J].中国机械工程,2007(1):70-74.
CHEN Guo, YANG Yuwei. Artificial neural network multi-variable forecasting model of aero-engine complex wear trend[J]. China Mechanical Engineering, 2007(1): 70-74. (in Chinese)
- [4] Schapire R E. The strength of weak learnability[J]. Ma-

- chine Learning, 1990, 5(2):197-227.
- [5] Freund Y, Schapire R E. A decision-theoretic generalization of on-line learning and an application to boosting[J]. Computational Learning Theory, 1995, 904:23-37.
- [6] Breiman L. Bagging predictors[J]. Machine Learning, 1996, 24(2):123-140.
- [7] Solomatine D P, Shrestha D L. AdaBoost. RT: a boosting algorithm for regression problems[C]//Proceeding of 2004 IEEE International Joint Conference on Neural Networks. Budapest, Hungary: IEEE, 2004:1163-1168.
- [8] Huang G B, Zhu Q Y, Siew C K. Extreme learning machine: theory and applications[J]. Neurocomputing, 2006, 70:489-501.
- [9] Huang G B, Wang D H, Lan Y. Extreme learning machines: a survey[J]. International Journal of Machine Learning and Cybernetics, 2011, 2(2):107-122.
- [10] SHI Lichen, BAO Lianglu. EEG-based vigilance estimation using extreme learning machines[J]. Neurocomputing, 2013, 102:135-143.
- [11] 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.
- [12] Drucker H. Improving regressors using boosting techniques[C]//Proceeding of the 14th International Conference on Machine Learning. San Francisco: Morgan Kaufmann Publishers Inc, 1997:107-115.
- [13] YANG Yihuan, LIN Yuching, SU Yafan, et al. Music emotion classification: a regression approach[C]//Proceeding of 2007 IEEE International Conference on Multimedia and Expo. Beijing: IEEE, 2007:208-211.
- [14] Niall R, Patterson D. A fusion of stacking with dynamic integration[C]//Proceeding of 20th International Joint Conference on Artificial Intelligence. San Francisco: Morgan Kaufmann Publishers Inc, 2007:2844-2849.
- [15] Puuronen S, Terziyan V, Tsymbal A. A dynamic integration algorithm for an ensemble of classifiers[C]//Proceeding of 11th International Symposium, Foundations of Intelligent Systems. Berlin Heidelberg: Springer, 1999:592-600.
- [16] Alexey T, Puuronen S. Bagging and boosting with dynamic integration of classifiers[C]//Proceeding of 4th European Conference, Principles of Data Mining and Knowledge Discovery. Berlin Heidelberg: Springer, 2000:116-125.
- [17] Niall R, Patterson D, Anand S, et al. Dynamic integration of regression models[C]//Proceeding of 5th International Multiple Classifier Systems Workshop. Berlin Heidelberg: Springer, 2004:164-173.
- [18] ZHANG Chunxia, ZHANG Jiangshe. A local boosting algorithm for solving classification problems[J]. Computational Statistics and Data Analysis, 2008, 52(4):1928-1941.