

基于MFOA-GRNN的汽轮机热耗率预测模型

钟震¹,童小忠²,司凤琪¹,任少君¹

(1. 东南大学 能源转换及其过程测控教育部重点实验室,江苏 南京 210096;

2. 浙江浙能技术研究院有限公司,浙江 杭州 311121)

摘要:为提高机组热耗率在线计算的精度与鲁棒性,提出多种群果蝇优化算法(Multi-population fruit fly optimization algorithm, MFOA)和广义回归神经网络(Generalized regression neural network, GRNN)相结合的汽轮机热耗率预测模型。以影响机组热耗率的主要运行参数为输入参数,建立基于GRNN的机组热耗率计算模型,并进一步采用改进的多种群果蝇优化算法优化GRNN模型中的光滑因子。将所建MFOA-GRNN热耗率预测模型应用到某1 000 MW机组中,结果表明该模型具有很好的计算精度,在测量数据发生方差增大、定值偏移等异常情况时该模型也能给出可靠的计算结果,具有较强的泛化能力和鲁棒性,满足实际工程需要。

关键词:热耗率;果蝇优化算法;广义回归神经网络;泛化能力;光滑因子;预测模型

中图分类号:TK261 文献标识码:A DOI:10.16146/j.cnki.rndlgc.2020.02.009

[引用本文格式]钟震,童小忠,司凤琪,等.基于MFOA-GRNN的汽轮机热耗率预测模型[J].热能动力工程,2020,35(2):63-69. ZHONG Zhen, TONG Xiao-zhong, SI Feng-qi, et al. Prediction model of steam turbine heat rate based on MFOA-GRNN[J]. Journal of Engineering for Thermal Energy and Power, 2020, 35(2): 63-69.

Prediction Model of Steam Turbine Heat Rate based on MFOA-GRNN

ZHONG Zhen¹, TONG Xiao-zhong², SI Feng-qi¹, REN Shao-jun¹

(1. Key Laboratory of Energy Thermal Conversion and Control of Ministry of Education, Southeast University, Nanjing, Jiangsu, China, Post Code: 210096; 2. Zhejiang Energy Group Research Institute, Hangzhou, Zhejiang, China, Post Code: 310012)

Abstract: In order to improve the accuracy and robustness of online calculation of unit heat rate, a prediction model of steam turbine heat rate based on multi-population fruit fly optimization algorithm (MFOA) and generalized regression neural network (GRNN) is proposed. Taking the main operating parameters affecting the unit heat rate as input parameters, the calculation model of unit heat rate based on GRNN is established, and the smoothing factor in GRNN model is further optimized by the improved multi-population fruit fly optimization algorithm. The built MFOA-GRNN heat rate prediction model is applied to a 1 000 MW unit, and the results show that the model has good calculation accuracy. The model can also generate reliable calculation results when the variance of measured data increases or the fixed value migration occurs. It shows that the proposed model has strong generalization ability and robustness, which can meet the actual engineering needs.

Key words: heat rate, fruit fly optimization algorithm, generalized regression neural network algorithm, generalization ability, smoothness factor, prediction model

引 言

热耗率是指机组每产生 $1 \text{ kW} \cdot \text{h}$ 电量所消耗的热量,它是汽轮机组最重要的经济性指标之一^[1]。获取准确的热耗率对于机组的经济性评价、运行优化以及节能诊断具有重要意义。

机组热耗率与机组运行参数、热力系统完善程度等密切相关,一般可以根据机组热力试验数据依据热力试验标准计算得到。目前,机组普遍配置了大量数据测点,使得依据机组在线运行数据计算机组热耗率成为可能,其采取的依然是试验标准所提供的计算方法,试验标准可参照 ASME PTC6A - 2000 汽轮机性能试验规程。

但是与试验条件不同,机组在线运行数据会受到测量误差的影响,特别是当传感器出现故障时还会出现错误的测量数据,直接影响试验标准所提方法的可靠性,因此有必要研究准确度高、鲁棒性高的计算方法。为此,研究者们提出了基于机器学习的计算方法。牛培峰等人^[2]利用双层聚类算法与最小二乘支持向量机(LSSVM)算法结合,建立了多模型汽轮机热耗率计算模型,模型具有较高的精确度和鲁棒性,但模型精度受聚类个数和 LSSVM 的结构参数影响较大,需优化的参数较多;张文琴等人^[3]提出基于偏最小二乘算法建立热耗率回归模型;朱誉等人^[4]提出基于 BP 神经网络的汽轮机热耗率计算方法,具有较高的精确度,但 BP 神经网络容易陷入局部最优,鲁棒性和泛化能力较差。

