

# 基于人工蜂群优化支持向量参数的压气机特性线的表达

徐思雨, 应雨龙, 周宏宇, 靳尧飞, 谢启跃

(上海电力大学 能源与机械工程学院, 上海 201306)

**摘要:**为克服传统方法对压气机特性线内插与外推预测性能模拟精度不高的问题及准确实现压气机在变工况条件下基于部件特性线行为的燃气轮机热力学仿真计算,一种基于蜜蜂采蜜行为的人工蜂群(artificial bee colony, ABC)优化支持向量机(support vector machine, SVM)参数的方法被提出并用于压气机特性线的表达。从泛化精度及计算耗时的角度,与常用的BP算法、粒子群算法和网格寻优法的SVM模型相比较。同时,为验证训练样本容量对实验结果的影响,减少样本集数量,对比同一转速下不同算法的预测性能曲线及柱状残差图。应用分析表明,不同转速下基于ABC算法优化的SVM模型在压气机特性线的表达上具有更佳的预测精度和计算实时性,并且该方法不随样本容量波动而精度失准,具有良好的鲁棒性。

**关键词:**压气机特性线的表达;内插与外推;支持向量机;人工蜂群算法;参数优化

中图分类号:TM74

文献标志码:A

文章编号:1009-2889(2020)04-0024-10

在燃气轮机实际运行操作过程中,无论设备的设计和制造多么精良,其主要部件(如压气机、燃烧室和透平)可能受来自机组内部恶劣工况和周围环境污染的影响,随着运行时间的增加产生不同程度的性能衰退或损伤,阻碍设备的正常运行,甚至不可避免地造成各种严重的事故发生<sup>[1-2]</sup>。当这些部件发生性能衰退或损伤时,其部件内在性能参数(如压比、质量流量、等熵效率等)会发生改变,导致外在气路可测参数(如温度、压力、转速等)发生变化。因此准确的燃气轮机热力模型在燃气轮机的性能分析、气路预测诊断及电网结构需求中起到关键作用,特别是以质量、能量和动量守恒定律为基础的气动-热力学模型的建立对于整个机组的性能设计和控制具有重大意义。

在非设计条件下,燃气轮机性能模型的准确性高度依赖于部件(压气机和透平)特性线和工质热物性计算程序的精度,尤其是压气机部件特性线的质量直接关系到在压缩过程中相关动力学、热力学性质的仿真计算及建模分析的精度。通常,这些部件特性线是由发动机试车台在不同操作条件下通过严格的试验获得。由于试验的风险过高、测量难度

大和计算难以收敛等原因,使得获取部件的特性信息十分困难。有时出于技术保密,制造商不会提供相关的部件特性线信息,用户只能使用基于已知和有限的部件图通过在设计点的缩放或流量分析方案如计算流体力学<sup>[3]</sup>和流线曲率法<sup>[4]</sup>等方法确定特性图,通常会产生一定程度的计算误差。

在压气机特性数据不足甚至没有的情况下,逐级叠加计算法是一种通过使用广义级性能曲线来获得整个多级压气机和涡轮特性图的有效方法,通过对压气机和涡轮部件流量的逐级分析实现压气机特性图的调整<sup>[5-7]</sup>。为了进一步提高燃气轮机热力性能模型的计算精度,众多学者提出了一些有效方法,主要通过气路实测参数来修正热力模型的部件特性线或生成新的部件特性线。Simani 等人<sup>[8]</sup>最先引入了一种燃气轮机热力模型修正方法,它通过优化算法来搜索一组最优的部件特性线比例系数。随后,Lambiris 等人<sup>[9]</sup>对此方法进行了拓展。Kong 等人<sup>[10]</sup>利用系统辨识方法提出了一种基于已有部件特性线和在设计工况点得到的比例系数来获取变工况条件下新部件特性线的方法。Gatto<sup>[11]</sup>、Li<sup>[12]</sup>和潘鹏飞<sup>[13]</sup>等人基于变工况点的热力模型,采用遗传

算法获取单组比例系数以对整体部件特性线进行修正。

尽管基于来自制造商或性能平台有限的已知实验数据可以用于生成和预测未知区域中的压气机特性曲线,但它们会损害实验数据的特性和压气机部件的实际物理过程,其特性参数间的高度非线性是很难通过少量的样本数据建立清晰明确的数学表达式。基于数据驱动的人工神经网络法(artificial neural network, ANN)<sup>[14-17]</sup>可以通过部分压气机特性数据或发动机的测量值来提高预测精度,但网络的训练容易受到初始化网络权重的影响,对样本点的数量和质量有一定的依赖性,需要足够的历史运行数据作为网络训练的样本,才能通过逐步优化设计找出最佳的网络结构模型。对于样本集中未涉及的特性数据点,ANN的方法往往难以给出准确的预测结果。其次,ANN网络的学习,可以看成是一个非结构化计算的黑箱系统,在很多情况下很难正确反映出一个压气机系统内部明确的输入输出变量关系。因此,传统方法对压气机特性图的内插与外推预测性能的模拟精度通常不甚令人满意。

为了解决上述问题,必须采用新的建模方法,它既不脱离理论的分析,又不完全依赖实验数据,同时降低实验的花费成本,得出更为完善和普适的模型。根据SVM的非线性回归预测机理,利用基于蜜蜂采蜜行为的ABC算法对其特征参数进行优化,并将优化后ABC-SVM模型用于压气机特性图的表达上,可准确实现非设计条件下基于部件特性线行为的燃气轮机热力学性能的仿真计算。文章安排如下:第1节系统地描述了压气机的特性及建模问题;第2节详细地阐述了文章所使用的方法;第3节是对压气机特性曲线的具体应用;第4节为实验的结论。

## 1 压气机特性

通常,以笛卡尔坐标图形式表示的压气机特性被定义为压气机特性图<sup>[18]</sup>。轴向的压气机特性图用于燃气轮机热力学模型中,其工作特性可以由4个绝对参数或相对折合参数来表示<sup>[19]</sup>。

通用的相对折合参数形式如式(1)、式(2)所示,并以等转速线或相对折合转速线的曲线簇的形式用两个特性线图(流量特性图和效率特性图)来表达。

$$G_r = f(n_r, \pi_r) \quad (1)$$

$$\eta_r = h(n_r, \pi_r) \quad (2)$$

式中: $G_r = \frac{G \sqrt{T^* \cdot R}}{P^*} / \frac{G_0 \sqrt{T_0^* \cdot R_0}}{P_0^*}$ 为相对折合流量; $T^*, P^*$ 分别代表压气机进口总温、总压,下标0表示设计工况条件下, $R$ 为气体常数; $n_r = \frac{n}{\sqrt{T^* \cdot R}}$

