

研究论文

DOI: 10.11949/j.issn.0438-1157.20180293

ASOS-ELM 建模方法及在汽轮机热耗率预测中的应用

牛培峰¹, 王泉飞¹, 刘楠², 王愿宁³, 常玲芳¹, 张先臣¹¹燕山大学电气工程学院, 河北 秦皇岛 066004; ²燕山大学, 河北 秦皇岛 066004;³大连海事大学环境科学与工程学院, 辽宁 大连 116026)

摘要: 针对极限学习机(ELM)不能准确地预测汽轮机热耗率的问题, 结合群智能优化算法, 提出一种改进的共生生物搜索算法和极限学习机(ASOS-ELM)综合建模的方法。该方法利用改进的共生生物搜索(ASOS)算法优化 ELM 隐层激活函数的参数, 求得最优的 ELM 模型。再将 ASOS-ELM 模型应用到热耗率建模中, 首先用 ELM 初始化热耗率预测模型, 以输出热耗率的均方根误差(RMSE)作为算法的适应度值, 然后通过 ASOS 算法找到合适的 ELM 参数, 从而得到准确的热耗率预测模型。并将热耗率预测的结果与传统的 ELM 模型、ASOS 算法优化支持向量回归(SVR)模型、改进的粒子群算法(PSO)和基本的共生生物搜索算法(SOS)优化的 ELM 作对比。结果表明, ASOS-ELM 模型在处理复杂的数据模型中, 具有精确的预测能力与快速的收敛速度, 为汽轮机热耗率建模提供了新思路。

关键词: 汽轮机; 热耗率; 算法; 极限学习机; 优化; 模型

中图分类号: TK 267

文献标志码: A

文章编号: 0438—1157 (2018) 09—3924—08

Modeling method of ASOS-ELM and its application in prediction of heat rate of steam turbine

NIU Peifeng¹, WANG Xiaofei¹, LIU Nan², WANG Yuanning³, CHANG Lingfang¹, ZHANG Xianchen¹

(¹School of Electrical Engineering, Yanshan University, Qinhuangdao 066004, Hebei, China; ²Yanshan University, Qinhuangdao 066004, Hebei, China; ³College of Environment Science and Engineering, Dalian Maritime University, Dalian 116026, Liaoning, China)

Abstract: The extreme learning machine (ELM) problem can not quickly and accurately predict heat rate. Combined with swarm intelligence optimization algorithm, an ameliorated symbiotic organisms search algorithm and extreme learning machine (ASOS-ELM) comprehensive modeling method is proposed. This method uses the ameliorated symbiotic organisms search (ASOS) algorithm to optimize the parameters of the ELM hidden layer activation function to obtain the optimal ELM model. Firstly, the initial heat rate prediction model is established with ELM, and the root mean square error (RMSE) of the output heat rate is used as the fitness value of the algorithm. Then the appropriate ELM parameters are found through the ASOS algorithm to obtain an accurate heat rate prediction model. The performance of the heat rate prediction is compared with the traditional ELM model, support vector regression (SVR) model optimized by the ASOS algorithm, ELM optimized by improved particle swarm optimization (PSO) and basic symbiotic organisms search algorithm (SOS). The results show that the ASOS-ELM model has a precise forecasting ability and rapid convergence speed when dealing with complex data models, which provides a new idea for modeling the heat rate of a steam turbine.

2018-03-19 收到初稿, 2018-06-03 收到修改稿。

联系人: 王泉飞。第一作者: 牛培峰 (1958—), 男, 教授。

基金项目: 国家自然科学基金项目 (61573306)。

Received date: 2018-03-19.

Corresponding author: WANG Xiaofei, 353456694@qq.com

Foundation item: supported by the National Natural Science Foundation of China (61573306).

Key words: steam turbine; heat rate; algorithm; extreme learning machine; optimization; model

引言

热耗率是指汽轮机发电机组发出 1 kW·h 的电时所需要消耗的热量,是表现机组性能的一项重要经济指标。精确地预测热耗率值,对电厂汽轮机组安全与经济运行,具有重要的指导作用^[1-2]。

