

基于双精英进化樽海鞘群算法优化ELM的焦炭价格预测

朱旭辉, 余孝敏, 倪志伟, 夏平凡, 张琛

引用本文

朱旭辉, 余孝敏, 倪志伟, 夏平凡, 张琛. 基于双精英进化樽海鞘群算法优化ELM的焦炭价格预测[J]. 计算机科学, 2023, 50(5): 292-301.

ZHU Xuhui, SHE Xiaomin, NI Zhiwei, XIA Pingfan, ZHANG Chen. [Coke Price Prediction Based on ELM Optimized by Double-elite Evolution Salp Swarm Algorithm](#) [J]. Computer Science, 2023, 50(5): 292-301.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[结合深度学习与改进的极限学习机的集成学习胸腺瘤CT图像预测方法](#)

Thymoma CT Image Prediction Method Based on Deep Learning and Improved Extreme Learning Machine Ensemble Learning

计算机科学, 2022, 49(11A): 211200097-6. <https://doi.org/10.11896/jsjcx.211200097>

[基于分解极限学习机的手写字符识别方法](#)

Handwritten Character Recognition Based on Decomposition Extreme Learning Machine

计算机科学, 2022, 49(11): 148-155. <https://doi.org/10.11896/jsjcx.211200265>

[基于温度以及运行数据的电缆接头绝缘劣化状态预测](#)

Prediction of Insulation Deterioration Degree of Cable Joints Based on Temperature and Operation Data

计算机科学, 2022, 49(10): 132-137. <https://doi.org/10.11896/jsjcx.210900139>

[基于螺旋进化萤火虫算法和BP神经网络的模型及其在PPP融资风险预测中的应用](#)

Model Based on Spirally Evolution Glowworm Swarm Optimization and Back Propagation Neural Network and Its Application in PPP Financing Risk Prediction

计算机科学, 2022, 49(6A): 667-674. <https://doi.org/10.11896/jsjcx.210800088>

[存在CSI估计错误的增强型ELM叠加CSI反馈方法](#)

Enhanced ELM-based Superimposed CSI Feedback Method with CSI Estimation Errors

计算机科学, 2022, 49(6A): 632-638. <https://doi.org/10.11896/jsjcx.210800036>

基于双精英进化樽海鞘群算法优化 ELM 的焦炭价格预测

朱旭辉^{1,2} 余孝敏^{1,2} 倪志伟^{1,2} 夏平凡^{1,2} 张琛³

1 合肥工业大学管理学院 合肥 230009

2 合肥工业大学过程优化与智能决策教育部重点实验室 合肥 230009

3 合肥学院人工智能与大数据学院 合肥 230092

(zhuxuhui@hfut.edu.cn)

摘要 焦炭是焦化企业生产的重要工业原料之一,准确地预测其未来价格趋势对焦化企业制定排产计划具有重要意义。极限学习机(ELM)泛化能力强,计算速度快,适合作为焦炭价格预测的模型,但 ELM 的预测性能受模型关键参数影响较大,故需对其参数进行优化。基于此,文中提出了基于双精英进化樽海鞘群算法的 ELM 焦炭价格预测方法。首先,采用 Logistic 混沌映射,改进的收敛因子、自适应惯性权重和双精英进化机制来改进樽海鞘群算法,提出了双精英进化樽海鞘群算法(MDSSA),提高算法的搜索能力;其次,运用 MDSSA 优化 ELM 的连接权值与阈值,找到 ELM 的最优参数组合,构建 MDSSA-ELM 焦炭价格预测模型;最后,在 8 个基准测试函数上测试 MDSSA 的收敛性能,在实际焦炭价格数据集上对 MDSSA-ELM 模型的预测性能进行实验,实验结果表明,MDSSA-ELM 相比其他方法预测能力更优,MDSSA 相比其他群智能算法搜索能力更强,为焦化企业实现焦炭智慧排产提供了有效的预测工具。

关键词 樽海鞘群算法;极限学习机;双精英进化;焦炭价格预测

中图分类号 TP181

Coke Price Prediction Based on ELM Optimized by Double-elite Evolution Salp Swarm Algorithm

ZHU Xuhui^{1,2}, SHE Xiaomin^{1,2}, NI Zhiwei^{1,2}, XIA Pingfan^{1,2} and ZHANG Chen³

1 School of Management, Hefei University of Technology, Hefei 230009, China

2 Key Laboratory of Process Optimization and Intelligent Decision-making, Ministry of Education, Hefei 230009, China

3 School of Artificial Intelligence and Big Data, Hefei University, Hefei 230092, China

Abstract Coke is one of important industrial raw materials, and accurate prediction of its future price trend has great significance for making production scheduling plans of coking plants. Extreme learning machine(ELM) has strong generalization ability and fast computing speed, and it is suitable as the model of coke price prediction. However, the prediction performance of ELM is greatly affected by its key parameters, and its parameters need to be optimized. Based on this, a coke price prediction method is proposed by optimizing the key parameters of ELM using double-elite evolution salp swarm algorithm. Firstly, the double-elite evolutionary salp swarm algorithm(MDSSA) is proposed by introducing logistic chaotic mapping, improved convergence factor, adaptive inertia weights and double-elite evolutionary mechanism, so as to enhance the search capability of salp swarm algorithm(MDSSA). Secondly, the connection weights and thresholds of ELM are optimized using MDSSA for finding the optimal parameters combination, so as to construct the MDSSA-ELM coke price prediction model. Finally, the convergence performance of MDSSA is validated using 8 benchmark functions, and the prediction ability of MDSSA-ELM model is tested on the actual coke price dataset. Experimental results demonstrate that MDSSA-ELM has stronger predictive capability than other methods, and MDSSA has superior searching ability than other algorithms, which provides an effective prediction tool for coking plants for achieving intelligent production scheduling.

Keywords Salp swarm algorithm, Extreme learning machine, Double-elite evolution, Coke price prediction

1 引言

原料,对国民经济的发展起着重要作用。同时,焦炭未来价格趋势对于焦化企业制定生产计划十分重要,因为焦化企业需要根据焦炭未来价格的变化趋势及时调整生产计划,以提高

焦炭可用于冶金、铸造和化工等,是一种重要的工业

到稿日期:2022-03-28 返修日期:2022-09-18

基金项目:国家自然科学基金(91546108,71521001);安徽省自然科学基金(1908085QG298,1908085MG232);中央高校基本科研业务费专项资金(JZ2019HGTA0053,JZ2019HGBZ0128);安徽省科技重大专项(201903a05020020);过程优化与智能决策教育部重点实验室开放课题

This work was supported by the National Natural Science Foundation of China(91546108,71521001), Natural Science Foundation of Anhui Province, China(1908085QG298,1908085MG232), Fundamental Research Funds for the Central Universities(JZ2019HGTA0053, JZ2019HGBZ0128), Anhui Provincial Science and Technology Major Projects(201903a05020020) and Open Research Fund Program of Key Laboratory of Process Optimization and Intelligent Decision-making(Hefei University of Technology), Ministry of Education.