GRNN 是美国学者 SPECHT 等人^[5]在 1991 年提出的一种以非线性回归分析为基础的前馈神经网络,具有结构简单、学习速度快、较强的非线性映射能力和泛化能力等优点。相比于 LSSVM,GRNN 需要调节的参数少,只需调节高斯基函数的宽度系数(光滑因子),最大限度地减少人为因素的影响。因此 GRNN 目前已被广泛应用于凝汽器真空预测^[6]、风速预测^[7]和负荷预测^[8]等领域。

本文提出一种基于 MFOA-GRNN 的汽轮机热耗率预测模型,通过广义回归神经网络建立机组热耗率预测模型,利用改进的多种群果蝇优化算法(MFOA)来优化模型中的光滑因子,进而通过具体算例分析所建模型的预测精度和模型鲁棒性。

1 算法原理

1.1 广义回归神经网络 (GRNN) 算法

GRNN 具有出色的非线性映射能力以及高度的容错性,适用于非线性问题的处理^[9]。GRNN 网络结构与 RBF 相似,但 GRNN 逼近能力更好,学习速度更快,并且在样本数据较少时,预测效果也较好^[10-11]。

GRNN 的网络结构如图 1 所示,主要由输入层、模式层、求和层与输出层共 4 层组成。输入层 $X = [x_1, x_2, \dots, x_n]^T$, 输出层为 $Y = [y_1, y_2, \dots, y_k]^T$ 。其主要理论依据是以样本数据作为后验条件,通过 Parzen 非参数估计,根据最大概率原则求出最佳输出结果。




图 1 GRNN 网络结构图

Fig.1 GRNN network structure diagram

(1) 输入层神经元数目与学习样本中输入向量维数相同,各神经元直接将输入变量传递给模式层。

(2) 模式层中各神经元对应不同的样本,神经元数目等于学习样本的数目,该层神经元传递函数为:

$$p_i = \exp\left[-\frac{(X - X_i)^T (X - X_i)}{2\sigma^2}\right], \quad (i = 1, 2, \dots, n) \quad (1)$$

式中: X —输入变量; X_i —相应神经元对应的学习样本; σ —光滑因子。

(3) 求和层使用两种类型的传递函数进行求和。一种传递函数如式(2)所示,将所有模式层的输出进行算术求和,其中各神经元与模式层的连接权值为 1。另一种传递函数如式(3)所示,其将所有模式层的神经元加权求和,模式层中第 i 个神经元与求和层中第 j 个神经元的连接权值为输出样本中第 j 个元素值。

$$S_D = \sum_{i=1}^n p_i \quad (2)$$

$$S_{N,j} = \sum_{i=1}^n y_{i,j} p_i, (j = 1, 2, \dots, k) \quad (3)$$

(4) 输出层的神经元数目与学习样本中输出向量维数相等,输出函数如式(4)所示,即将求和层中的两类神经元相除。

$$y_j = \frac{S_{N,j}}{S_D}, (j = 1, 2, \dots, k) \quad (4)$$

由上述过程可以看出,广义回归神经网络只需确定一个参数 σ (光滑因子)。若光滑因子取值偏大,会导致输出结果接近所有样本因变量的平均值;若光滑因子取值偏小,则导致输出结果接近训练样本的值,这样会导致模型泛化能力变差,无法达到模型预测的效果。因此 σ 的取值对最终模型的效果十分关键,根据相关文献的研究成果采用改进的FOA算法来获取合适的光滑因子,最终提高模型的精确度。

1.2 改进的果蝇算法

果蝇优化算法(FOA)是由台湾学者潘文超提出的一种群智能优化算法^[12]。果蝇优化算法原理与蚁群算法(ACO)以及粒子群算法(PSO)等智能优化算法相似,但是相比之下,FOA算法结构简单、易于理解、可快速收敛、精度高。因此FOA算法常用来优化其它算法的结构参数。但FOA算法有其自身的局限性,其算法本身是在二维空间寻找全局最优解,无法在三维空间寻找最优解^[13];容易陷入局部最优解从而影响预测精度;果蝇的飞行步长固定不可调,其对最后结果也有影响。因此针对这些缺点,提出了多种群果蝇优化算法(MFOA),该方法首先将种群分为大小相等的几个子种群,各子种群在三维空间各自独立迭代寻优,最终选择全局最优解,另外,采用逐步递减的步长,步长随迭代次数的增加逐渐减小,在一定程度上可以减少寻优次数^[14]。