影响热耗率的因素有很多^[3],传统的热耗率计算方法往往不能满足现场需要,为了更准确地预测热耗率,国内外对热耗率回归模型进行了相关研究。张文琴等^[4]通过偏最小二乘(PLS)算法建立热耗率回归分析模型。王惠杰等^[5]提出基于支持向量机(support vector machine, SVM)的热耗率回归模型。文献[6]利用万有引力算法(GSA)与最小二乘支持向量机 LSSVM 结合建立热耗率模型。文献[7]将在线支持向量回归算法(AOSVR)应用在热耗率分析中。虽然, SVM 能较好地解决少样本等实际问题,可是其训练过程需要大量的时间^[8]。人工神经网络则是另一种可行的方法,文献[9]则采用 BP 神经网络对起耗率进行预测,但是该网络训练速度慢,易于陷入局部最优。而 Huang 等^[10]提出的一种单隐层神经网络,极限学习机(extreme learning machine, ELM),具有学习速度快、泛化性能强等特点。ELM 模型为了寻找更好的效果,通常的方法是要寻找最优的隐层节点数,对于复杂的工业模型,往往需要很多的隐层节点;另一种则是采用网格法或反向推理等来设计输入权重和阈值,显然也是不明智的^[11]。

共生生物搜索(symbiotic organisms search, SOS)算法是 Cheng 等^[12]在 2014 年提出的一种新的元启发式优化算法。SOS 算法最大的优点是仅仅需要两个参数(最大迭代次数和种群个数)^[13-15]。因此,它避免了由于错误的调参而导致性能受损的危险。文献[16]成功地将 SOS 算法应用到磁浮系统的自适应模糊反推控制上。文献[17]将 SOS 算法与小波神经网络(WNN)相结合,应用在非线性信道均衡器上。但由于可控的参数过少,不足以适应复杂的工程实际。因此,通过改进互利系数,与其寄生阶段,提出一种改进的共生生物搜索(ameliorated symbiotic organisms search, ASOS)算法,提高了原有算法的搜索和开发能力。再与粒子群算法(particle swarm optimization, PSO)、SOS 算法作对比,验证 ASOS 的寻优能力。并在 ASOS 算法的基础上,优化 ELM

的激活函数,建立 ASOS-ELM 模型,该建模方法能以较少的神经元,较少次的迭代,有效地跟踪热耗率。

本文以 600 MW 超临界汽轮机机组作为研究对象,将 ASOS 与 ELM 相结合,建立 ASOS-ELM 汽轮机热耗率预测模型。并与 ELM 模型、利用 PSO 算法、SOS 算法优化 ELM 的改进模型和 ASOS 优化支持向量回归(support vector regression, SVR)模型进行对比,验证了 ASOS-ELM 模型的优越性。

1 改进的共生生物搜索算法

1.1 共生生物搜索算法

SOS 算法的灵感源于物种在生态系统中生存的共生互动策略。它由自然界中最常见的三种共生关系组成,包括互利共生、偏利共生和寄生^[18-20]。不同的共生关系列举如下。

(1) 互利共生

互利共生是指两种不同个体之间相互有利的关系,例如蜜蜂与花朵。对于个体 i ,随机选取个体 $j(i \neq j)$,两个个体之间的相互联系可以改善适应度值。按式(1)更新

$$\begin{cases} X_{i_new} = X_i + rand(0,1) \times (X_{best} - MV \times BF_1) \\ X_{j_new} = X_j + rand(0,1) \times (X_{best} - MV \times BF_2) \end{cases} \quad (1)$$

$$MV = \frac{X_i + X_j}{2} \quad (2)$$

式中, $rand(0,1)$ 为 $[0,1]$ 之间的随机数。互利系数 BF_1 、 BF_2 为随机数 1 或 2。 X_{best} 为当前迭代的最优个体。 MV 为中间变量,象征两个有机体之间的共同特征,用于提高生存优势。最终保留两者之间较优个体。

(2) 偏利共生

偏利共生是指对一个体有利,对另一个体没有影响。例如鲫鱼与鲨鱼。与互利共生相似,对于个体 i ,随机选择个体 $j(i \neq j)$,在遍历过程中,个体 i 从个体 j 中得利,个体 j 没有任何影响。个体 i 按式(3)更新

$$X_{i_new} = X_i + rand(-1,1) \times (X_{best} - X_j) \quad (3)$$

式中, $rand(-1,1)$ 为 $[-1,1]$ 之间的随机数。 $(X_{best} - X_j)$ 表示个体 j 提供帮助,使个体 i 不断向最优个体靠拢,最终保留两者之间较优个体。

(3) 寄生

寄生是通过两个个体之间的相互作用消除了生

态系统中较弱的有机体。在这种关系中，一方获得利益，另一方则受到这种关系的伤害。例如蚊子和人类。对于个体 i ，随机选择若干维数，替换为搜索范围内的随机值，产生新的个体——寄生向量。随机选取个体 $j(i \neq j)$ ，保留寄生向量与个体 j 中两者较优个体的作为新的个体 j 。