通信作者:倪志伟(zhiwein@163.com)

企业生产效益。近年来,国家将智能制造作为企业转型的重要手段,通过建设智能工厂来提高企业的生产效率和效益。2015年国务院颁布的《中国制造2025》、2017年工信部颁发的《高端智能再制造行动计划(2018—2020年)》、2019年发改委颁布的《产业结构调整指导目录》以及2021年工信部颁布的《国家智能制造标准体系建设指南(2021版)》都强调了智能制造的重要性,为智能工厂建设提供了有力的制度保障。在焦化企业建设智能工厂的过程中,智慧排产是其中关键的一步,焦炭价格未来趋势预测亦是智慧排产中的重要问题,准确地对其进行预测可以为焦化企业带来较好的效益。因此,亟需对焦炭价格未来趋势进行准确的预测,为焦化企业的智能化建设提供有效的预测工具,以辅助企业实现智慧排产。

焦炭价格未来趋势预测实质上是回归问题,解决上述问题的常用方法主要包括决策树、贝叶斯网络、神经网络、支持向量回归等统计学和人工智能两类方法。Padilla等^[1]利用最相关的关联规则改进非线性回归的时间序列来预测农产品的未来趋势;Tai等^[2]基于后验概率密度函数,使用贝叶斯分类器预测短期股票变化趋势;Dhanapal等^[3]使用决策树回归器对不同农产品价格进行预测并提供了一个有效的作物价格预测系统;Yang等^[4]建立非平稳时间序列ARIMA模型来描述并预测稀土产品价格的动态变化;Du^[5]建立了基于BP神经网络的定价优化模型,用来预测无车运输平台订单的运费价格;E等^[6]使用针对最小二乘支持向量回归的超参数优化的混合模型预测碳价格。上述方法在处理价格预测问题时均存在一定的不足:线性回归模型无法拟合数据复杂的内部关系;贝叶斯网络需获得先验概率,且受属性之间相关性程度影响较大;决策树对连续字段较难预测并且多以较稳定的宏观因素建立树模型;当ARIMA模型预测步长变大时,预测误差也会增大,无法保证较高的预测精度;初始值和节点个数会影响BP神经网络的预测效果,导致模型预测性能不稳定;支持向量回归在处理小规模数据时效率较高,面对大规模数据样本时则训练速度慢,效率低下。

2004年Huang等提出了极限学习机(Extreme Learning Machine, ELM)^[7],开拓了新的预测领域。ELM是一种单层前馈神经网络,其输入权重和偏置可以随机初始化,具有泛化性能好且计算速度快的优势,在一些实际问题中有所应用^[8-10],也为焦炭价格预测问题提供了新的工具,但ELM的主要参数对预测模型的性能影响较大,因此可以通过优化其主要参数来提升预测性能^[11]。例如,Li等^[12]使用鲸鱼优化算法优化ELM的输入权值和偏差两个重要参数,提高了ELM的预测性能;Subudhi等^[13]使用灰狼优化算法对ELM参数进行调整以提高分类精度;Muduli等^[14]利用飞蛾火焰优化算法优化ELM的隐藏节点参数来提升模型的泛化性能。上述方法通过使用群智能算法优化ELM的参数,ELM模型的预测性能得到了一定提升,但所使用的群智能算法存在易产生局部最优、种群多样性差的缺陷。

2017年,Mirjalili等^[15]提出了一种新型群智能优化算法——樽海鞘群算法(Salp Swarm Algorithm, SSA),该算法的思想来源于观察海洋中樽海鞘生物群体的运动过程,仅有一个控制探索与开发的关键参数,模型简单且易实现。Liu等^[16]将上一代群体位置引入领导者位置更新公式中,结合

惯性权重更新位置,使用自适应调整领导者-跟随者数量的策略来平衡SSA的全局和局部搜索;Yu等^[17]通过正态过程搜索增强算法跳出局部最优的能力,并利用gap的震荡机制确保对当前最优解附近的反复开发,从而提升SSA的求解精度和全局搜索能力;Kamel等^[18]通过集成随机突变寻找新的搜索区域,从而避免SSA在不同区域搜索时所产生的停滞,同时使用自适应相关系数关注最有潜力的区域以增强开发过程;Hegazy等^[19]比较了5种混沌映射方式对SSA搜索性能的影响,并且将用于更新个体位置的所有随机变量替换为混沌变量,这样有助于初始种群的遍历分布,提高算法的收敛速度,避免陷入局部最优;Balakrishnan等^[20]通过随机更新个体位置来增强群体探索不同区域的能力,使用Levy飞行机制随机化樽海鞘群位置,这样有助于群体的移动,探索更大的搜索空间,降低SSA陷入局部最优的可能性;Chaabane等^[21]在位置更新公式中引入权重因子来平衡勘探和开发能力,在整个搜索过程中加入控制参数以提高解的质量,通过反向学习平衡SSA的全局和局部搜索能力,以提高算法的收敛精度与收敛速度。虽然上述改进后的算法对樽海鞘群的搜索性能有一定程度的提升,但仍未能完全平衡算法的勘探和开发能力以使得算法性能最佳。

因此,为了更好地平衡SSA的勘探和开发能力,本文提出了双精英进化樽海鞘群算法(Multi-Dynamic Salp Swarm Algorithm, MDSSA),以提高算法的收敛速度和精度,为ELM的参数优化提供高效的计算工具。基于此,首先运用混沌映射、改进的收敛因子、自适应惯性权重与双精英进化策略改进标准樽海鞘群算法;其次使用改进的SSA优化ELM的主要参数(连接权值和阈值),构建MDSSA-ELM预测模型,以实现准确预测焦炭价格的目的,并在实际焦炭价格数据集上进行测试,验证MDSSA-ELM预测模型的有效性、稳定性和显著性。本文的主要贡献如下:

- (1)提出了基于双精英进化的樽海鞘群算法,通过引入混沌映射、改进的收敛因子、自适应惯性权重和双领导者种群迭代进化机制,提高了算法的收敛速度和精度;
- (2)构建了MDSSA-ELM焦炭价格预测模型,运用MDSSA优化ELM的主要参数来提升模型的预测性能;
- (3)提出的MDSSA-ELM模型为焦炭价格预测提供了新的工具。

2 双精英进化樽海鞘群算法

考虑到标准SSA具有控制参数少、模型简单、易实现的优点,本文使用SSA来优化ELM,构建焦炭价格预测模型。为了进一步提升SSA算法的搜索能力,本文还提出了双精英进化樽海鞘群算法,以为ELM的主要参数优化提供高效的优化工具。

2.1 标准樽海鞘群算法

2017年,Mirjalili等^[15]通过观察海洋中樽海鞘生物群体的运动与聚集行为,提出了樽海鞘群算法,该算法是一种新型的群智能优化算法。樽海鞘群通过个体首尾相连形成一条链,然后进行捕食和移动。位于链首的个体是领导者,而链后的樽海鞘个体都是追随者。领导者在链首带领追随者,引导整个樽海鞘群体向最优食物位置前进,其位置更新公式为:

$$x_j^1 = \begin{cases} F_j + c_1((\max_j - \min_j)c_2 + \min_j), & c_3 \geq 0.5 \\ F_j - c_1((\max_j - \min_j)c_2 + \min_j), & c_3 < 0.5 \end{cases} \quad (1)$$

其中,领导者在第 j 维空间的位置表示为 x_j^1 ;食物在第 j 维空间的位置表示为 F_j ;第 j 维空间的取值上边界和取值下边界分别表示为 \max_j 和 \min_j ; c_2 和 c_3 是 0 和 1 之间的随机数, c_2 确定移动步长, c_3 确定移动方向; c_1 是最重要的参数,主要用于控制整个群体的探索能力和开发能力,与当前种群的迭代次数有关,其计算式如下:

$$c_1 = 2e^{-\left(\frac{4t}{T_{\max}}\right)^2} \quad (2)$$

其中, t 为当前迭代次数, T_{\max} 为种群最大迭代次数。

追随者跟随领导者运动,第 i 只追随者的下一次迭代位置由其“当前次迭代位置”和“第 $i-1$ 只个体位置”共同决定,经牛顿运动定理公式化简得到追随者的位置更新公式,如式(3)所示:

$$x_j^i(t) = \frac{1}{2}[x_j^i(t-1) + x_j^{i-1}(t-1)] \quad (3)$$

其中,第 i 只樽海鞘个体在第 t 次迭代时位于第 j 维空间的坐标为 $x_j^i(t)$ 。

2.2 双精英进化樽海鞘群算法

标准樽海鞘群算法的种群随机初始化,易导致算法陷入局部最优。针对上述缺陷,使用 Logistic 混沌映射进行种群初始化,以提高初始种群的遍历性,使初始种群分布更加均匀。为了平衡算法的探索与开发能力,采用逆不完全 Γ 函数替换收敛因子从而更新领导者位置,并引入自适应惯性权重更新追随者位置;为了增加种群多样性,引入双精英进化机制,在每一次迭代前根据种群个体适应度值的优劣,将种群划分为两个子种群,每个种群的前一半个体作为领导者进行更新,后一半个体作为追随者进行更新,以实现双精英进化,从而提升算法的搜索性能。