/ $\frac{n_0}{\sqrt{T_0^* \cdot R_0}}$ 为相对转速,不带下标的参数表示压气

机相关的实际值; $\pi_r = \frac{\pi}{\pi_0}$ 为相对压比; $\eta_r = \frac{\eta}{\eta_0}$ 为相对等熵效率。

在机组的实际运行过程中,压气机运行状况的变化非常复杂,特别是在启动、加速等情况下,目前还尚未有能够完全反应压气机动态过程的特性资料。所以,对于全非线性部件级燃气轮机热力建模、压气机热力建模是最困难的。通常它会被建成一个集总参数模型,并假设其表现为准静态,以便使用其稳态的压气机特性线图。

一般情况下,由压气机试车台试验或流量分析方案只能获取包含设计工况点在内的部分压气机特性线,如图1所示。它们往往是离散分布的点,这意味着大部分信息(如在某些稳定状态附近数据点的插值和外推,启动或关闭导通时压气机的参数特性以及压气机的喘振裕度等)需要预测。此外,在设计点和最大负载间的速度线上,由于缺乏实验数据,通常采用插值的方法来确定所需位置的未知值。然而,如果关注点接近空气动力学稳定极限线或阻塞点,常用的插值方法容易出错。因此,为准确实现压气机在变工况条件下的热力计算,除了保证部件特性线本身的拟合精度外,还需要保证优良的泛化(即内插和外推)能力。

## 2 人工蜂群优化的支持向量机

### 2.1 支持向量回归机

作为一种典型的基于核的学习算法,SVM具有较强的自适应学习、非线性逼近能力,可用于求解线性或非线性的凸二次规划优化问题<sup>[20]</sup>。

$$h(x, w) = [w \cdot \varphi(x)] + b \quad (3)$$

用式(3)所示的非线性回归函数去拟合数据集 $\{x_i, y_i\}, i = 1, \dots, n, x_i \in R^d, y_i \in \mathbf{R}$ ,假设所有训练数据的拟合误差为 $\varepsilon$ (也称为不敏感系数),则有:

$$\begin{cases} [w \cdot \varphi(x_i)] + b \leq \varepsilon & i = 1, \dots, n \\ [w \cdot \varphi(x_i)] + b - y_i \leq \varepsilon \end{cases} \quad (4)$$

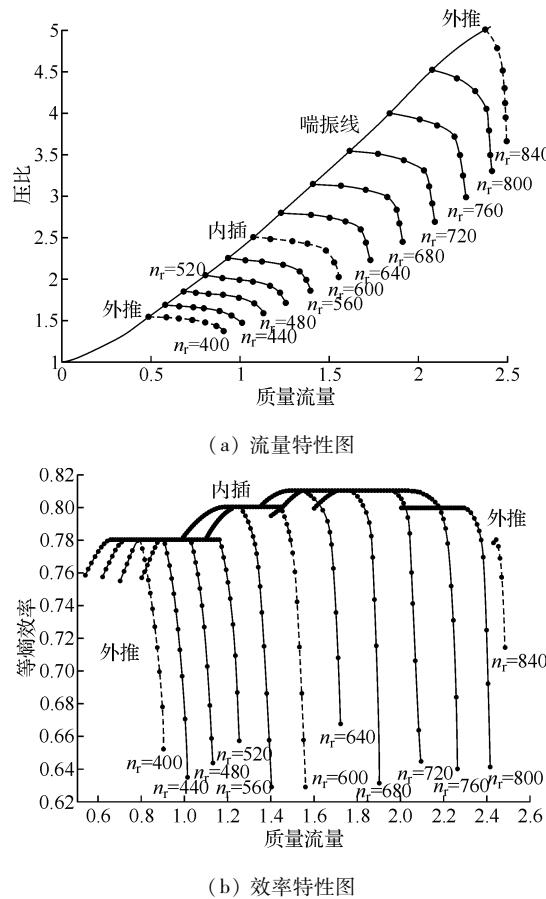


图1 压气机流量特性图和效率特性图

引入松弛因子  $\zeta_i \geq 0, \zeta_i^* \geq 0$ , 式(4)变成:

$$\begin{aligned} & y_i - \{[w \cdot \varphi(x_i)] + b\} \leq \varepsilon + \zeta_i \quad i = 1, \dots, n \\ & \{[w \cdot \varphi(x_i)] + b\} - y_i \leq \varepsilon + \zeta_i^* \end{aligned} \quad (5)$$

一个标准的  $\varepsilon$  不敏感支持向量机表示为:

$$\begin{aligned} & \min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n (\zeta_i + \zeta_i^*) \\ & \text{s. t. } \begin{cases} y_i - \{[w \cdot \varphi(x_i)] + b\} \leq \varepsilon + \zeta_i \\ \{[w \cdot \varphi(x_i)] + b\} - y_i \leq \varepsilon + \zeta_i^* \\ \zeta_i \cdot \zeta_i^* \geq 0 \end{cases} \end{aligned} \quad (6)$$

其中  $C$  是大于0的平衡因子。

对二次规划问题,建立Lagrange方程:

$$\begin{aligned} l(w, b, \zeta_i, \zeta_i^*) &= \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n (\zeta_i + \zeta_i^*) - \\ &+ \sum_{i=1}^n \beta_i \cdot \{\varepsilon + \zeta_i - y_i + [w \cdot \varphi(x_i)] + b\} - \sum_{i=1}^n \beta_i^* \cdot \{\varepsilon + \zeta_i^* + y_i - [w \cdot \varphi(x_i)] - b\} - \sum_{i=1}^n (\eta_i \zeta_i + \eta_i^* \zeta_i^*) \end{aligned} \quad (7)$$

式中:  $\beta_i, \beta_i^*, \eta_i, \eta_i^*$  是拉格朗日乘子。

令式(7)对参数  $w, b, \zeta_i$  和  $\zeta_i^*$  的偏导都等于零,有:

$$\begin{cases} \frac{\partial l}{\partial w} = w - \sum_{i=1}^n (\beta_i - \beta_i^*) \cdot \varphi(x_i) = 0 \\ \frac{\partial l}{\partial b} = \sum_{i=1}^n (\beta_i - \beta_i^*) = 0 \\ \frac{\partial l}{\partial \zeta_i} = C - \beta_i - \eta_i = 0 \\ \frac{\partial l}{\partial \zeta_i^*} = C - \beta_i^* - \eta_i^* = 0 \end{cases} \quad (8)$$