1.2 ASOS 算法

与其他算法相比，SOS 算法基于三种相互作用，不易陷入局部最优和过早收敛。在解决复杂的优化问题上有着很高效率^[21]。但是由于寻优过程的随机性，寻优过程中需要耗费大量的时间，对此，本文提出一种改进方法，改进后的算法有着更好的求解速度与收敛精度。方法具体描述如下。

(1) 改善互利系数

在互利共生阶段，互利系数决定中间变量 MV 的影响效果。然而在 SOS 算法中，只有 1、2 两个常量来控制更新的快慢，制约搜索过程的收敛速度。文献[22]表明，自适应因子可以改善搜索更新的性能。因此，在 SOS 算法搜索过程中，采用自适应的互利系数是更好的选择。

$$BF_1 = 2 - \frac{\text{iter}}{\text{iter-max}} \quad (4)$$

$$BF_2 = 2 - \frac{\text{iter}}{\text{iter-max}} \quad (5)$$

式中，iter 是当前迭代次数，iter-max 是最大迭代次数。改进后的互利系数随迭代次数的增加，逐渐从 2 线性递减到 1。

(2) 精英策略

SOS 算法在寄生阶段通过随机变异，主要是为了增强种群的多样性，可是盲目的随机寄生并不能有效地使个体改善，反而浪费计算资源^[23-24]。为了增加其突变成功概率。作者改变传统寄生策略，首先在整个种群更新开始，进行适应度从小到大排序。将前一半种群分为精英种群，后一半为普通种群。精英种群在寄生阶段，采用式(6)更新寄生向量，并只与普通种群对比，保留两者中较优个体。普通

种群则按传统寄生方式产生寄生向量，与精英种群对比。

$$V_{\text{para}} = X_i + \alpha \times \text{rand}(-1,1) \times X_j \quad (6)$$

式中， V_{para} 是由个体 i 创建的寄生向量， α 是变化系数，取值为 0.01。由精英种群产生的寄生向量，对比普通种群有着更强的竞争性。这种方式既加快了收敛精度，又能很好地跳出局部最优。

ASOS 算法的具体流程如下。

(1) 初始化参数设定，确定种群数量，最大迭代次数；

(2) 计算种群适应度值，依据适应度的大小进行排序；

(3) 确定整个种群中最优值 X_{best} 及最优个体；

(4) 进入“互利共生”阶段，按式(1)进行更新；

(5) 进入“偏利共生”阶段，按式(3)进行更新；

(6) 进入“寄生”阶段，精英种群按式(6)产生寄生向量，普通种群仍按传统方式产生寄生向量；

(7) 当整个种群完成更新操作，进行步骤(8)，否则返回步骤(3)；

(8) 若达到所设的终止条件，即找到最优解；否则返回步骤(2)。

为了验证 ASOS 算法的有效性，采用 5 个标准的数值测试函数对 PSO、SOS、ASOS 进行仿真实验。5 个基准测试函数见表 1，前两个是单峰函数，后三个是多峰函数。参数设置：最大迭代次数 1000 次，可行解维度 40 维，每次仿真实验独立运行 20

表 1 基准测试函数

Name	Function	Range	$f_{\min}$
F1	Sphere	$[-100,100]^n$	0
F2	Scgweifel's problem 1.2	$[-100,100]^n$	0
F3	Ackley	$[-32,32]^n$	0
F4	Griewank	$[-600,600]^n$	0
F5	Rastrigin	$[-5.12,5.12]^n$	0

表 2 3 种算法对基准函数的运行结果

Table 2 Simulation results of three algorithms for benchmark function

Name	PSO			SOS			ASOS		
	mean	Sd	C.I	mean	Sd	C.I	mean	Sd	C.I
F1	2.2154×10^{-2}	1.6018×10^{-2}	1000	7.7957×10^{-271}	0	1000	0	0	559
F2	1.0657×10^4	3.0148×10^3	1000	1.1511×10^{-90}	1.5425×10^{-90}	1000	0	0	967
F3	1.1531×10^{-1}	2.5277×10^{-1}	1000	4.4408×10^{-15}	0	120	8.8817×10^{-16}	0	94
F4	4.3481×10^{-2}	3.3565×10^{-2}	1000	0	0	73.8	0	0	33.2
F5	9.1458×10^1	2.0194×10^1	1000	0	0	86	0	0	30.2

次。ASOS 与 SOS 算法种群个数 20, 为保证最大评价数一致, PSO 种群个数为 80, 学习因子 $c_1=c_2=2$ 。以表格的形式纪录寻优结果的平均值(mean)、标准差(Sd)和平均收敛迭代次数 C.I, 如表 2 所示。