2.2.1 Logistic 混沌映射的种群初始化

为了测试算法的收敛性能,本文使用表 1 中的 F1-F4 这 4 个单峰测试函数与 F5-F8 这 4 个多峰测试函数进行

实验。各测试函数的最优值均为 0,单峰测试函数主要用于测试算法的局部开发能力,多峰测试函数主要用于测试算法的全局探索和避免陷入局部最优的能力。

SSA 算法的初始种群分布对其收敛速度与寻优能力影响较大,标准 SSA 的初始种群通常是随机生成的,其初始种群的随机性易导致种群分布不均匀。考虑到混沌序列具有非线性、随机性和遍历性的优点,将混沌映射引入到 SSA 的种群初始化中,使初始种群分布更均匀,种群更多样,从而提高算法的寻优能力,而混沌映射主要是通过映射关系在区间 $[0, 1]$ 之间产生混沌序列,并将其映射到种群的搜索空间中。

Li 等^[22]使用 Tent 混沌映射,以更大的概率获得好的初始解位置,加快种群的收敛速度,改善初始解的覆盖空间。本文使用混沌序列常用的 3 种混沌映射生成方式(Logistic, Sine, Iterative)与随机生成方法,在 8 个测试函数上(见表 1)进行对比分析,结果如表 2 所列。

表 1 测试函数

Table 1 Test functions

$F(\cdot)$	Expression
F_1	$F_1(x) = \sum_{i=1}^n x_i^2$
F_2	$F_2(x) = \sum_{i=1}^n x_i + \prod_{i=1}^n x_i $
F_3	$F_3(x) = \sum_{i=1}^n ([x_i + 0.5])^2$
F_4	$F_4(x) = \sum_{i=1}^n ix_i^4 + random[0,1)$
F_5	$F_5(x) = -20A_1 - B_1 + 20 + e$
F_6	$F_6(x) = \frac{1}{4000} \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1$
F_7	$F_7(x) = \frac{\pi}{n} (A_2 + \sum_{i=1}^{n-1} B_2 + C_2) + D_2$ $y_i = 1 + \frac{x_i + 1}{4}$
F_8	$F_8(x) = 0.1(A_3 + \sum_{i=1}^n B_3 + C_3) + D_3$

表 2 随机初始化与混沌映射对比分析

Table 2 Comparative analysis of random initialization and chaotic mapping

Test function		random	logistic	sinusoidal	iterative
F_1	Mean	0.0379	2.6025 × 10 ⁻⁴	1.2845 × 10 ⁻³	2.3870 × 10 ⁻²
	Var	0.0076	5.3904 × 10 ⁻⁸	3.6458 × 10 ⁻⁶	8.0947 × 10 ⁻⁶
F_2	Mean	0.3503	0.0325	0.0929	0.1191
	Var	0.1095	3.8916 × 10 ⁻⁴	4.9906 × 10 ⁻³	6.1030 × 10 ⁻³
F_3	Mean	0.0294	4.5173 × 10 ⁻⁵	2.0914 × 10 ⁻⁴	5.4021 × 10 ⁻³
	Var	0.0024	8.4758 × 10 ⁻¹⁰	5.8316 × 10 ⁻⁸	1.2373 × 10 ⁻⁴
F_4	Mean	0.0571	0.0188	0.0274	0.0366
	Var	0.0019	2.3232 × 10 ⁻⁵	2.5612 × 10 ⁻⁴	2.9853 × 10 ⁻⁴
F_5	Mean	0.1895	0.0105	0.0201	0.1224
	Var	0.0797	5.3709 × 10 ⁻⁵	2.2421 × 10 ⁻⁴	7.2522 × 10 ⁻⁵
F_6	Mean	0.1592	1.3755 × 10 ⁻⁴	2.4880 × 10 ⁻³	3.9200 × 10 ⁻⁶
	Var	0.0185	1.8768 × 10 ⁻⁷	3.8511 × 10 ⁻⁶	1.0035 × 10 ⁻¹¹
F_7	Mean	0.5200	0.0829	0.0942	0.0963
	Var	0.1160	1.6378 × 10 ⁻³	5.0027 × 10 ⁻³	2.6581 × 10 ⁻²
F_8	Mean	0.1301	0.0117	0.0325	0.0225
	Var	0.0312	2.2387 × 10 ⁻⁵	5.2489 × 10 ⁻⁴	2.4230 × 10 ⁻⁴

表 1 中参数的表示如下:

$$\begin{cases} A_1 = \exp\left(-0.2\sqrt{\frac{1}{n}\sum_{i=1}^n x_i^2}\right) \\ B_1 = \exp\left(\frac{1}{n}\sum_{i=1}^n \cos(2\pi x_i)\right) \\ A_2 = 10\sin(\pi y_1) \\ B_2 = (y_i - 1)^2 [1 + 10\sin^2(\pi y_{i+1})] \\ C_2 = (y_n - 1)^2 \\ D_2 = \sum_{i=1}^n u(x_i, 10, 100, 4) \end{cases}$$

$$\begin{cases} A_3 = \sin^2(3\pi x_1) \\ B_3 = (x_i - 1)^2 [1 + \sin^2(3\pi x_i + 1)] \\ C_3 = (x_n - 1)^2 [1 + \sin^2(2\pi x_n)] \\ D_3 = \sum_{i=1}^n u(x_i, 5, 100, 4) \end{cases}$$

由表 2 可知,使用 3 种混沌映射方法初始化种群后,算法的寻优精度都得到了提升,同时可以发现,Logistic 混沌映射方式仅在 F6 测试函数上性能略微弱于 Iterative 混沌映射,但在整体上明显优于其他两种映射方式。因此,通过对比,本文采用 Logistic 混沌映射方式来代替算法的随机初始化,使得初始种群分布更加均匀,计算式如下:

$$Z_{k+1} = \mu Z_k (1 - Z_k) \quad (4)$$

$$X_j^i = \max_j + (\max_j - \min_j) Z_k \quad (5)$$

其中, μ 是 $[0, 4]$ 之间的随机数,且 $z_0 \notin \{0, 0.25, 0.5, 0.75, 1.0\}$, 实验中参数 μ 取值为 3.99; z_i 表示第 i 个混沌变量,取值为 $[0, 1]$;再根据式(5)作逆映射得到种群初始位置。

2.2.2 逆不完全 Γ 函数的收敛因子 c_1

为了更好地平衡算法的全局勘探和局部开发能力,Wang 等^[23]提出了一种基于逆不完全 Γ 函数的收敛因子,该因子随着迭代次数的增加逐渐递减至 0,在迭代前期快速减小,接近线性下降,在迭代后期下降趋势变缓,接近指数下降,能够较好地实现探索与开发的平衡。受此启发,对标准 SSA 中的参数 c_1 运用一种改进的逆不完全 Γ 函数收敛因子,改进后的逆不完全 Γ 函数收敛因子加快了前期下降的速度,能够更好地避免算法陷入局部最优,从而寻得全局最优解,计算式如下:

$$c = c_{\min} + \frac{c_{\max} - c_{\min}}{\lambda_1} \times \text{gammaincinv}\left(\lambda_1, 1 - \frac{t}{T_{\max}}\right) \quad (6)$$

其中,收敛因子 c 的最大值、最小值分别表示为 c_{\max} 和 c_{\min} , t 表示当前迭代次数, T_{\max} 表示最大迭代次数, λ_1 是一个非负的随机变量。此时,领导者位置更新公式如下:

$$x_j^i = \begin{cases} F_j + c((\max_j - \min_j)c_2 + \min_j), & c_3 \geq 0.5 \\ F_j - c((\max_j - \min_j)c_2 + \min_j), & c_3 < 0.5 \end{cases} \quad (7)$$