式(6)进一步写为:

$$\begin{aligned} & \min \frac{1}{2} \sum_{i,j=1}^n (\beta_i - \beta_i^*)(\beta_j - \beta_j^*) [\varphi(x_i) \cdot \varphi(x_j)] \\ & + \sum_{i=1}^n \beta_i(\varepsilon - y_i) + \sum_{i=1}^n \beta_i^*(\varepsilon + y_i) \\ & \text{s. t. } \begin{cases} \sum_{i=1}^n (\beta_i - \beta_i^*) = 0 \\ \beta_i, \beta_i^* \in [0, C] \end{cases} \end{aligned} \quad (9)$$

通过求解二次规划问题,可得:

$$w = \sum_{i=1}^n (\beta_i - \beta_i^*) \varphi(x_i) \quad (10)$$

由于非线性映射  $\varphi$  未知,特征空间具有很高的维数,因此  $w$  无法用一个清晰的数学表达式表示。为了简化  $\varphi$  的计算,引入一个核函数  $k(x, x')$ ,满足:

$$k(x, x') = \{\varphi(x) \cdot \varphi(x')\} \quad (11)$$

式(9)变为:

$$\begin{aligned} & \min \frac{1}{2} \sum_{i,j=1}^n (\beta_i - \beta_i^*)(\beta_j - \beta_j^*) k(x_i, x_j) + \sum_{i=1}^n \beta_i(\varepsilon - y_i) + \sum_{i=1}^n \beta_i^*(\varepsilon + y_i) \\ & \text{s. t. } \begin{cases} \sum_{i=1}^n (\beta_i - \beta_i^*) = 0 \\ \beta_i, \beta_i^* \in [0, C] \end{cases} \end{aligned} \quad (12)$$

根据KKT条件,在最优解处,有:

$$\begin{cases} \beta_i \{\varepsilon + \zeta_i - y_i + [w \cdot \varphi(x_i)] + b\} = 0 \\ \beta_i^* \{\varepsilon + \zeta_i^* + y_i - [w \cdot \varphi(x_i)] - b\} = 0 \end{cases} \quad (13)$$

可由式(14)求得阈值  $b$ :

$$\begin{aligned} b &= y_i - [w \cdot \varphi(x_i)] - \varepsilon, \beta_i \in (0, C) \\ b &= y_i - [w \cdot \varphi(x_i)] - \varepsilon, \beta_i^* \in (0, C) \end{aligned} \quad (14)$$

则最终有:

$$\hat{h} = \sum_{i=1}^n (\beta_i - \beta_i^*) k(x_i, x) + b \quad (15)$$

支持向量回归机在形式上类似于一个神经网络

的结构,输出是对应支持向量中间节点的线性组合,权值为对应的 Lagrange 乘子,如图 2 所示。

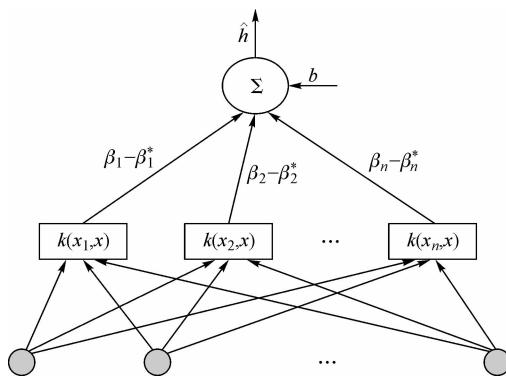


图 2 支持向量回归机模型

在利用 SVM 对压气机特性参数间的非线性关系进行回归预测时,模型性能很大程度上受到其自身参数和使用特征的影响,对预测结果的精度产生一定影响。如何利用常规的优化方法设计出符合目标函数约束的、整体性能最优的参数组合是目前研究 SVM 相关应用领域的一大热点和难点之一。

## 2.2 基于蜜蜂采蜜行为的蜂群算法

ABC 算法是 Karaboga<sup>[21]</sup>于 2005 年提出的一种有效元启发式算法,主要用于寻找数值优化问题中的最优解。由采蜜蜂、观察蜂和侦察蜂组成的人工蜂群能够利用不同角色间的信息共享和群体间的相互协作机制来实现对食物源(蜜源)的开采<sup>[22]</sup>。

假设某个蜂群的规模为  $N_s$ ,采蜜蜂和观察蜂的数量相等,均为  $N$  个。优化模型中,一个食物源位置对应一个可行解;解的质量代表一个适应度函数值,它取决于搜索的蜜源质量;解的数目就等于食物源的数量。基于蜜蜂采蜜行为的 ABC 算法过程类似于进化计算中搜索待求解问题的最优解过程。

(1) 初始时刻,采蜜蜂随机搜索蜂巢附近的食物源  $\mathbf{X}_i^j = (x_i^1, x_i^2, \dots, x_i^n)$ ,其中  $n$  是待求解函数模型中需要优化的参数个数。采蜜蜂储存所发现蜜源的信息后,飞回蜂巢通过跳摇摆舞来传达食物地点的重要信息。

$$\mathbf{X}_i^j = \mathbf{X}_{\min}^j + \text{rand}(0, 1)(\mathbf{X}_{\max}^j - \mathbf{X}_{\min}^j) \quad (16)$$

式中: $i = 1, 2, \dots, N, j = 1, 2, \dots, n, \mathbf{X}_{\max}^j$  和  $\mathbf{X}_{\min}^j$  分别表示维度  $j$  的上下限。

(2) 一个采蜜蜂对应一个食物源,即每个采蜜可在当前记忆位置向量  $\mathbf{X}_i^j$  附近领域通过如下搜索式(17)生成一个新的位置向量  $\mathbf{V}_i^j$ 。

$$\mathbf{V}_i^j = \mathbf{X}_i^j + \varphi_i^j(\mathbf{X}_i^j - \mathbf{X}_k^j) \quad (17)$$

式中: $j \in \{1, 2, \dots, n\}$  和  $k \in \{1, 2, \dots, N\}$  均为随机选择的, $k \neq i, \varphi_i^j$  为  $[-1, 1]$  之间的随机数。

(3) 每产生一个新的位置向量  $\mathbf{V}_i^j$ ,采蜜蜂就会基于贪婪选择算子与记忆中的原位置向量  $\mathbf{X}_i^j$  进行比较,以为下一代种群保留适应度高的优良个体。

$$\mathbf{V}_i^j = \begin{cases} \mathbf{X}_{\max}^j, & \mathbf{V}_i^j < \mathbf{X}_{\min}^j \\ \mathbf{V}_i^j, & \mathbf{V}_i^j \leq \mathbf{X}_{\min}^j < \mathbf{X}_{\max}^j \\ \mathbf{X}_{\min}^j, & \mathbf{V}_i^j > \mathbf{X}_{\max}^j \end{cases} \quad (18)$$