从表 2 可以看出, 在相同条件下, ASOS 对 F1、F2、F4、F5 都能准确地找到最优值, 并且有收敛速度快。对于 F3 函数, 虽然没找到理论最优值, 但也很接近。而 PSO 算法, 对 5 个测试函数都没有达到很好的效果, 尤其是对 F2 函数, 直接陷入局部最优。与 SOS 算法相比, 改进后的 ASOS 算法在收敛精度上, 都能达到最佳精度。对于收敛迭代速度上, 要比 SOS 算法快 2~3 倍。总体说明 ASOS 算法可以平衡算法的探索能力和开发能力, 能更好地应用在实际工程的模型建立上。

2 基于 ASOS 优化 ELM 模型

2.1 极限学习机

ELM 是一种经典的单隐层前馈神经网络, 通过对输入权值与隐层阈值的随机分配, 再设置适当的隐层节点个数, 输出权值就可以计算最小误差来确定^[25-26]。对于任意 N 个随机样本 (x_i, y_i) , 其中 $x_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in R^n$ 表示第 i 个样本的 n 维输入向量, $y_i = [y_{i1}, y_{i2}, \dots, y_{il}]^T \in R^n$ 代表第 i 个样本的 l 维输出向量。设 ELM 隐层节点数为 m 个, 隐层激活函数为 $g(x)$, 则样本输出可表示为

$$y_i = \sum_{j=1}^m W_{j,oh} g(W_{j,in} x_i + b_j) \quad (7)$$

式中, $j=1, 2, \dots, N$; $W_{j,oh}$ 为第 j 个隐层到输出层之间的连接权值; $W_{j,in}$ 为输入层到第 j 个隐层神经元之间的连接权值; b_j 为第 j 隐层神经元的阈值。

ELM 的输出矩阵表示

$$Y = W_{oh} H \quad (8)$$

$$H = \begin{bmatrix} g(w_{1,in} x_1 + b_1) & \cdots & g(w_{1,in} x_N + b_1) \\ \vdots & \ddots & \vdots \\ g(w_{m,in} x_1 + b_m) & \cdots & g(w_{m,in} x_N + b_m) \end{bmatrix}_{m \times N} \quad (9)$$

式中, H 是隐层输出矩阵, W_{oh} 输出权值为

$$W_{oh} = YH^+ \quad (10)$$

式中, H^+ 为 H 的 Moore-Penrose 广义逆。

ELM 模型步骤如下:

- (1) 确定训练样本和隐层节点数;
- (2) 对输入权值矩阵 W_{in} 和隐层阈值 b 进行随机取值;
- (3) 计算隐层输出矩阵 H ;
- (4) 利用式(10)求得输出权值矩阵 W_{oh} 。

2.2 ASOS-ELM 模型

ELM 最大的优势就是不需要设置大量的参数, 在执行过程中也不用调整输入权值与阈值, 这样可以防止沉重的计算负担。然而在 ELM 中, 隐层的输出对训练效果的影响很大, 其中主要是由激活函数控制^[27-28]。采用相同的激活函数并不能提供最佳的解决方案, 因此对激活函数的参数进行优化可以提高模型的泛化能力。

在 ELM 中常见的激活函数是主要是 Sigmoid 函数, 该函数是一种单极函数, 如式(11)所示。

$$g(x, \lambda, \theta) = \frac{1}{1 + e^{[-\lambda(x - \theta)]}} \quad (11)$$

式中, x 是净输入值, λ 是坡度, θ 是函数中心。常规方法是使 λ 和 θ 分别为 1 和 0。由于函数输出随着参数 λ 和 θ 的变化而发生显著变化, 需要选用适当的参数使该节点输出最优。

ASOS-ELM 模型就是通过 ASOS 算法对激活函数进行优化, 找到每个隐层节点中最合适的参数, 建立最优模型。其中, ASOS 算法中每个个体对应一组 λ 和 θ , 即 $v = [\lambda_1, \lambda_2, \dots, \lambda_m, \theta_1, \theta_2, \dots, \theta_m]$, 个体维度为 $2m$ 。并采用均方根误差(RMSE)作为优化问题的目标函数, RMSE 越小表明误差越小、优化能力越强。

$$f(v) = \sqrt{\frac{\sum_{i=1}^N \left\| \sum_{j=1}^m W_{j,oh} g(W_{j,in} x_i + b_j) - y_i \right\|^2}{N}} \quad (12)$$