2.2.3 自适应惯性权重

在 SSA 算法搜索过程中,在迭代前期,前一个体对后一个体影响较大时,可以快速遍历搜索区域进行全局勘探;在迭代后期,前一个体对后一个体影响较小时,有助于局部开发。为了更好地权衡全局勘探和局部开发能力,本文引入自适应惯性权重来更新追随者位置,计算式如下:

$$\bar{\omega} = 0.5(\omega_{\max} - \omega_{\min})c'e^{-\frac{ct}{T}} + \omega_{\min} \quad (8)$$

其中, $c' = c'_{\min} + \frac{c'_{\max} - c'_{\min}}{\lambda_2} \times \text{gammaincinv}\left(\lambda_2, 1 - \frac{t}{T_{\max}}\right)$ 。

此时,追随者位置的更新式如下:

$$x_j^i(t) = \frac{1}{2}[x_j^i(t-1) + \bar{\omega} \cdot x_j^{i-1}(t-1)] \quad (9)$$

2.2.4 双精英进化机制

标准 SSA 在进化中采用单种群进化机制,算法寻优速度较缓慢,为了提升算法的搜索能力,引入双精英进化机制。在 SSA 中,考虑到精英个体在种群进化过程中对追随者有重要的指引作用,本文采用双精英进化机制。首先,算法在每次进行迭代时,按照适应度值的优劣排序,并划分两个子种群;其次,将每一个子种群的前一半适应度值较优的个体作为领导者,将另一半作为追随者;最后,将两个子种群个体根据领导

者和追随者个体的更新方式进行独立进化,从而实现双精英进化,以提升算法的搜索能力。

2.2.5 算法寻优步骤

MDSSA 算法如算法 1 所示。

算法 1 MDSSA 算法

1. 参数初始化,包括:种群规模 N 、最大迭代次数 T_{\max} 、收敛因子 c 、随机变量 c_2 和 c_3 、自适应惯性权重 $\bar{\omega}$ 、搜索空间的上限 \max_j 和下限 \min_j ;
2. 采用混沌映射方式(见式(4)和式(5))对种群进行初始化,生成分布更加均匀的初始种群;
3. 计算 N 个樽海鞘个体的适应度值并排序;
4. 按照适应度值优劣排序后,将排在首位的个体设置为当前种群中最佳食物源位置;
5. 按照适应度值的优劣确定领导者和追随者;
6. 位置更新,分别利用式(6)一式(9)更新领导者和追随者的位置;
7. 若更新迭代后当前种群中最优个体适应度值优于最佳食物源位置,则更新最佳食物源位置,否则保留原食物源位置,并按照步骤 6 更新领导者和追随者的位置;
8. 重复迭代,动态更新樽海鞘个体全局最优解,判断其是否满足最大迭代次数或算法终止条件,如果满足则停止迭代并保存最优解,否则返回步骤 3 继续迭代。

2.3 MDSSA 算法的收敛性和复杂度分析

在本文提出的 MDSSA 算法的优化过程中,初始种群通过混沌序列在解空间中分布更加均匀,使用改进的收敛因子和惯性权重更新领导者和追随者的位置,引入双精英进化机制不断更新樽海鞘个体位置从而寻找全局最优解,全局最优解随着算法的不断迭代而动态更新,直至寻得稳定的最优解,MDSSA 算法的迭代寻优是一个吸收态 Markov 过程,其具有全局收敛性,证明过程见文献[24-25]。

接下来,分别从时间复杂度和空间复杂度两个方面来分析 MDSSA 算法的复杂度。

前者,在初始化过程中, N 只樽海鞘个体为 $O(N)$,其他参数为 $O(1)$;在迭代过程中,计算个体相应适应度值为 $O(N)$,更新领导者和追随者个体位置为 $O(N^2)$,因此算法经过 T_{\max} 次迭代后为 $O(T_{\max} \times N^2)$ 。

后者,在初始化过程中, N 只樽海鞘个体为 $O(N \times D)$;在迭代过程中,更新收敛因子和惯性权重为 $O(N)$,每次迭代更新最佳食物源位置为 $O(N \times D)$,计算最佳食物源及其适应值分别为 $O(D)$ 和 $O(N \times D)$,因此算法经过 T_{\max} 次迭代后为 $O(N \times D)$ 。

3 基于 MDSSA-ELM 的焦炭价格预测模型

为了准确地预测焦炭价格的未来趋势,本文提出了基于 MDSSA 和 ELM 的焦炭价格预测方法。将 ELM 作为预测基模型,运用 MDSSA 对 ELM 的两个重要参数连接权值和阈值进行优化,获得优化后的最佳参数组合并赋值给 ELM,构建焦炭价格预测模型,以实现对焦炭价格的准确预测。

3.1 极限学习机

Huang 等提出的极限学习机^[7]具有运行速度快、运行效率高、模型简单、容易实现的特点。在使用 ELM 的过程中,只需要设置网络的隐层节点数,该算法在实现过程中随机赋值网络的输入权值和偏置参数,无须调整即可产生输出结果,

模型的计算速度快,具有良好的泛化能力^[26]。

极限学习机由输入层、隐含层和输出层组成,其结构如图1所示。假设网络输入层个数表示为 m , 隐含层个数表示为 M , 输出层个数表示为 n , 隐层神经元的激活函数表示为 $g(x)$, 一般选取“sigmoid”函数, 隐层神经元阈值表示为 b_i 。模型输入 N 个不同样本 (x_i, t_i) , $1 \leq i \leq N$, $x_i = [x_{i1}, x_{i2}, \dots, x_{im}]^T \in \mathbf{R}^m$, 表示模型输入的 m 维样本数据, $t_i = [t_{i1}, t_{i2}, \dots, t_{in}]^T \in \mathbf{R}^n$ 表示由输入的样本数据训练得到的 n 维理想输出结果值。




图1 极限学习机网络模型结构

Fig. 1 Structure diagram of extreme learning machine network model

极限学习机的网络模型的数学表达式如下:

$$\sum_{i=1}^m \beta_j g(w_i \cdot x_i + b_i) = o_j, j=1, 2, \dots, n \quad (10)$$

其中,网络输入层节点与第 i 个隐层节点之间的输入权重表示为 $w_i = [\tau w_{i1}, \tau w_{i2}, \dots, \tau w_{im}]^T$; 第 i 个隐层节点与网络输出层节点之间的输出权重表示为 $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{in}]^T$; 模型输出值表示为 $o_i = [o_{i1}, o_{i2}, \dots, o_{in}]^T$ 。

极限学习机的代价函数 E 可表示为:

$$E(\mathbf{S}, \boldsymbol{\beta}) = \sum_{j=1}^n \| o_j - t_j \|^2 \quad (11)$$

其中, $s = (w_i, b_i, i=1, 2, \dots, M)$, w_i 表示输入权值, b_i 表示隐层节点阈值。极限学习机的目标就是寻找能够最小化网络输出值与实际观测值两者之间误差的最优 $\mathbf{S}, \boldsymbol{\beta}$, 即 $\min(E(\mathbf{S}, \boldsymbol{\beta}))$, 可将 $\min(E(\mathbf{S}, \boldsymbol{\beta}))$ 进一步表示为:

$$\min(E(\mathbf{S}, \boldsymbol{\beta})) = \min \| \mathbf{H}(w_1, \dots, w_M, b_1, \dots, b_M, x_1, \dots, x_N) \boldsymbol{\beta} - \mathbf{T} \|^2 \quad (12)$$