在查阅相关文献的基础上,针对FOA算法的缺点分别做以下改进:

(1) 扩大空间范围,传统的FOA算法是在二维空间寻找最优解,现扩大到三维空间。

(2) 传统FOA算法只有一个种群,会导致某个果蝇陷入局部最优从而导致整体的局部最优。因此可效仿粒子群优化算法^[15],采用多个种群同时寻优,扩大选择范围从而避免陷入局部最优。

(3) 采用动态步长,步长计算参考式(5),其中 β 为步长修正因子, β 值在0~1之间; r_t 为果蝇移动半径, t 表示迭代次数。

$$r_t = \beta \times r_{t-1} \quad (5)$$

改进后的果蝇优化算法计算步骤如下:

步骤1:设置种群规模 L ,最大迭代步数Step,步长修正因子 β ,以及种群数量 M ,初始化果蝇群体初始位置 $X_{0,m}, Y_{0,m}, Z_{0,m}$, m 表示第 m 个种群。

步骤2:确定各种群果蝇的觅食方向和移动半径 r_t 。

$$\begin{cases} X_{l,m} = X_{0,m} + r_t \\ Y_{l,m} = Y_{0,m} + r_t \\ Z_{l,m} = Z_{0,m} + r_t \end{cases} \quad (l = 1, 2, \dots, L, m = 1, 2, \dots, M) \quad (6)$$

步骤3:计算各种群的味道判定值 $S_{l,m}$,并将其代入适应度函数Fit(对应GRNN预测结果的均方根误差RSME),计算各果蝇的适应度 $F_{l,m}$ 。

$$S_{l,m} = 1 / \sqrt{X_{l,m}^2 + Y_{l,m}^2 + Z_{l,m}^2} \quad (7)$$

$$F_{l,m} = \text{Fit}(S_{l,m}) \quad (8)$$

步骤4:找出各种群中适应度最小的位置 I_{best_m} 及对应的最佳适应度值 F_{best_m} 。

$$[F_{\text{best}_m}, I_{\text{best}_m}] = \min F_{l,m} \quad (9)$$

步骤5:保留各种群最佳适应度值及其对应的坐标,对应种群的其它果蝇飞往该处。

$$X(m) = X(I_{\text{best}_m}) \quad (10)$$

$$Y(m) = Y(I_{\text{best}_m}) \quad (11)$$

$$Z(m) = Z(I_{\text{best}_m}) \quad (12)$$

$$F_{\text{best}}(m) = F_{\text{best}_m} \quad (13)$$

步骤6:比较各种群的最佳适应度值并更新全局最佳适应度值 F_{best} 和最佳位置坐标,如果 $F_{\text{best}} > F_{\text{best}}(m)$ 则

$$X_{\text{best}} = X(m) \quad (14)$$

$$Y_{\text{best}} = Y(m) \quad (15)$$

$$Z_{\text{best}} = Z(m) \quad (16)$$

$$F_{\text{best}} = F_{\text{best}}(m) \quad (17)$$

步骤7:重复步骤2~步骤6,如果迭代次数 $t > \text{Step}$,则迭代结束,输出最终果蝇最佳位置坐标和最佳适应度。

2 热耗率预测模型的建立

2.1 确定影响汽轮机热耗率的主要参数

根据机组运行特性及热耗率的影响因素分析,

选取影响机组热耗的关键因素作为模型输入参数^[16]:负荷、主蒸汽压力、主蒸汽温度、再热蒸汽温度、再热减温水量、凝结水流量、给水压力、给水温度和真空度。

2.2 建立 MFOA-GRNN 热耗率预测模型

确定模型输入、输出参数后,从历史数据库中选择稳态数据,稳态检测方法按照 ASME 机组性能试验规程进行,即 15 min 内,负荷相对平均值波动不超过 2%,主蒸汽压力相对平均值波动不超过 1%。剔除存在失真或者数据不完整的样本,将剩余样本按照一定比例分为模型训练集和模型测试集并将数据标准化。利用 MFOA 算法优化 GRNN 模型的光滑因子,其目标函数(最佳适应度)如式(18)所示。以目标函数值最小为原则,通过给定条件判断是否满足终止条件,将优化得到的参数代入 GRNN 模型,利用给定数据测试模型效果,最终完成 MFOA-GRNN模型的建立。建模流程如图 2 所示。