ASOS-ELM 的流程图如图 1 所示。

2.3 性能测试

为了验证 ASOS-ELM 模型在处理复杂问题时的有效性。利用 4 个经典 UCI 的标准数据集作回归




图 1 ASOS 算法优化 ELM 的流程

Fig.1 ASOS algorithm optimizes the flow chart of ELM

实验, 如表 3 所示。

并与 ELM、PSO 和 SOS 算法分别优化 ELM 模型进行对比。首先对数据集输入输出进行归一化。四种 ELM 模型的隐层节点设为 20 层。三种优化算法最大迭代次数 100, SOS 与 ASOS 算法种群个数 20。其中 PSO 的种群个数 80、学习因子 $c_1=c_2=2$ 。每个模型各独立运行 20 次。并引入 RMSE 作为性能指标, 如表 4、表 5 所示。

表 3 测试数据集

Table 3 Test data sets

Data set	Sample (training/test)	Input number	Output number
California_Housing	20640(10320/10320)	8	1
Auto_price	159(135/24)	15	1
Machine_CPU	209(175/34)	6	1
Servo_data	167(140/27)	4	1

表 4 四种模型对训练样本的均方根误差的比较

Table 4 Comparison of root mean square errors of four models in training samples

Data set	ELM	PSO-ELM	SOS-ELM	ASOS-ELM
California_Housing	1.3698×10^{-1}	1.3366×10^{-1}	1.3436×10^{-1}	1.3242×10^{-1}
Auto_price	6.7593×10^{-2}	5.5370×10^{-2}	4.9583×10^{-2}	5.1540×10^{-2}
Machine_CPU	2.5436×10^{-2}	2.0534×10^{-2}	2.2123×10^{-2}	2.1708×10^{-2}
Servo_data	8.5425×10^{-2}	6.8690×10^{-2}	6.5101×10^{-2}	6.6611×10^{-2}

表 5 四种模型对测试样本的均方根误差的比较

Table 5 Comparison of root mean square errors of four models in test samples

Data set	ELM	PSO-ELM	SOS-ELM	ASOS-ELM
California_Housing	1.3823×10^{-1}	1.3436×10^{-1}	1.3539×10^{-1}	1.3436×10^{-1}
Auto_price	9.3017×10^{-2}	9.5031×10^{-2}	9.7510×10^{-2}	8.6601×10^{-2}
Machine_CPU	5.4605×10^{-2}	7.1442×10^{-2}	6.6643×10^{-2}	4.7549×10^{-2}
Servo_data	1.1049×10^{-1}	1.0247×10^{-1}	1.0198×10^{-1}	9.9214×10^{-2}

从表 4 可以看出, 利用不同的优化算法对 λ 和 θ 优化后, 模型的训练效果比单独 ELM 模型有所提高, 说明对激活函数的优化能改善 ELM 的训练能力。其中以 ASOS-ELM 模型的训练结果最好, 说明 ASOS 算法具有更好寻优能力。从表 5 看出, 对于测试样本的预测结果上, ASOS-ELM 的测试效果都要优于其他三种模型, 尤其数据集 Machine_CPU 和 Servo_data, ASOS-ELM 仍然有着很高的预测精度。相比 PSO-ELM 和 SOS-ELM 则陷入过拟合, 导致预测结果明显变差。因此, 可以表明 ASOS-ELM 有更好的学习能力与泛化能力, 可以应用于汽轮机热耗率预测模型的建立。

3 热耗率模型的建立与仿真

3.1 汽轮机热耗率建模

由于影响热耗率的因素中存在着强耦合、非线性关系^[29-31], 采用 ASOS-ELM 对热耗率建立建模。以 600 MW 超临界汽轮机组为研究对象, 从集散控制系统(DCS)中随机采取不同时间段的数据。从系统中共采集 300 组数据, 270 组作为训练集, 30 组作为测试集。模型的输入为 12 个主要影响汽轮机热耗率的参数(包括负荷、主蒸汽压力、主蒸汽流量、背压等)。模型的输出为热耗率。