其中, 隐层输出矩阵表示为 \mathbf{H} , 输出权重矩阵表示为 $\boldsymbol{\beta}$, 数据样本理想的输出值矩阵表示为 \mathbf{T} , 三者分别定义为:

$$\mathbf{H}(w_1, \dots, w_M, b_1, \dots, b_M, x_1, \dots, x_N) = \begin{bmatrix} g(w_1 x_1 + b_1) \cdots g(w_M x_1 + b_M) \\ \vdots \\ g(w_1 x_N + b_1) \cdots g(w_M x_N + b_M) \end{bmatrix}_{N \times M} \quad (13)$$

$$\boldsymbol{\beta} = [\beta_1^T \cdots \beta_M^T]_{M \times N}^T \quad (14)$$

$$\mathbf{T} = [t_1^T \cdots t_N^T]_{N \times N}^T \quad (15)$$

当 ELM 网络模型中的 $g(x)$ 无限可微时, ELM 的 w_i 和 b_i 能够被随机分配, 此时隐层的输出矩阵 \mathbf{H} 被唯一确定, 因此极限学习机的学习过程可转化为求解一个线性系统 $\mathbf{H}\boldsymbol{\beta} = \mathbf{T}$, 得到的最小二乘解 $\hat{\boldsymbol{\beta}}$ 即为输出权重, 其计算式如下:

$$\hat{\boldsymbol{\beta}} = \mathbf{H}^+ \mathbf{T} \quad (16)$$

其中, \mathbf{H}^+ 是矩阵 \mathbf{H} 的 MP 广义逆^[27], 即 Moore-Penrose 广义逆矩阵, 它是逆矩阵概念的推广, 对于任一 $m \times n$ 阶矩阵 \mathbf{A} , 都存在唯一的 $n \times m$ 阶矩阵 \mathbf{A}^+ , 若满足: $\mathbf{A}\mathbf{A}^+ \mathbf{A} = \mathbf{A}$; $\mathbf{A}^+ \mathbf{A}\mathbf{A}^+ = \mathbf{A}^+$; $(\mathbf{A}\mathbf{A}^+)^* = \mathbf{A}\mathbf{A}^+$; $(\mathbf{A}^+ \mathbf{A})^* = \mathbf{A}^+ \mathbf{A}$, 则称 \mathbf{A}^+ 为 \mathbf{A} 的 Moore-Penrose 广义逆矩阵, 即 MP 广义逆矩阵。该广义逆矩阵常

被应用于求解非一致线性方程组的最小范数最小二乘解, 可使解的形式更为简单, 并保证解的唯一性。

3.2 基于双精英进化的 MDSSA-ELM 焦炭价格预测模型

由于 ELM 模型随机生成的连接权值和阈值会影响模型的预测性能, 因此难以对焦炭价格未来趋势进行准确的预测。为弥补 ELM 随机参数初始化的缺陷, 首先, 本文引入混沌映射、改进的收敛因子、自适应惯性权重和双精英进化机制, 提出了 MDSSA; 其次, 使用 MDSSA 对 ELM 的连接权值和阈值进行优化, 以得到 ELM 网络最佳的参数组合; 最后, 将搜索得到的最佳参数组合赋值给 ELM, 构建出焦炭价格预测模型, 并在测试集进行性能测试, 检验模型的有效性和准确性。MDSSA-ELM 的具体步骤如算法 2 所示。

算法 2 MDSSA-ELM 算法

输入: MDSSA 参数, ELM 参数, 焦炭价格训练集和测试集

输出: 焦炭价格预测结果

1. MDSSA 种群初始化阶段引入 Logistic 混沌映射, 通过混沌序列生成分布更加均匀的初始种群;
2. 将 MDSSA 种群个体代表的参数组合输入 ELM 模型, 在焦炭价格训练集上进行训练, 将训练得到的 MSE 误差作为个体的适应度值;
3. 计算每个海鞘的适应度值, 训练模型, 若训练误差符合问题终止条件则结束训练, 否则继续训练;
4. 根据排序后的适应度值选定当前最佳食物源, 对领导者、追随者位置进行更新, 选择新的最佳食物源及其位置;
5. 判断是否达到最大迭代次数或算法终止条件, 如果满足则停止迭代并保存最优解, 否则返回步骤 2 继续训练;
6. 获得全局最优值以及最优个体位置, 将最优个体代表的参数组合输入 ELM 模型, 构建 MDSSA-ELM 焦炭价格预测模型;
7. 选定数据集中的测试数据作为模型的输入, 输出焦炭价格未来趋势的预测结果。

4 实验

为了评估 MDSSA-ELM 焦炭价格预测模型的性能, 本文选取实际焦炭价格数据集, 从预测误差、拟合系数和运行时间入手来判断模型的预测效果, 并使用其他预测方法对同一数据集进行实验。实验结果表明, 本文模型具有显著的优势, 并验证了其可行性和有效性。

4.1 数据集选取

焦炭是我国重要的工业原料, 同时我国是世界上最大的煤炭、焦炭和生铁的生产国与消费国, 煤、焦、铁三者之间存在价格联动关系^[28]。焦炭是连接煤炭和钢铁的桥梁, 炼焦煤的价格则是焦炭价格的关键影响因素, 焦炭也是钢铁冶金工业重要的生产原料。因此, 这三者之间具有复杂的相关性^[28]。本文从影响焦炭价格的上下游产品价格因素角度出发, 分析影响焦炭价格的指标类型, 如图 2 所示。

本文实验数据来源于国内某焦化厂, 并选取 2010 年 9 月 25 日—2021 年 9 月 1 日期间的 2709 条数据作为训练集和测试集。使用 EM (Expectation-Maximum) 算法^[29] 对缺失值进行填补, 在实验中使用第 $t-1$ 天的样本数据预测第 t 天的焦炭价格。为消除不同量纲的影响, 本文对数据进行归一化处理, 并将焦炭价格数据集随机划分为 3 份, 其中 2 份作为训练集, 剩下的 1 份作为测试集, 在预测完成后对预测值进行反归一化处理, 作出样本观测值与预测值的拟合回归曲线图。

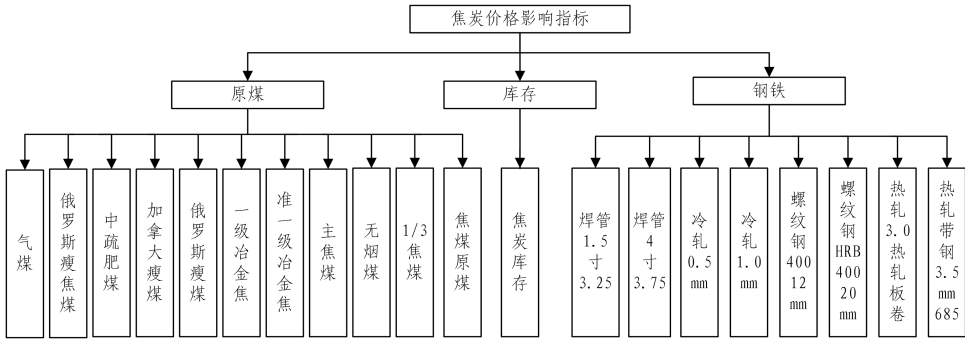


图2 焦炭价格的影响因素指标

Fig. 2 Influencing factors index of coke price

4.2 实验环境和参数设置

本文使用 MATLAB R2021a 编写实验代码,所有实验均独立运行 30 次之后取得最终结果。PC 机的参数为:64 位 Windows 10 操作系统,基于 x64 的处理器系统类型; Intel(R) Core(TM) i5-10600KF 4.10 GHz CPU 的处理器; 16.00GB 的机带 RAM。MDSSA 中所使用的参数设置如表 3 所列。

表3 MDSSA 参数设置

Table 3 Parameter settings of MDSSA

Parameter name	Definition	Value
c_{\max}, c_{\min}	收敛因子 c 的最大值、最小值	3, 0
c'_{\max}, c'_{\min}	收敛因子 c' 的最大值、最小值	2, 0
λ_1, λ_2	随机变量	0.0, 0.01
$\omega_{\max}, \omega_{\min}$	权重系数的最大值、最小值	1, 0.5
α	随机数	0.05
c_2, c_3	随机数	[0, 1]
N	种群规模	30
T_{\max}	最大迭代次数	100