图 2 MFOA-GRNN 热耗率预测模型流程图
Fig.2 Flow chart of MFOA-GRNN heat rate prediction model

$$\text{Fit} = \min(\sqrt{\frac{1}{n} \sum_{i=1}^n (H_r(i) - H_r^*(i))^2}) \quad (18)$$

式中: H_r —GRNN 模型预测的热耗率值; H_r^* —对应的实际值; n —样本的数量。

3 案例分析

以某电厂 1 000 MW 超超临界凝汽式汽轮机组为对象,建立 MFOA-GRNN 热耗率预测模型。模型的输入参数为负荷、主蒸汽压力、主蒸汽温度、再热蒸汽温度、再热减温水量、凝结水流量、给水压力、给水温度和真空度,输出参数为汽轮机热耗率。从电厂 SIS 数据库中采集 2018 年 6 月份的相关运行数据,采样间隔为 1 min,对运行数据进行稳态筛选和剔除失真数据后,得到负荷率大于 50% 的样本共 9 744 条,以负荷为划分条件,将样本划分为 5 个区间,区间长度为 100 MW,每个区间随机抽取 400 条样本,其中前 320 条作为训练样本,后 80 条作为测试样本。最终的训练样本共计 1 600 条,测试样本共计 400 条,样本顺序按时间先后排列。部分样本如表 1 所示,图 3 和图 4 分别为负荷和热耗率的分布情况。




图 3 负荷分布
Fig.3 Load distribution

3.1 MFOA-GRNN 模型预测结果

根据算法流程,将 MFOA 算法参数初始化,设置最大迭代步数 Step = 100,种群规模 $L = 20$,种群数量 $M = 10$,步长修正因子 $\beta = 0.8$ 。首先利用 MFOA 算法优化 GRNN 模型的光滑因子,经过 100 次迭代计算后,在第 60 步时收敛于坐标 (0.054, 0.106, 0.055),对应的最小 RSME 为 11.87,得到的最佳光滑因子 σ 为 0.1315。具体优化过程如图 5 所示。

表 1 某 1 000 MW 汽轮机组运行数据样本
Tab.1 Running data sample of a 1 000 MW steam turbine unit

序号	热耗率/ kJ · kW ⁻¹ · h ⁻¹	负荷/ MW	主蒸汽压 力/MPa	主蒸汽 温度/℃	再热蒸汽 温度/℃	再热减温水流 量/t · h ⁻¹	凝结水流量/ t · h ⁻¹	给水压 力/MPa	给水温 度/℃	真空 度/%
1	7 654.77	782.64	20.67	600.59	590.69	2.72	1 596.71	23.99	278.89	93.78
2	7 636.63	796.49	21.33	597.24	585.67	1.96	1 637.02	24.78	280.73	93.78
3	7 675.15	794.00	20.86	594.89	582.27	2.33	1 631.06	24.64	280.11	93.77
4	7 666.15	814.84	21.48	594.95	587.39	10.51	1 692.28	25.28	281.45	93.76
5	7 621.72	809.92	21.81	599.86	591.55	0	1 663.06	25.33	284.38	93.72
6	7 520.13	998.05	27.43	600.43	598.87	0	2 084.41	31.91	294.26	92.86
7	7 518.41	997.42	27.63	601.47	599.61	0	2 092.92	32.04	294.41	92.87
...	...	...	...	...	...	...	...	...	...	...
2000	7 847.84	631.76	16.90	601.40	601.47	2.08	1 262.66	19.59	270.00	94.16




图 4 热耗率分布
Fig.4 Heat rate distribution




图 5 MFOA 算法优化过程
Fig.5 MFOA algorithm optimization process

将得到的最佳光滑因子代入到 GRNN 模型中,通过训练样本来训练模型并利用测试样本来检测模型效果。图 6 和图 7 分别展示了 MFOA-GRNN 模型

预测结果的绝对误差和相对误差。由图 4 ~ 图 5 可以发现,预测值与真实值误差较小,相对误差(RE)在 0.8% 以内,平均绝对误差为 18.9 kJ/(kW · h),说明所建模型符合工程需要。