(4) 当所有采蜜蜂完成搜索任务时,观察蜂根据采蜜蜂跳舞传递的蜜源信息能够准确评价其蜜源质量(即蜜源收益度),并根据与蜜源质量成正比的概率  $P$  快速有效地对食物源进行选择,即轮盘赌法。在 ABC 算法中,轮盘赌选择方案中每个切片的大小与适应度值成正比,如式(19)所示。

$$P_t = \frac{f_t}{\sum_{m=1}^N f_m} \quad (19)$$

式中: $f_t$  代表第  $t$  个解对应的适应度函数值。

(5) 同第(2)步和第(3)步,并记录种群经过最终迭代更新后达到的最优适应度值及相应的参数值。

(6) 每当一个食物源被充分开采后,与之相关的采蜜蜂就会放弃原先的食物源,成为侦察蜂继续寻找新的食物源。

(7) 当满足算法停止准则时,计算停止,否则跳转到第(2)步。

## 2.3 基于 ABC-SVM 算法的压气机特性线的表达

作为一种典型的模式识别方法,SVM 仅可用于解决单输出目标函数的逼近问题,但由于支持向量非线性回归机的预测样本是源于已知和有限的压气机特性数据,输入数据存在多样性和复杂性。因此,为实现压气机特性参数间的多输入多输出关系的模型辨识,需要针对每个输出量分别设计相应的学习机。

在对压气机的特性参数关系进行建模时,其压比和转速视为支持向量机的输入,流量和等熵效率作为输出。利用两个向量机的并联,共同组成压气机不同转速特性下的训练样本集  $\{(x_i, y_i)\}, i = 1, 2, \dots, m$ 。其中  $m$  为样本总数,  $x$  代表支持向量机的输入,  $y$  代表支持向量机的输出。

回归预测网络模型训练前,压气机特性参数样本数据必须进行归一化处理。基于 ABC 算法的归一化和反归一化处理是利用如下所示的

“mapminmax”函数实现。

$$\tilde{x} = 2 \frac{x - x_{\min}}{x_{\max} - x_{\min}} - 1 \quad (20)$$

向量机所使用的核函数类型、宽度参数  $\sigma$  及平衡因子  $C$  往往是根据经验进行选择,由于特征参数的变化会对 SVM 的回归预测性能产生巨大影响,特别是内核的选取在算法性能中起着决定性的作用,所以传统的 SVM 方法将增加预测的随机性并导致最终预测结果的不准确。这样,以宽度参数和平衡因子为对象,利用基于蜜蜂采蜜行为的 ABC 算法可实现支持向量非线性回归机模型参数的优化设计,即对相关模型重要控制参数及适应度函数进行初始化设置。

为提高回归预测的精度,采用式(21)所示的适应度函数表达式:

$$F = \frac{1}{M} \sum_{t=1}^M (O_t - P_t)^2 \quad (21)$$

式中: $O_t$  为第  $t$  个样本的实际输出值; $P_t$  为第  $t$  个模型预测的输出值; $M$  是样本总数。

对于压气机特性参数的优化求解, $n$  取值为 2,即宽度参数  $\sigma$  和平衡因子  $C$  代表了食物源位置。由于径向基函数有助于显示原始输入空间和输出空间之间的关系,因此可用作 SVM 非线性回归机的核函数类型。具体的实验操作步骤如下:

步骤 1:某离心式压气机特性参数数据的录入。

步骤 2:参数样本数据的归一化处理。

步骤 3:相关参数的初始化,即采蜜蜂种群数  $N = 20$ ,算法控制参数(最大限制次数) $L = 100$ ,最大迭代次数  $I = 10$ ,初始迭代次数  $i = 0$ ,支持向量的不敏感系数  $\varepsilon = 0.01$ ,参数搜索范围设为  $[0.01, 100]$ 。

步骤 4:所有蜜蜂变为侦察蜂,随机产生 20 个初始解。

步骤 5:计算初始解的适应度函数值,并初始化第  $i$  个采蜜蜂在同一蜜源的连续停留次数  $t_i = 0$ 。

步骤 6:建立人工蜂群优化支持向量参数的模型。

步骤 7:采蜜蜂据式(17)搜索新蜜源以产生新解,并判断适应度函数值是否优于先前蜜源的值,若是,则基于贪婪选择算子更新蜜源位置, $t_i = 0$ ,否则更新标志向量  $t_i = t_i + 1$ 。

步骤 8:采蜜蜂传达蜜源信息,观察蜂以选择概率向量  $P$ ,判断是否保留蜜源。

步骤 9:当所有观察蜂完成搜索过程后,若某个

采蜜蜂在同一蜜源的连续停留次数  $t$  大于算法的最大限制次数  $L$  时,该解陷入局部最优,此时当前蜜源就被舍弃,而采蜜蜂转化为侦察蜂,利用式(16)继续搜索新蜜源,并记录当前最优解, $i = i + 1$ ,否则,直接记录当前最优解。