ASOS-ELM 模型参数设置为如下: ELM 隐层节点数为 20。ASOS 算法的种群个数为 20, 最大迭代次数 100 次, λ 和 θ 寻优范围为 $[-1, 1]$, 目标函数为最小均方根误差, 即

$$f = \min \sqrt{\frac{\sum (y_i - Y_i)^2}{N}} \quad (13)$$

其中 $i=1, \dots, N$, y_i 为热耗率的预测值, Y_i 为热耗率的实际值。仿真结果如图 2 和图 3 所示。




图 2 训练样本热耗率预测值与实际值对比

Fig.2 Comparison of predicted and actual values of training sample heat rate




图 3 测试样本热耗率预测值与实际值对比

Fig.3 Comparison of predicted and actual values of test sample heat rate

为了进一步体现 ASOS-ELM 建模能力, 分别将 ASOS-SVR 模型和其他三个模型作对比, 各模型独立运行 20 次。ASOS-SVR 模型是利用 libsvm 工具箱实现 SVR 建模, 是通过 ASOS 算法找到最优参数 $(c, g) = (8.099 \times 10^3, 4.344 \times 10^{-3})$ 。图 4 为 ELM 在不同隐层节点数下训练样本与测试样本的 RMSE。在 PSO-ELM 和 SOS-ELM 模型中, 参数设置与上面 ASOS-ELM 模型一致, 其中 PSO 算法的种群个数 80、学习因子 $c_1=c_2=2$ 。图 5 给出 PSO、SOS、ASOS 算法优化 ELM 模型中训练样本的优化过程。




图 4 ELM 模型下训练样本与测试样本的 RMSE

Fig.4 RMSE of training samples and test samples under ELM model




图 5 3 种算法优化 ELM 的迭代过程

Fig.5 Three algorithms optimization iterative process of ELM

3.2 仿真结果及分析

从图 2 可以看出, ASOS-ELM 模型能够很好地对训练样本进行拟合, 表明该预测模型具有较强的学习能力。从图 3 可以看出 ASOS-ELM 模型能够对测试样本中的热耗率有着较好的跟踪, 说明该模型具有较好的泛化与预测能力。

在训练的过程中, 从图 4 可以看出, ELM 模型的训练精度随隐层节点数的增加, 慢慢趋于稳定并

接近于零, 而测试精度仍然有较大的波动。其中在隐层节点为 117 时达到最优结果, 若是隐层节点继续增加, 则 ELM 会发生过拟合。说明 ELM 模型不能很好地预测汽轮机热耗率。从图 5 可以看出, 在隐层节点数只有 20 时, 智能优化算法可以通过优化激活函数, 极大地提高热耗率的训练精度。其中对比 PSO、SOS 算法, ASOS 算法在第 8 次迭代时就已经收敛, 表明 ASOS-ELM 具有收敛速度快、学习能力强等优点。

为了具体表现 ASOS-ELM 模型的性能, 再引入 2 个性能评价指标: 平均绝对百分误差(MAPE)和平均绝对误差(MAE)。表 6 列出各模型的性能指标, 图 6 为 5 种模型测试样本的预测误差盒图, 其中 ELM 模型以隐层节点为 117 来进行对比。




图 6 各模型对测试样本的预测误差盒图对比

Fig.6 Predictive error box plot comparison of each model to test sample

由表 6 可以看出, 5 种建模方法中, ELM 模型和 SOS-ELM 模型, 虽然对训练样本有较好的预测精度, 但是 ELM 模型则需要 117 个隐层节点, 而 SOS-ELM 不管是在收敛速度还是对测试样本的泛化能力上, 比 ASOS-ELM 要差很多。相对于 PSO-ELM 模型, PSO 算法只能比原 ELM 模型精度有所提高, 而 ASOS 则表现出很强的寻优能力。对于 ASOS-SVR 模型, ASOS 能够找到 SVR 最优参数, 与 ASOS-ELM 模型一样都有较好的训练精度, RMSE 都小于 10。但是考虑到 SVR 模型需要长时间的训练, 并且可以看出测试样本的精度变差, 说明其存在过拟合的风险。因此, ASOS-ELM 模型要优于其他 4 个模型。由图 6 可知, 明显看出 ASOS-ELM 模型的误差范围最小, 效果更好, 没有离群点, 而另外 4 个模型不仅误差范围较大, 而且存在离群误差点。明显表明 ASOS-ELM 模型预测更加准确, 能较好地完成任务。

表 6 各模型对热耗率的预测精度

Table 6 Prediction accuracy of each model for heat rate

Model	Hidden node	Training set			Test set		
		RMSE	MAPE	MAE	RMSE	MAPE	MAE
ELM	20	58.2881	1.33×10^{-7}	46.2552	74.1943	4.44×10^{-5}	57.4608
ELM	117	19.4533	2.20×10^{-8}	8.5312	31.8677	1.46×10^{-5}	26.5873
PSO-ELM	20	24.6537	3.49×10^{-8}	18.553	27.3741	2.08×10^{-5}	18.4517
SOS-ELM	20	10.2074	5.98×10^{-9}	7.9754	23.2908	2.44×10^{-5}	12.1947
ASOS-SVR		7.8812	1.11×10^{-7}	4.2975	19.8577	3.57×10^{-5}	16.4387
ASOS-ELM	20	7.0748	2.87×10^{-9}	5.5732	7.3846	1.56×10^{-5}	5.9811