本文采用平均绝对误差 (Mean Absolute Error, MAE)、平均绝对百分误差 (Mean Absolute Percent Error, MAPE)、均方根误差 (Root Mean Square Error, RMSE) 和拟合回归系数 R 作为预测模型性能的评估指标,其计算式如下:

$$MAE = \frac{1}{m} \sum_{i=1}^m |y_i - \hat{y}_i| \quad (17)$$

$$MAPE = \frac{1}{m} \sum_{i=1}^m \frac{|y_i - \hat{y}_i|}{y_i} \quad (18)$$

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2} \quad (19)$$

$$R = \frac{(m \sum_{i=1}^m y_i \hat{y}_i - \sum_{i=1}^m y_i \sum_{i=1}^m \hat{y}_i)^2}{(m \sum_{i=1}^m y_i^2 - (\sum_{i=1}^m y_i)^2)(m \sum_{i=1}^m \hat{y}_i^2 - (\sum_{i=1}^m \hat{y}_i)^2)} \quad (20)$$

其中, y_i 为第 i 天焦炭价格归一化后的真实值; \hat{y}_i 为第 i 天焦炭价格归一化后的预测值; m 为预测天数。

4.3 实验结果分析

4.3.1 参数分析

为了评估所提出的 MDSSA 的收敛性能,我们在表 1 中的 8 个测试函数上进行测试。图 3 和表 4 分别呈现了在不同种群规模下 8 个测试函数所得的最优值变化曲线与结果。




图3 最优值比较结果

Fig. 3 Comparison results of optimal values

由图 3 和表 4 可以看出,随着种群规模的增加,在 8 个测试函数上的寻优结果逐渐逼近最优解;当种群数量超过 30 时,算法的收敛性能提升不明显。同时,在不同迭代次数下的实验结果如图 4 所示,由图 4 可以看出,迭代次数达到 100 次左右时,算法的寻优结果趋于稳定,表明了算法具有较好的收敛性能。因此,本文建议将 N 设置为 30, T_{\max} 设置为 100。实验中输入层的输入为数据集中包含的 20 个影响焦炭价格的因素,输出层的输出为焦炭价格。因此,根据焦炭价格数据集,将 ELM 的 m 和 n 分别设置为 20 和 1。为了获得隐层神经元的最佳规模,本文分析了在不同隐层神经元规模下的误差、拟合回归系数的均值和方差,如表 5 和图 5 所示。

由表 5 和图 5 可知,随着隐层神经元规模的增大,误差逐渐减小,拟合回归系数逐渐变大;当隐层神经元规模超过 30 后,再继续增大神经元规模,误差减小不明显,拟合回归系数变化亦不明显,同时,继续增大神经元规模会大幅提高计算复杂度。因此,本文将 ELM 的隐层神经元规模设置为 30。

表4 不同搜索个体数量得到的最优值结果

Table 4 Optimal value results obtained by different number of search individuals

Parameter	20	25	30	35	40
F1	7.0124×10^{-4}	7.0096×10^{-4}	6.9986×10^{-4}	6.9931×10^{-4}	6.9918×10^{-4}
F2	7.1589×10^{-4}	7.0144×10^{-4}	6.9068×10^{-4}	6.9045×10^{-4}	6.9040×10^{-4}
F3	7.2478×10^{-4}	7.2216×10^{-4}	7.1564×10^{-4}	7.1505×10^{-4}	7.1490×10^{-4}
F4	7.0708×10^{-4}	6.8943×10^{-4}	6.7961×10^{-4}	6.7939×10^{-4}	6.7896×10^{-4}
F5	7.2242×10^{-4}	7.1740×10^{-4}	6.9890×10^{-4}	6.9882×10^{-4}	6.9815×10^{-4}
F6	7.3736×10^{-4}	7.3061×10^{-4}	7.2146×10^{-4}	7.2135×10^{-4}	7.2117×10^{-4}
F7	7.2315×10^{-4}	7.1260×10^{-4}	7.1039×10^{-4}	7.1006×10^{-4}	7.0918×10^{-4}
F8	7.2787×10^{-4}	7.1633×10^{-4}	7.1555×10^{-4}	7.1454×10^{-4}	7.1406×10^{-4}




图 4 不同迭代次数收敛曲线图

Fig. 4 Convergence curve at different iteration times

表 5 不同隐元个数误差指标结果

Table 5 Results of error metrics with different number of hidden elements

Element number	Variable name	MAE	MAPE	RMSE	R
20	Mean	0.0623	0.6657	0.0816	0.9696
	Var	2.3336×10^{-4}	0.1020	4.2378×10^{-4}	2.6186×10^{-4}
25	Mean	0.0491	0.4794	0.0638	0.9817
	Var	1.3682×10^{-4}	0.0320	1.8399×10^{-4}	6.3768×10^{-5}
30	Mean	0.0301	0.2867	0.0400	0.9932
	Var	9.0684×10^{-6}	0.0048	1.1738×10^{-5}	1.3092×10^{-6}
35	Mean	0.0317	0.3352	0.0417	0.9924
	Var	2.5600×10^{-5}	0.0050	3.8634×10^{-5}	4.9988×10^{-6}
40	Mean	0.0323	0.3530	0.0426	0.9920
	Var	2.6416×10^{-5}	0.0088	4.7828×10^{-5}	6.7681×10^{-6}




图 5 各指标均值直方图

Fig. 5 Histogram of mean value of each indicator

4.3.2 MDSSA 性能测试

为了测试改进的算法(MDSSA)在低维和高维空间中的搜索性能,本文使用表 1 中的 8 个测试函数,针对不同的维度 ($dim=2, 5, 10, 20$),将所提出的 MDSSA 与标准 SSA 和 ISSA^[30]作对比,比较在不同维度下 8 个测试函数重复运行取得的最优值、最劣值、均值以及方差,实验结果如表 6 所列。由表 6 可知,MDSSA 算法在 8 个测试函数上的收敛性能明显优于标准 SSA,相比 ISSA,MDSSA 在收敛性能方面也表现出一定的优势,在 8 个测试函数上收敛精度整体上优于 ISSA。

表 6 SSA,ISSA 与 MDSSA 的寻优性能对比结果

Table 6 Comparison results of optimization performance of SSA,ISSA and MDSSA

Test function		Best value	Worst value	Mean	Var
F1($dim=20$)	SSA	7.0527×10^{-16}	2.6651×10^{-15}	1.8342×10^{-15}	2.2010×10^{-31}
	MDSSA	1.3799×10^{-21}	6.5674×10^{-17}	5.7450×10^{-18}	2.0373×10^{-34}
	ISSA	3.5040×10^{-17}	8.8135×10^{-16}	3.2708×10^{-16}	3.9605×10^{-32}
F2($dim=10$)	SSA	9.8532×10^{-9}	1.9295×10^{-8}	1.4945×10^{-8}	4.9399×10^{-18}
	MDSSA	1.2463×10^{-11}	1.3485×10^{-9}	1.6004×10^{-10}	6.0695×10^{-20}
	ISSA	6.0701×10^{-9}	4.4434×10^{-9}	2.6802×10^{-9}	1.3201×10^{-18}
F3($dim=5$)	SSA	1.1551×10^{-10}	3.7023×10^{-8}	1.7969×10^{-9}	4.4748×10^{-17}
	MDSSA	4.4409×10^{-16}	7.4385×10^{-15}	2.4795×10^{-15}	3.0937×10^{-30}
	ISSA	2.1827×10^{-13}	8.9098×10^{-10}	2.3147×10^{-10}	9.0694×10^{-20}
F4($dim=2$)	SSA	5.6917×10^{-5}	6.1796×10^{-3}	1.9664×10^{-3}	2.8520×10^{-6}
	MDSSA	1.8573×10^{-5}	9.6785×10^{-4}	4.1250×10^{-4}	7.2451×10^{-8}
	ISSA	2.8476×10^{-5}	8.9819×10^{-4}	5.1057×10^{-4}	7.3133×10^{-8}

(续表)