步骤 10:当算法迭代次数  $i$  大于最大迭代次数  $I$  时,输出最佳参数值,进行支持向量网络的训练,否则跳转步骤 7。

步骤 11:利用 ABC 算法优化值进行支持向量网络的训练并用于压气机特性曲线的预测。

步骤 12:仿真预测数据的反归一化处理。

步骤 13:模型结果输出。

利用 ABC 智能算法优化 SVM 参数并用于压气机特性表达的流程图如图 3 所示。

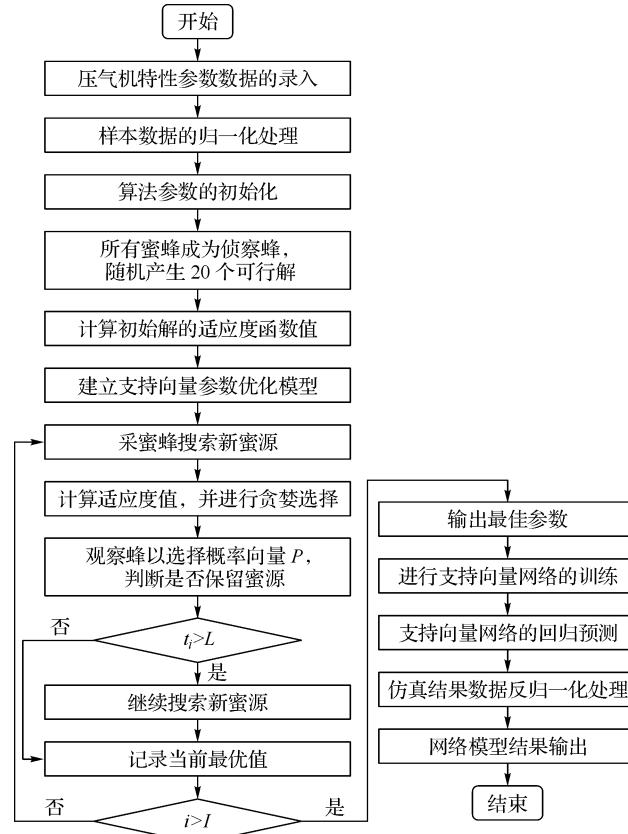


图 3 ABC-SVM 算法用于压气机特性线表达的流程图

### 3 仿真分析

#### 3.1 压气机流量特性的预测

为了验证 ABC 优化 SVM 参数算法对压气机流量特性预测的准确性,从泛化精度及计算耗时的角度,与常用的人工神经网络 BP 算法以及采用 PSO 优化的和基于交叉验证网格寻优法(CV-GS)优化的

SVM模型进行对比。此外,为探究训练样本容量对于仿真预测结果的影响,设置两种对比模型:模型一代表压气机流量特性取样数据点数为140个,用尾数1表示;模型二代表取样数据点数为77个,用尾数2表示。对比同一转速下不同算法的预测性能曲线得到图4~图6所示。

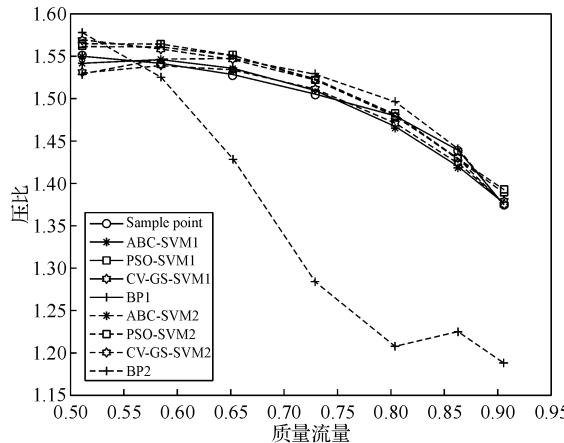


图4 低转速区域流量外推特性的比较

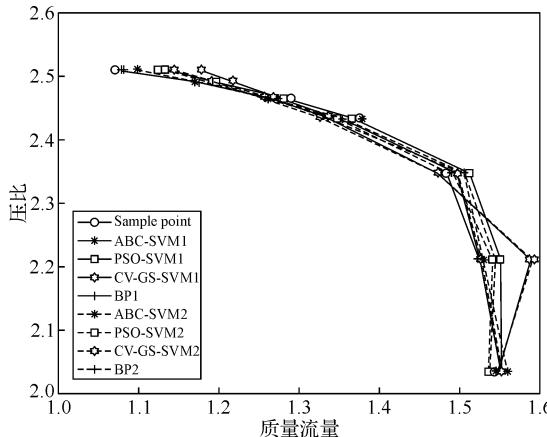


图5 中转速区域流量内插特性的比较

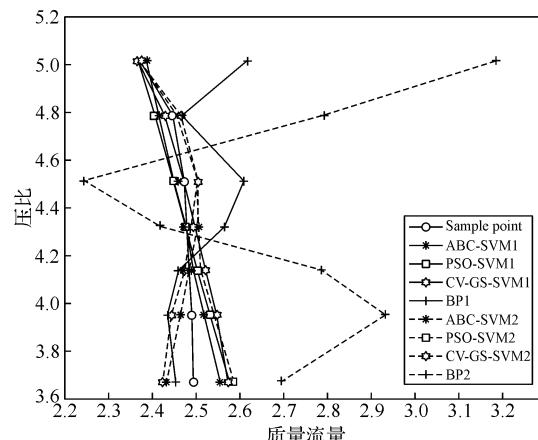


图6 高转速区域流量外推特性的比较

压气机流量特性预测数据的相应柱状残差图如图7~图9所示。其中,样本数据点与预测数据点的误差均取正值,正负号仅用以使用区分不同样本集预测的数据偏离程度。

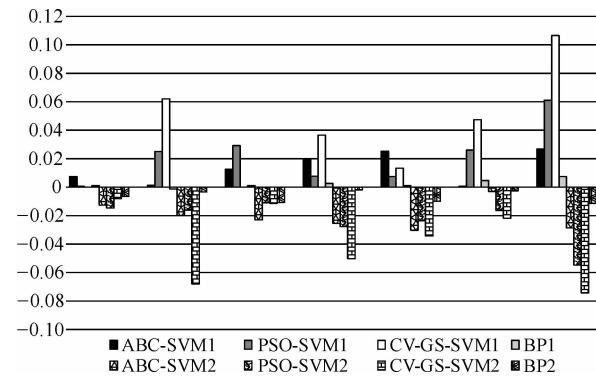


图7 低转速区域流量外推特性的预测残差图

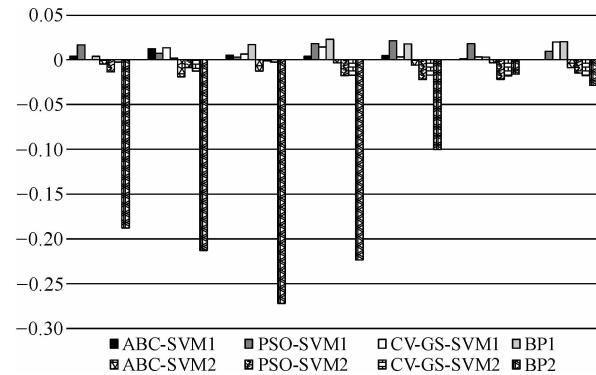


图8 中转速区域流量内插特性的预测残差图

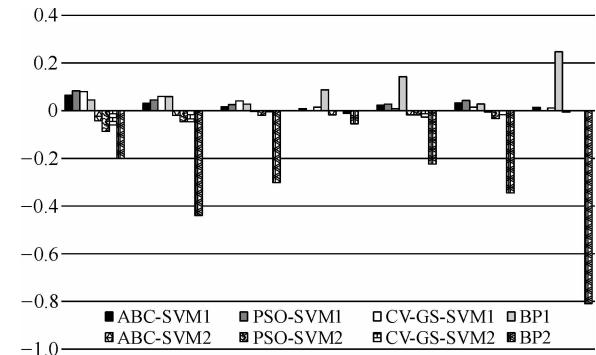


图9 高转速区域流量外推特性的预测残差图

为了进一步比较上述算法对压气机流量特性曲线图内插与外推性能预测的准确性,引入样本数据点与预测数据点的均方根误差(如式(22)所示)作为模型精度的评价指标,如表1所示。