图 6 MFOA-GRNN 模型绝对误差
Fig.6 Absolute error of MFOA-GRNN model

3.2 MFOA-GRNN 模型与其它模型的对比

为进一步了解 MFOA-GRNN 模型的性能,将训练后的模型与 FOA-GRNN 模型、GRNN 模型、BP 模型以及 LSSVM 模型作对比,采用平均相对误差(MRE)、均方根误差(RSME)进行模型性能评测。

$$\text{MRE} = \frac{1}{n} \sum_{i=1}^n \frac{|H_i - H_i^*|}{H_i^*} \times 100\% \quad (19)$$

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (H_i - H_i^*)^2} \quad (20)$$

式中: n —测试样本个数; H_i —模型预测值; H_i^* —对

应样本的实际值。




图 7 MFOA-GRNN 模型相对误差

Fig.7 Relative error of MFOA-GRNN model

经过 FOA 算法优化后的 GRNN 模型光滑因子为 0.056 3。设置未优化的 GRNN 模型光滑因子为 0.5。BP 神经网络层数设为 3 层,学习率为 0.006,隐藏层神经元个数为 10。将 LSSVM 模型中的惩罚因子设为 1804.3,核径向范围设为 72.9,选用 RBF 核函数。预测结果对比如表 2 和表 3 所示。

表 2 不同模型误差分布

Tab.2 Different model error distribution

模型	相对误差 <	相对误差 >	绝对误差范围/ kJ·kW ⁻¹ ·h ⁻¹
	0.5% 的比例	0.8% 的比例	
MFOA-GRNN	0.91	0	[-59.22,65.94]
FOA-GRNN	0.78	0.02	[-68.18,86.42]
GRNN	0.65	0.11	[-112.94,96.50]
BP	0.51	0.19	[-156.96,165.28]
LSSVM	0.69	0.08	[-78.28,89.81]

表 3 不同模型性能对比

Tab.3 Performance comparison of different models

模型	训练数据		测试数据	
	MRE	RMSE/ kJ·kW ⁻¹ ·h ⁻¹	MRE	RMSE/ kJ·kW ⁻¹ ·h ⁻¹
MFOA-GRNN	0.176	12.606	0.245	23.239
FOA-GRNN	0.125	10.092	0.320	30.141
GRNN	0.227	21.509	0.410	38.924
BP	0.086	8.689	0.673	52.227
LSSVM	0.229	22.164	0.371	35.546

由表 2 可以看出,相比于其它模型,经过 MFOA 算法优化后的 GRNN 模型具有更高的精度,MFOA-GRNN 模型预测误差小于 0.5% 的比例为 91%,明显高于其它模型,并且绝对误差范围也较小。由表 3 可看出,BP 模型的训练样本误差较小,但测试样本误差最大,说明 BP 模型泛化能力较差;LSSVM 模型预测精度略高于未经优化的 GRNN 模型,二者均有较好的泛化能力;同时对比 MFOA-GRNN 模型与 FOA-GRNN 模型发现,FOA-GRNN 模型在训练样本中的误差小于 MFOA-GRNN 模型,但在测试样本中误差较大,这是因为后者的光滑因子小于前者,导致训练出的模型预测值偏向于训练数据,在一定程度上导致泛化能力较差。综上,MFOA-GRNN 模型相较其它模型具有更高的精度和更好的泛化能力。

3.3 MFOA-GRNN 模型鲁棒性测试

为测试 MFOA-GRNN 模型的鲁棒性,选取某段连续稳态数据共 80 条,分别测试测量数据方差增大和发生定值偏移时,MFOA-GRNN 模型预测值和式 (21) 计算值的变化,式(21)为汽轮机性能试验时所采用的计算方法。其中前 30 条数据未添加扰动,对后 50 条数据中的主蒸汽温度分别添加 5% 的随机噪声和 5% 负偏置。MFOA-GRNN 模型预测值与计算值以及实际值的比较,如图 8 和图 9 所示。

$$q = \frac{D_{zq} h_{zq} - D_{gs} h_{gs} + D_{zr} h_{zr} - D_{lrr} h_{lrr} - D_{jws} h_{jws}}{P_e} \tag{21}$$

式中: P_e —机组负荷; D_{zq} —主蒸汽流量; D_{gs} —给水流量; D_{zr} —再热蒸汽流量; D_{lrr} —冷再热蒸汽流量; D_{jws} —减温喷水流量; h_{zq} —主蒸汽焓; h_{gs} —给水焓; h_{zr} —再热蒸汽焓; h_{lrr} —冷再热蒸汽焓; h_{jws} —减温水焓。