Test function		Best value	Worst value	Mean	Var
$F5(dim=20)$	SSA	8.8756×10^{-9}	1.5717×10^{-8}	1.2266×10^{-8}	2.4707×10^{-18}
	MDSSA	4.0374×10^{-11}	8.5260×10^{-9}	1.4566×10^{-9}	2.9947×10^{-18}
	ISSA	3.8621×10^{-9}	1.4290×10^{-8}	8.6140×10^{-9}	7.7472×10^{-18}
$F6(dim=10)$	SSA	2.1094×10^{-15}	8.9928×10^{-15}	5.4845×10^{-15}	3.4169×10^{-30}
	MDSSA	0	1.2213×10^{-15}	9.6219×10^{-17}	5.5028×10^{-32}
	ISSA	4.4409×10^{-16}	7.4385×10^{-15}	2.4795×10^{-15}	3.0937×10^{-30}
$F7(dim=5)$	SSA	1.2626×10^{-4}	7.0432×10^{-1}	8.2037×10^{-2}	2.6176×10^{-2}
	MDSSA	1.1640×10^{-5}	9.5538×10^{-4}	4.0395×10^{-4}	7.6574×10^{-8}
	ISSA	9.0475×10^{-5}	4.9277×10^{-2}	1.1332×10^{-2}	1.7562×10^{-4}
$F8(dim=2)$	SSA	1.3000×10^{-13}	2.6000×10^{-5}	1.2000×10^{-6}	2.5000×10^{-11}
	MDSSA	4.0938×10^{-14}	2.9073×10^{-6}	2.4569×10^{-7}	3.6496×10^{-13}
	ISSA	4.5876×10^{-13}	1.7419×10^{-5}	8.4458×10^{-7}	1.0199×10^{-11}

这表明了本文提出的 MDSSA 在寻优性能方面的优势,同时也表明了 MDSSA 的有效性和稳定性。

4.3.3 MDSSA-ELM 预测结果分析

为了测试 MDSSA-ELM 预测模型的性能,本文从与其他预测模型方法进行对比实验和显著性检验两个方面来证明模型的有效性 with 显著性。对比 ELM,SVR,BP 这 3 种模型的

预测性能,实验结果如表 7 所列。由表 7 可知,ELM 的预测结果误差较小,拟合回归系数优于 BP,且运行时间短。SVR 也取得了较好的拟合结果,但其运行时间较长,预测误差较大。因此,总体来说,ELM 的预测性能具有一定的优势。此外,将 MDSSA-ELM 预测模型与标准 ELM 模型、SSA-ELM 预测模型、ISSA-ELM 预测模型进行对比分析,结果如表 8 所列。

表 7 ELM,BP 与 SVR 的对比结果

Table 7 Comparison results of ELM,BP and SVR

Model		MAE	MAPE	RMSE	R	Time
ELM	Mean	0.1142	1.0716	0.1425	0.9164	0.0090
	Var	2.7289×10^{-4}	0.0735	3.2688×10^{-4}	3.5910×10^{-4}	1.9149×10^{-7}
BP	Mean	0.2146	0.2910	0.2965	0.6821	1.4615
	Var	3.4802×10^{-3}	0.0094	5.5701×10^{-3}	0.0115	0.0238
SVR	Mean	1.0018	3.4602	1.0614	0.9550	300.9720
	Var	1.4560×10^{-4}	0.0146	1.0525×10^{-4}	1.4920×10^{-5}	0.5818

表 8 MDSSA-ELM 与其他预测模型的对比结果

Table 8 Comparison results of MDSSA-ELM and other predictive models

Model		MAE	MAPE	RMSE	R	Time
ELM	Mean	0.1142	1.0716	0.1425	0.9164	0.0090
	Var	2.7289×10^{-4}	0.0735	3.2688×10^{-4}	3.5910×10^{-4}	1.9149×10^{-7}
SSA-ELM	Mean	0.0441	0.3366	0.0570	0.9777	10.0928
	Var	3.9073×10^{-5}	0.0110	5.3036×10^{-5}	3.2120×10^{-5}	0.0537
ISSA-ELM	Mean	0.0369	0.2834	0.0479	0.9843	10.1360
	Var	2.0249×10^{-5}	0.0046	3.1479×10^{-5}	1.3620×10^{-5}	0.0228
WOA-ELM	Mean	0.0681	0.5106	0.0869	0.9474	10.2331
	Var	1.3648×10^{-4}	0.0344	2.1482×10^{-4}	3.0550×10^{-4}	0.0099
GWO-ELM	Mean	0.0474	0.3784	0.0614	0.9735	10.3522
	Var	8.6683×10^{-5}	0.0165	1.4047×10^{-4}	1.2721×10^{-4}	0.0102
MFO-ELM	Mean	0.0684	0.5079	0.0878	0.9468	10.4174
	Var	8.9306×10^{-5}	0.0357	1.5485×10^{-4}	2.1708×10^{-4}	0.0267
MDSSA-ELM	Mean	0.0238	0.1973	0.0352	0.9916	10.2070
	Var	1.5420×10^{-6}	0.0010	1.2869×10^{-6}	2.9265×10^{-7}	0.0335

由表 8 可知,MDSSA-ELM 在运行时间上有所增加,但其预测精度获得了较为显著的提升,预测结果明显优于标准 ELM。在均值方面,相比 SSA-ELM,MDSSA-ELM 在 MAE,MAPE 和 RMSE 这 3 个误差指标上分别减少了 0.0203,0.1393,0.0218,同时回归系数 R 提升了 1.39%,相比 ISSA-ELM,MDSSA-ELM 在 MAE,MAPE 和 RMSE 这 3 个误差指标上分别减少了 0.0131,0.0861,0.0127,同时回归系数 R 提升了 0.73%,仅在运行时间上略存在劣势,表明了 MDSSA-ELM 预测模型的有效性;在方差方面,MDSSA-ELM 除了在运行时间上较 SSA-ELM 与 ISSA-ELM 存在较小差距,在其他 4 个指标上均优于 SSA-ELM 与 ISSA-ELM,

表明了 MDSSA-ELM 预测模型的稳定性。同时,图 6 给出了 4 种模型的预测值与样本观测值的拟合回归曲线。由图 6 可以看出,本文提出的预测模型的拟合效果明显优于其他模型,相比 SSA-ELM 模型与 ISSA-ELM 模型,MDSSA-ELM 的拟合误差更小、效果更佳。此外,MDSSA-ELM 预测模型相比标准 ELM 模型具有显著优势。综上所述,MDSSA-ELM 具有较好的有效性和稳定性。

将 MDSSA-ELM 与 WOA-ELM^[31],GWO-ELM^[32] 和 MFO-ELM^[33] 这 3 种预测模型进行对比分析,进一步检验了本文提出的 MDSSA-ELM 模型的预测效率,然后将对比方法中的 N 与 T_{\max} 两个参数值与表 3 进行相同的设置,3 种对比

模型的其他参数与文献中保持一致,实验结果如表 8 所列。




图 6 ELM,SSA-ELM,ISSA-ELM 与 MDSSA-ELM 样本拟合回归图

Fig. 6 Sample fitting regression diagram of ELM, SSA-ELM, ISSA-ELM and MDSSA-ELM

由表 8 可知,相比 WOA-ELM, GWO-ELM 和 MFO-ELM 这 3 种预测模型,本文提出的 MDSSA-ELM 预测模型除了在算法运行时间方面存在微弱差距外,其他指标的均值与方差结果均优于 3 种对比模型,这进一步表明了 MDSSA-ELM 预测模型的有效性和稳定性。同时,图 7 给出了以上 4 种模型的预测值与样本观测值的拟合回归曲线。由图 7 可以看出,本文提出的预测模型的拟合效果均优于其他模型,其

拟合程度最高,预测效果最好。




图 7 MDSSA-ELM 与其他模型样本拟合回归图

Fig. 7 Sample fitting regression diagram of MDSSA-ELM and other models

最后,为了检验本文提出的 MDSSA-ELM 预测模型的预测结果与其他模型有显著性差异,本文进行了如表 9 所列的 T 检验分析,对两两成对的数据进行测试, $H=1$ 也就是 P 值小于 0.05 时表示假设 H_0 被拒绝,表明 MDSSA-ELM 与其他方法之间存在显著性差异,否则两组数据差异不显著^[34]。表 9 的结果显示,MDSSA-ELM 与对比算法进行比较所得的 P 值大部分都小于 0.05,表明了本文提出 MDSSA-ELM 模型与其他模型之间存在显著性差异。上述结果表明了本文提出的 MDSSA-ELM 模型的显著性。