$$E = \sqrt{\frac{\sum_{t=1}^M (O_t - P_t)^2}{M}} \quad (22)$$

表 1 不同算法对压气机流量外推与内插特性预测的精度比较

算法	均方根误差/%			
	低转速外推	中转速内插	高转速外推	总计
ABC-SVM1	0.689 363 22	1.698 728 16	3.016 292 04	2.037 884 25
PSO-SVM1	1.579 179 21	2.959 164 40	4.008 380 10	3.017 591 31
CV-GS-SVM1	1.046 086 03	5.293 335 41	4.040 017 99	3.891 676 64
BP1	1.607 442 87	0.421 412 27	11.405 392 2	6.654 432 96
ABC-SVM2	0.956 006 80	2.166 938 13	2.983 698 54	2.199 395 89
PSO-SVM2	1.593 568 97	2.658 889 36	4.411 445 32	3.112 876 73
CV-GS-SVM2	1.403 315 27	3.858 833 19	3.653 576 72	3.173 248 09
BP2	17.455 833 5	0.694 376 53	40.648 082 3	25.543 785 1

表 2 展示了两种样本容量情况下,上述三种算法对压气机流量特性预测的平均耗时情况。

表 2 不同算法对压气机流量特性预测的平均耗时情况

算法	ABC-SVM1	PSO-SVM1	CV-GS-SVM1	BP1
时间/s	17.728 4	45.666 4	10.102 4	22.514 1
算法	ABC-SVM2	PSO-SVM2	CV-GS-SVM2	BP2
时间/s	4.147 4	8.283 3	4.934 7	10.302 7

从图 4~图 9 及表 1 可知,与其它两种优化算法及常规的 BP 网络模型相比,采用 ABC 算法优化的 SVM 模型具有最优的外推性能,尤其是低转速区的 RMSE 低至 0.69%。虽然 BP 网络模型的内插性能较优,但总体说来,ABC 算法优化 SVM 参数的方法在压气机流量特性图的表达上表现出更佳的泛化性能。由于压气机特性线具有在低转速下过于水平、高转速下过于垂直的特点,使得在高转速区域特性线的模拟计算工作量大,拟合结果精度会相应降低。

然而,总的来说,所预测数据的走势与样本曲线相近,符合实际压气机特性参数的变化规律。同时,也可看出降低实验样本的数量会影响实验预测结果的精度。特别是对于 BP 网络模型,在预测压气机流量特性的外推性能时,误差结果增加幅度较大。虽然经过 ABC 算法优化的 SVM 模型预测压气机流量特性时,性能预测误差增加 7.93%;利用 PSO 算法优化的 SVM 模型预测时,性能预测误差仅增加 3.16%;基于 CV-GS 优化的 SVM 模型预测时,性能预测误差降低 18.46%,但实际上 ABC 算法优化的 SVM 模型仍然具有最佳的预测精度,且不随样本容量的改变而产生精度失准,具有良好的鲁棒性。

从表 2 可知,降低实验数据点的样本量,会减少优化算法的预测时间及 BP 网络模型的训练时间。利用 ABC 算法优化的 SVM 模型预测压气机流量特性时,在小样本容量的测试中搜索运行时间更短,体

现了 SVM 算法在统计样本容量较少时的泛化能力,可以确保良好的计算实时性。

### 3.2 压气机效率特性的预测

基于不同转速的部件特性线表示方法,上述算法对压气机效率特性的预测精度对比如图 10~图 12 所示。类似地,图中尾数 1 代表压气机效率特性的取样数据点数为 180 个,尾数 2 代表取样数据点数为 100 个。