4 结 论

本文提出一种 ASOS-ELM 建模方法, 其中 ASOS 算法采用精英策略与自适应互利系数来改进 SOS 算法, 与 ELM 结合, 寻找最优的 ELM 隐层激活函数中一组参数 λ 和 θ 。为了验证该模型的性能, 通过标准 UCI 数据集与 ELM、PSO-ELM、SOS-ELM 模型进行对比, 证明了该模型具有良好的训练能力与预测能力。再利用 ASOS-ELM 建模方法应用到汽轮机热耗率预测模型的建立中, 以 12 个影响热耗率的因素作为模型输入, 热耗率为模型输出, 最小 RMSE 为目标函数, 从而建立精确的热耗率预测模型。最后比较 ASOS-ELM 和其他 4 种模型的训练过程与预测误差。结果表明, 相比其他模型, ASOS-ELM 模型不仅寻优速度快、训练能力强, 还能准确地反映热耗率与各输入变量间复杂的非线性关系, 具有较高的实用价值。

References

- [1] 邵峰, 黄启龙, 戴维葆, 等. 实用机组定滑压运行曲线试验研究[J]. 动力工程学报, 2013, 33(8): 643-647.
SHAO F, HUANG Q L, DAI W B, *et al.* Experimental research on practical rated-sliding pressure operation curve of power units[J]. Journal of Chinese Society of Power Engineering, 2013, 33(8): 643-647.
- [2] VOUMVOULAKIS E M, HATZIARGYRIOU N D. A particle swarm optimization method for power system dynamic security control[J]. IEEE Transactions on Power Systems, 2010, 25(2): 1032-1041.
- [3] 闫顺林, 兰红颖. 进汽参数变化对汽轮机热耗率影响的分析[J]. 汽轮机技术, 2013, 55(1): 62-64.
YAN S L, LAN H Y. The analysis of effect of steam parameters on turbine heat rate[J]. Turbine Technology, 2013, 55(1): 62-64.
- [4] 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 W Q, FU Z G, JIN T, *et al.* Based on partial least squares algorithm, the heat rate regression analysis [J]. Modern Electric Power, 2009, 26(5): 56-59.
- [5] 王惠杰, 陈林霄, 李洋, 等. 基于 ν -SVM 的汽轮机热耗率回归模型研究[J]. 动力工程学报, 2014, 34(8): 606-611.
WANG H J, CHEN L X, LI Y, *et al.* Study on heat rate regression model of steam turbines based on ν -SVM[J]. Journal of Chinese Society of Power Engineering, 2014, 34(8): 606-611.
- [6] ZHANG W P, NIU P F, LI G Q, *et al.* Forecasting of turbine heat rate with online least squares support vector machine based on gravitational search algorithm[J]. Knowledge-Based Systems, 2013, 39(2): 34-44.
- [7] 李辉. 基于在线支持向量回归算法的电站热耗率模型[J]. 中国电力, 2014, 47(7): 21-25.
LI H. Power plant heat rate model based on online support vector regression algorithm[J]. Electric Power, 2014, 47(7): 21-25.
- [8] 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 C, NIU P F, DUAN X L, *et al.* Determination of optimal initial steam pressure of turbine based on relevance vector machine[J]. CIESC Journal, 2016, 67(9): 3812-3816.
- [9] 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 Y, FENG L F, XU Z G. Online calculation of steam turbine thermal performance based on BP neural network[J]. Thermal Power Generation, 2008, 37(12): 17-19.
- [10] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: theory and applications[J]. Neurocomputing, 2006, 70(1): 489-501.
- [11] 刘厦, 刘石, 任婷. 基于 SA-ELM 的声学层析成像温度分布重建算法[J]. 化工学报, 2017, 68(6): 2434-2446.
LIU S, LIU S, REN T. SA-ELM based method for reconstructing temperature distribution in acoustic tomography measurement[J]. CIESC Journal, 2017, 68(6): 2434-2446.
- [12] CHENG M Y, PRAYOGO D. Symbiotic organisms search: a new metaheuristic optimization algorithm[J]. Computers & Structures, 2014, 139: 98-112.
- [13] EZUGWU E S, ADEWUMI A O, FRINCUI M E. Simulated annealing based symbiotic organisms search optimization algorithm for traveling salesman problem[J]. Expert Systems with Applications, 2017, 77: 189-210.
- [14] SAHA S, MUKHERJEE V. Optimal placement and sizing of DGs in RDS using chaos embedded SOS algorithm[J]. Iet Generation Transmission & Distribution, 2016, 10(14): 3671-3680.
- [15] GUHA D, ROY P, BANERJEE S. Quasi-oppositional symbiotic organism search algorithm applied to load frequency control[J]. Swarm & Evolutionary Computation, 2017, 33: 46-67.
- [16] UROS S, ANDRE S, AMOR C, *et al.* Improved adaptive fuzzy backstepping control of a magnetic levitation system based on symbiotic organism search[J]. Applied Soft Computing, 2017, 56: 19-33.