由图 8 和图 9 可以发现,MFOA-GRNN 对噪声具有较强的抗干扰能力,分别对测试样本中主蒸汽温度添加 5% 的随机噪声和 5% 的负偏置后,模型预测结果与真实值的绝对误差仍然保持在 100 kJ/(kW·h) 以内,而式 (21) 的计算结果与真实值绝对误差明显高于 MFOA-GRNN,最大绝对误差能达到 350 kJ/(kW·h) 左右。这是因为理论计算式很大程度上依赖现场测量数据的准确度,当式中的某个测量值出现较大偏差时,其计算误差也随之增

大。MFOA-GRNN 模型在训练过程中间接确定了每个变量对热耗率的影响程度,通过权重的分配在一定程度上减小了某个参数测量误差的影响,模型具有较强的鲁棒性。




图8 对主蒸汽温度添加5%随机噪声

Fig.8 The main steam temperature with added 5% random noise




图9 对主蒸汽温度添加5%负偏置

Fig.9 Main steam temperature with added 5% offset

4 结 论

针对传统果蝇算法的缺点提出了改进措施,并利用改进后的果蝇算法(MFOA)结合GRNN算法建立热耗率预测模型。

将MFOA-GRNN热耗率预测模型与FOA-GRNN模型、GRNN模型、BP模型、LSSVM模型作对比,MFOA-GRNN模型具有更好的预测精度。

对主蒸汽温度分别添加5%的随机噪声和5%的负偏置后,MFOA-GRNN热耗率模型仍具有较高

的预测精度,表明该模型具有较强的鲁棒性,适用于稳态工况下的热耗率在线计算。

参考文献:

- [1] 刘超,牛培峰,段晓龙,等.基于相关向量机的汽轮机最优运行初压的确定[J].化工学报,2016,67(9):3812-3816.
LIU Chao, NIU Pei-feng, DUAN Xiao-long, et al. Determination of optimal initial steam pressure of turbine based on relevance vector machine[J]. CIESC Journal, 2016, 67(9): 3812-3816.
- [2] 牛培峰,刘超.基于双层聚类与GSA-LSSVM的汽轮机热耗率多模型预测[J].电机与控制学报,2016,20(3):90-95.
NIU Pei-feng, LIU Chao. Multi-model for turbine heat rate forecasting based on double layer clustering algorithm and GSA-LSSVM[J]. Electric Machines and Control, 2016, 20(3): 90-95.
- [3] 张文琴,付忠广,靳涛,等.基于偏最小二乘算法的热耗率回归分析[J].现代电力,2009,26(5):56-59.
ZHANG Wen-qin, FU Zhong-guang, JIN Tao, et al. Heat rate regression analysis based on partial least squares algorithm[J]. Modern Electric Power, 2009, 26(5): 56-59.
- [4] 朱誉,冯利法,徐治皋.基于BP神经网络的热经济性在线计算模型[J].热力发电,2008,37(12):17-19.
ZHU Yu, FENG Li-fa, XU Zhi-gao. An on-line calculation model of thermal economic efficiency based BP neural network[J]. Thermal Power Generation, 2008, 37(12): 17-19.
- [5] Specht D F. A general Regression Neural network[J]. IEEE Transactions on Neural Networks, 1991, 2(6): 568-576.
- [6] 葛晓霞,肖洪闯,蔡宁宁等.基于果蝇算法优化广义回归神经网络的凝汽器真空预测[J].汽轮机技术,2018,60(3):208-212.
GE Xiao-xia, XIAO Hong-chuang, CAI Ning-ning, et al. Vacuum Prediction of Condenser Based on GRNN optimized by fruit fly algorithm[J]. Turbine Technology, 2018, 60(3): 208-212.
- [7] ZHEN H G, JIE W, LU H Y, et al. A case study on a hybrid wind speed forecasting method using BP neural network[J]. Knowledge-Based Systems, 2011, 24(7): 1048-1056.
- [8] 邹红波,伏春林,喻圣.基于Akima-LMD和GRNN的短期负荷预测[J].电工电能新技术,2018,37(1):51-56.
ZOU Hong-bo, FU Chun-lin, YU Sheng. Short-term load forecasting based on Akima-LMD and GRNN[J]. Adv Technol Electral Eng Energ, 2018, 37(1): 51-56.
- [9] 王小川. MATLAB神经网络43个案例分析[M].北京:北京航空航天大学出版社,2013.
WANG Xiao-chuan. 43 Case analysis of Matlab neural network [M]. Beijing: Beijing University of Aeronautics and Astronautics Press, 2013.