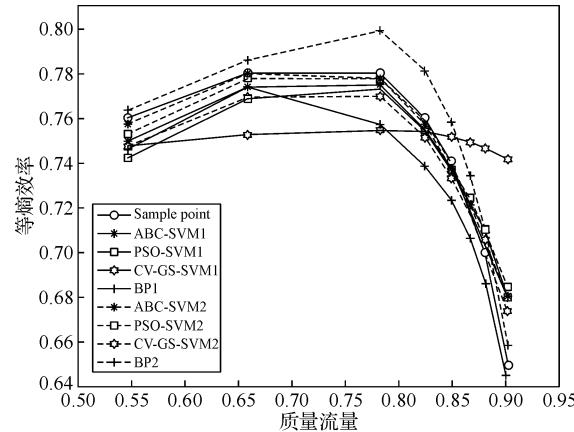


图 10 高转速区域流量外推特性的比较

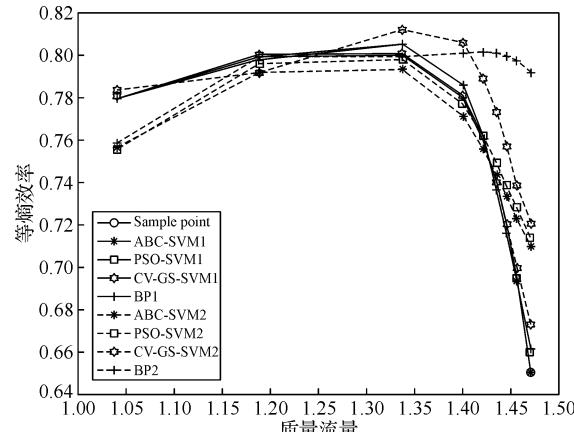


图 11 中转速区域效率内插特性的比较

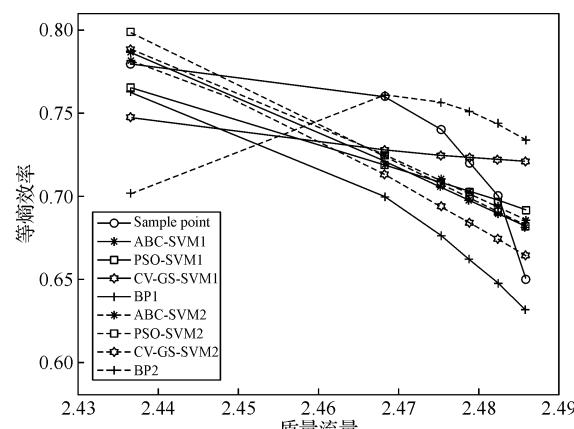


图 12 高转速区域效率外推特性的比较

压气机效率特性预测的相应柱状残差图如图13~图15所示。其中,样本数据点与预测数据点的误差均取正值,正负号仅用以区分使用不同样本集预测的数据偏离程度。

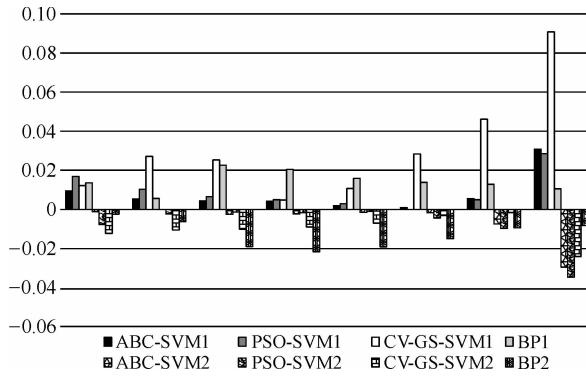


图 13 低转速区域效率外推特性的预测残差图

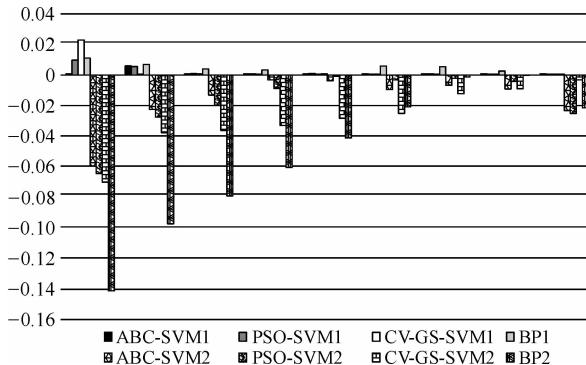


图 14 中转速区域效率内插特性的预测残差图

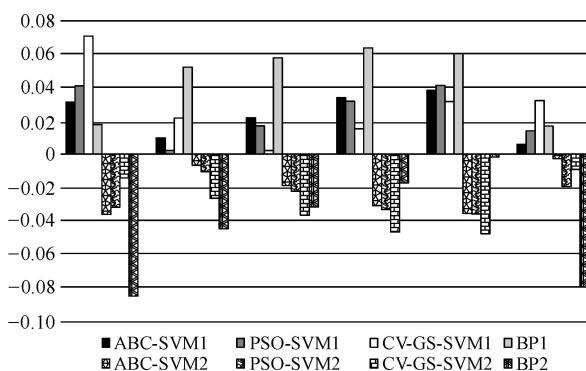


图 15 高转速区域效率外推特性的预测残差图

为进一步比较上述算法对压气机效率特性图内插与外推性能预测的准确性,同样引入样本数据点与预测数据点的均方根误差(RMSE)(如式(22)所示)作为模型精度的评价指标,如表3所示。

表 3 不同算法对压气机效率外推与内插特性预测的精度比较

算法	均方根误差/%			
	低转速外推	中转速内插	高转速外推	总计
ABC-SVM1	1.225	678.13	0.209	654.86
PSO-SVM1	1.339	625.77	0.360	223.33
CV-GS-SVM1	4.059	416.33	0.756	810.19
BP1	1.573	881.81	0.548	245.07
ABC-SVM2	1.098	082.46	2.166	938.13
PSO-SVM2	1.593	568.97	2.367	798.40
CV-GS-SVM2	1.314	220.86	3.424	041.67
BP2	1.385	028.29	6.836	729.47
			5.230	898.03
			5.108	339.39

表 4 展示了上述三种算法在不同样本集下对压气机效率特性预测的平均耗时情况。

表 4 不同算法对压气机效率特性预测的平均耗时情况

算法	ABC-SVM1	PSO-SVM1	CV-GS-SVM1	BP1
时间/s	17.280	49.538	44.393	18.019
算法	ABC-SVM2	PSO-SVM2	CV-GS-SVM2	BP2
时间/s	4.374	10.356	12.982	12.006

从图10~图15及表3可知,与其它两种优化算法及常用的BP网络算法相比,采用ABC算法对SVM参数进行优化的方法在压气机效率特性图的表达上具有更优的内插与外推性能,其内插的RMSE低至0.21%,不仅准确反映了数据的变化趋势,还以极小的误差逼近测试数据。在低转速区域和高转速区域,ABC优化SVM模型的外推性能也能达到最佳。

同时,也可看出降低实验样本的数量会影响压气机效率曲线预测结果的精度,特别是经过BP网络模型预测的压气机效率特性误差增加幅度明显。虽然经过ABC算法优化的SVM模型预测压气机效率特性时,性能预测误差增加32.53%;经过PSO算法优化的SVM模型预测时,性能预测误差仅增加32.04%;基于CV-GS优化的SVM模型预测时,性能预测误差降低8.12%,但ABC算法优化的SVM模型仍然具有最佳的预测精度,且不随样本容量的改变而产生精度失准,具有良好的鲁棒性。

从表4可知,降低实验数据点的样本量会减少优化算法预测及BP网络模型训练的时间。采用ABC算法优化的SVM模型预测压气机效率特性时,在两种统计样本容量的测试中搜索运行时间更短,尤其是在小样本容量下的时间消耗减少到原样本容量下的四分之一,体现了优化后的SVM算法在小样

本时的泛化能力,可以确保良好的计算实时性。

## 4 结论

为克服传统方法对于压气机特性曲线内插与外推性能模拟精度不高的问题以及准确实现变工况条件下燃气轮机热力学的仿真计算,一种基于蜜蜂采蜜行为的人工蜂群算法优化支持向量非线性回归机参数的方法被提出,并用于压气机特性图的表达上。模型的建立与仿真是通过一台 Inter Core I5-4210U @ 2.70 GHz 处理器 PC 端的 MATLAB R2016a 软件平台求解。

(1) 与常用的 BP 网络算法及利用 PSO 和基于 CV-GS 法优化的 SVM 参数模型相比,所提出基于 ABC 算法的优化模型在压气机流量和效率特性曲线的表达上,具有更优的内插与外推性能。所预测数据的走势与样本曲线相近,符合实际压气机特性参数的变化规律。