- [17] NANDAS J, JONWAL N. Robust nonlinear channel equalization using WNN trained by symbiotic organism search algorithm[J]. *Applied Soft Computing*, 2017, **57**: 197-209.
- [18] ZHANG B Y, SUN L J, YUAN H W, *et al.* An improved regularized extreme learning machine based on symbiotic organisms search[C]// *Industrial Electronics and Applications*. IEEE, 2016: 1645-1648.
- [19] 周虎, 赵辉, 周欢, 等. 自适应精英反向学习共生生物搜索算法[J]. *计算机工程与应用*, 2016, **52**(19): 161-166.
- ZHOU H, ZHAO H, ZHOU H, *et al.* Symbiotic organisms search algorithm using adaptive elite opposition-based learning[J]. *Computer Engineering and Applications*, 2016, **52**(19): 161-166.
- [20] LIAO T W, KUO R J. Five discrete symbiotic organisms search algorithms for simultaneous optimization of feature subset and neighborhood size of KNN classification models[J]. *Applied Soft Computing*, 2018, **64**: 581-595.
- [21] EZUGWU A E, ADEWUMI A O. Soft sets based symbiotic organisms search algorithm for resource discovery in cloud computing environment[J]. *Future Generation Computer Systems*, 2017, **76**: 33-50.
- [22] RAO R V, PATEL V. A multi-objective improved teaching-learning based optimization algorithm for unconstrained and constrained optimization problems[J]. *International Journal of Industrial Engineering Computations*, 2014, **5**(1): 1-22.
- [23] LI X, YAO X. Cooperatively coevolving particle swarms for large scale optimization[J]. *IEEE Transactions on Evolutionary Computation*, 2012, **16**(2): 210-224.
- [24] YANG M, OMIDVAR M N, LI C, *et al.* Efficient resource allocation in cooperative co-evolution for large-scale global optimization[J]. *IEEE Transactions on Evolutionary Computation*, 2017, **21**(4): 493-505.
- [25] 徐圆, 黄兵明, 贺彦林. 基于改进 ELM 的递归最小二乘时序差分强化学习算法及其应用[J]. *化工学报*, 2017, **68**(3): 916-924.
- XU Y, HUANG B M, HE Y L. Recursive least-squares TD (λ) learning algorithm based on improved extreme learning machine[J]. *CIESC Journal*, 2017, **68**(3): 916-924.
- [26] 李荣雨, 王立明. 基于 ISOMAP-ELM 的软测量建模及化工应用[J]. *计量学报*, 2016, **37**(5): 548-552.
- LI R Y, WANG L M. Soft measurement modeling and chemical application based on ISOMAP-ELM neural network[J]. *Acta Metrologica Sinica*, 2016, **37**(5): 548-552.
- [27] OJHA V K, ABRAHAM A, SNASEL V. Metaheuristic design of feedforward neural networks: a review of two decades of research[J]. *Engineering Applications of Artificial Intelligence*, 2017, **60**: 97-116.
- [28] OJHA V K, ABRAHAM A, SNASEL V. Simultaneous optimization of neural network weights and active nodes using metaheuristics[C]// *International Conference on Hybrid Intelligent Systems*. IEEE, 2015: 248-253.
- [29] NIU P F, CHEN K, MA Y P, *et al.* Model turbine heat rate by fast learning network with tuning based on ameliorated Krill Herd algorithm[J]. *Knowledge-Based Systems*, 2017, **118**: 80-92.
- [30] LIU C, NIU P, LI G, *et al.* A hybrid heat rate forecasting model using optimized LSSVM based on improved GSA[J]. *Neural Processing Letters*, 2017, **45**(1): 299-318.
- [31] MA Y P, NIU P F, YAN S S, *et al.* A modified online sequential extreme learning machine for building circulation fluidized bed boiler's NO_x emission model[J]. *Applied Mathematics & Computation*, 2018, **334**: 214-226.