(2) 改变训练样本的容量,会影响实验预测结果的精度,特别是对于 BP 网络算法模型。相较于其他两种优化模型,虽然基于 ABC 算法的优化模型在压气机性能预测上的误差有所提高,但它仍具有最佳的预测精度,对数据的变动具有良好的鲁棒性,这将有利于实现在后续变工况条件下基于压气机部件特性线行为的相关热力学性能的仿真计算。

(3) 对于压气机特性图的表达,采用 ABC 算法优化的 SVM 模型在两种统计样本容量测试中的搜索运行时间都较短,尤其是小样本容量下的时间消耗明显减少且最低,这将有利于改善基于部件特性线行为的燃气轮机发电机组动态性能仿真模拟的计算实时性。

(4) 采用 ABC 算法优化的 SVM 模型利用小样本数据的机器学习技术,避免了 ANN 的结构选择问题,可以实现全局最优,便于改善后续的基于发动机部件行为性能模型的状态检测、热力学分析、故障诊断及预测等。

## 参考文献:

- [1] 张明升. 燃气轮机性能下降原因分析及其解决方案 [J]. 石化技术, 2019, 26(04): 231.
- [2] 应雨龙, 李靖超, 庞景隆, 等. 基于热力模型的燃气轮机气路故障预测诊断研究综述 [J]. 中国电机工程学报, 2019, 39(3): 731-743.
- [3] TEMPLALEXIS I, PILIDIS P, PACHIDIS V, et al. Development of a 2-D compressor streamline curvature code [C]// Power for Land, Sea, and Air, American Society of Mechanical Engineers. Barcelona, Spain: ASME Turbo Expo, 2006.
- [4] CASEY M, ROBINSON C. A new streamline curvature through flow method for radial turbo machinery [R]. Berlin: ASME Turbo Expo, 2008.
- [5] LEE J J, KIM T S. Development of a gas turbine performance analysis program and its application [J]. Energy, 2011 (36): 5274-5285.
- [6] 杨璐, 郑群, 张海, 等. 轴流压气机吞水后的性能变化研究 [J]. 推进技术, 2017, 38(07): 1499-1506.
- [7] 杨承, 黄志峰, 马晓茜. 联合循环热电联产机组变工况性能分析 [J]. 中国电机工程学报, 2017, 37(12): 3514-3524, 3680.
- [8] SIMANI S, FANTUZZI C, BEGHELLI S. Diagnosis techniques for sensor faults of industrial processes [J]. IEEE Transactions on Control Systems Technology, 2000, 8(5): 848-855.
- [9] LAMBIRIS B, MATHIOUDAKIS K, STAMATISA A, et al. Adaptive modeling of jet engine performance with application to condition monitoring [J]. Journal of Propulsion and Power, 1994, 10(6): 890-896.
- [10] KONG C, KI J, KANG M. A new scaling method for component maps of gas turbine using system identification [J]. Journal of Engineering for Gas Turbines and Power, 2003, 125(4): 979-985.
- [11] GATTO E L, LI Y G, PILIDIS P. Gas turbine off-design performance adaptation using a genetic algorithm [C]// Power for Land, Sea, and Air, American Society of Mechanical Engineers. Barcelona, Spain: ASME Turbo Expo, 2006.
- [12] LI Y G, MARINAI L, PACHIDIS V, et al. Multiple-point adaptive performance simulation tuned to aeroengine test-bed data [J]. Journal of Propulsion and Power, 2009, 25(3): 635-641.
- [13] 潘鹏飞. 于遗传算法的发动机部件级模型设计点匹配 [C]// 全面建成小康社会与中国航空发展. 北京: 中国航空学会, 2013.
- [14] YU Y, CHEN L, SUN F, WU C. Neural-network based analysis and prediction of a compressor's characteristic performance map [J]. Applied Energy, 2007, 81(1): 48-55.
- [15] GHORBANIAN K, GHOLAMREZAEI M. An artificial neural network approach to compressor performance prediction [J]. Applied Energy, 2009, 86(7): 1210-1221.
- [16] 周奎, 刘尚明. 基于数据和神经网络的压气机性能预测研究 [J]. 热力透平, 2017, 46(03): 158-163.
- [17] 黄伟, 常俊, 孙智滨. 基于 MEA-BP 神经网络的压气机特性曲线预测 [J]. 重庆理工大学学报(自然科学), 2019, 33(02): 67-74.
- [18] TSOUTSANIS E, MESKIN N, BENAMMAR M, et al. A component map tuning method for performance prediction and diagnostics of gas turbine compressors [J]. Applied Energy, 2014, 135: 572-585.
- [19] YING Y L, CAO Y P, LI S Y. Study on flow parameters optimisation for marine gas turbine intercooler system based on simulation experiment [J]. International Journal of Computer Applications in Technology, 2013, 47(1): 56-67.

- [20] 丁世飞, 齐丙娟, 谭红艳. 支持向量机理论与算法研究综述  
[J]. 电子科技大学学报, 2011, 40(1):2-10.
- [21] KARABOGA D, An idea based on honey bee swarm for numerical optimization[R]. Turkey: Kayseri, 2005.
- [22] 秦全德, 程适, 李丽, 等. 人工蜂群算法研究综述[J]. 智能系统学报, 2014(2):127-135.

## Expression of Compressor Characteristic Line Based on Artificial Bee Colony Optimization Support Vector Machine Parameters

Xu Siyu, Ying Yulong, Zhou Hongyu, Jin Yaofei, Xie Qiyue

(School of Energy and Mechanical Engineering, Shanghai University of Electric Power, Shanghai 201306, China)

**Abstract:** In order to overcome the difficulty of low simulation accuracy of the interpolation and extrapolation performance of compressor characteristic maps by traditional methods, and to accurately realize thermodynamic simulation calculation of gas turbine based on compressor component characteristic line behavior of under off-design conditions, an novel optimization algorithm for the parameter of support vector machine (SVM) based on artificial bee colony (ABC) and used for expression of compressor characteristic map. It is compared with the general error back propagation (BP) algorithm as well as the SVM model of particle swarm optimization and grid optimization from the perspective of generalization accuracy and calculation time consumption. At the same time, the number of sample sets is reduced to verify the influence of training sample size on experimental results. The prediction performance curves and column residual plots of different algorithms under the same rotation speed are compared. Application analysis shows that the SVM model optimized based on ABC algorithm has better prediction accuracy and real-time calculation in the expression of compressor characteristic lines at different rotational speeds. Moreover, the method does not lose accuracy with the fluctuation of sample size, which has good robustness.

**Key words:** expression of compressor characteristic line; interpolation and extrapolation; support vector machine; artificial bee colony algorithm; parameter optimization