表 9 MDSSA-ELM 与对比预测模型的 T 检验结果

Table 9 T test results of MDSSA-ELM and comparative prediction models

Prediction model	MAE		MAPE		RMSE		R		Time	
	P value	H	P value	H	P value	H	P value	H	P value	H
MDSSA-ELM vs BP	4.2479×10^{-17}	1	1.5000×10^{-5}	1	5.0928×10^{-18}	1	8.6127×10^{-16}	1	4.6984×10^{-84}	1
MDSSA-ELM vs SVR	2.1211×10^{-137}	1	4.7861×10^{-23}	1	4.0949×10^{-142}	1	2.2412×10^{-50}	1	2.6098×10^{-115}	1
MDSSA-ELM vs ELM	1.6393×10^{-23}	1	2.9765×10^{-17}	1	1.8014×10^{-24}	1	1.6586×10^{-19}	1	2.0995×10^{-52}	1
MDSSA-ELM vs SSA-ELM	1.2065×10^{-17}	1	4.5969×10^{-8}	1	1.7520×10^{-6}	1	4.3516×10^{-14}	1	0.0388	1
MDSSA-ELM vs WOA-ELM	3.8608×10^{-19}	1	3.0582×10^{-10}	1	3.3967×10^{-18}	1	2.5840×10^{-14}	1	0.4968	0
MDSSA-ELM vs GWO-ELM	1.7581×10^{-14}	1	1.4220×10^{-8}	1	6.0901×10^{-13}	1	1.1251×10^{-9}	1	4.2700×10^{-4}	1
MDSSA-ELM vs MFO-ELM	5.8299×10^{-22}	1	5.5939×10^{-10}	1	2.0880×10^{-20}	1	2.0779×10^{-16}	1	1.7000×10^{-5}	1

注: $p < 0.05$,表示差异显著

结束语 为了准确地预测焦炭价格的未来变化趋势,本文提出了基于 MDSSA 优化的 ELM 焦炭价格预测方法,构建了 MDSSA-ELM 预测模型。首先,改进后的 MDSSA 具有更快的收敛速度和更高的精度,可以为 ELM 的优化提供高效的计算工具;其次,运用 MDSSA 和 ELM 构建的 MDSSA-ELM 预测模型减少了焦炭价格未来趋势的预测误差,增强了焦炭未来价格趋势的拟合效果;最后,在实际焦炭价格数据集上的实验结果表明了本文提出的 MDSSA-ELM 预测模型的有效性、稳定性和显著性,为焦炭价格预测提供了新工具。未来的研究可考虑从文本数据挖掘方面入手,从与焦炭价格相关的政策文件和评价等文本数据中提取有意义的特征和有效的策略,以构建深度学习模型,实现焦炭价格的智能预测。

参考文献

- [1] PADILLA W R, GARCÍA J, MOLINA J M. Improving time series forecasting using information fusion in local agricultural markets[J]. Neurocomputing, 2021, 452: 355-373.
- [2] TAI V V, CHENGOC H, LEDAI N, et al. A new strategy for

- short-term stock investment using bayesian approach[J]. Computational Economics, 2021, 59(2): 887-911.
- [3] DHANAPAL R, AJANRAJ A, BALAVINAYAGAPRAGATHI-SH S, et al. Crop price prediction using supervised machine learning algorithms[J]. Journal of Physics: Conference Series, 2021, 1916(1): 012042.
- [4] YANG B Q, ZHANG X L. Forecast of price of rare earths neodymium oxide and dysprosium oxide based on ARIMA time series model[J]. Journal of the Chinese Society of Rare Earths, 2017, 35(5): 680-686.
- [5] DU Y A. Research on the route pricing optimization model of the car-free carrier platform based on the BP neural network algorithm[J]. Complexity, 2021, 2021(4): 8204214.
- [6] E J W, YE J M, HE L L, et al. A denoising carbon price forecasting method based on the integration of kernel independent component analysis and least squares support vector regression [J]. Neurocomputing, 2021, 434: 67-79.
- [7] 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.

- [8] XU H X, MA C L, FENG H. A thrust allocation method based on extreme learning machine[J]. Journal of Huazhong University of Science and Technology(Natural Science Edition), 2021, 49(12): 34-39, 70.
- [9] HUO Y L, LI Y L. A plant leaf classification method based on multi feature fusion and extreme learning machine[J]. Computer Engineering and Science, 2021, 43(3): 486-493.
- [10] WANG H X, CHEN Y Q, SHEN J, et al. Novel semi-supervised extreme learning machine and its application in anti-vibration hammer corrosion detection [J]. Computer Science, 2020, 47(12): 262-266.
- [11] LIU W, YAN S, CHEN T, et al. Feature recognition of irregular pellet images by regularized extreme learning machine in combination with fractal theory[J]. Future Generation Computer Systems, 2022, 127: 92-108.
- [12] LI L L, SUN J, TSENG M L, et al. Extreme learning machine optimized by whale optimization algorithm using insulated gate bipolar transistor module aging degree evaluation [J]. Expert Systems with Applications, 2019, 127: 58-67.
- [13] SUBUDHI U, DASH S. Detection and classification of power quality disturbances using GWO ELM[J]. Journal of Industrial Information Integration, 2021, 22: 100204.
- [14] MUDULI D, DASH R, MAJHI B. Automated breast cancer detection in digital mammograms: A moth flame optimization based ELM approach[J]. Biomedical Signal Processing and Control, 2020, 59: 101912.
- [15] MIRJALILI S, GANDOMI A H, MIRJALILI S Z, et al. Salp Swarm Algorithm: A bio-inspired optimizer for engineering design problems [J]. Advances in Engineering Software, 2017, 114: 163-191.
- [16] LIU J S, YUAN M M, ZUO F. Global search-oriented adaptive leader salp swarm algorithm [J]. Control and Decision, 2021, 36(9): 2152-2160.
- [17] YU J S, WU L. Two types of leaders salp swarm algorithm [J]. Computer Science, 2021, 48(4): 254-260.
- [18] KAMEL S, EBEED M, JURADO F, et al. An improved version of salp swarm algorithm for solving optimal power flow problem [J]. Soft Computing, 2021, 25(5): 4027-4052.
- [19] HEGAZY A E, MAKHLOUF M A, EL-Tawel G S. Feature selection using chaotic salp swarm algorithm for data classification [J]. Arabian Journal for Science and Engineering, 2019, 44(4): 3801-3816.
- [20] BALAKRISHNAN K, DHANALAKSHMI R, KHAIRE U M. Improved salp swarm algorithm based on the levy flight for feature selection [J]. The Journal of Supercomputing, 2021, 77(11): 12399-12419.
- [21] CHAABANE S B, BELAZI A, KHARBECH S, et al. Improved salp swarm optimization algorithm: application in feature weighting for blind modulation identification [J]. Electronics, 2021, 10(16): 2002.
- [22] LI Y C, HAN M X, GUO Q L. Modified whale optimization algorithm based on tent chaotic mapping and its application in structural optimization [J]. KSCE Journal of Civil Engineering, 2020, 24(12): 3703-3713.
- [23] WANG M N, WANG Q P, WANG X F. Improved grey wolf optimization algorithm based on iterative mapping and simplex method [J]. Journal of Computer Applications, 2018, 38(A2): 16-20, 54.
- [24] XIA P F, NI Z W, ZHU X H. Attribute selection method based on fireworks evolution artificial fish swarm algorithm and multi-fractal dimension with its application in air quality prediction [J]. Journal of Systems Science and Mathematical Sciences, 2020, 40(7): 1157-1177.
- [25] PENG P, NI W, ZHU X H, et al. Attribute reduction method based on improved binary glowworm swarm optimization algorithm and neighborhood rough set [J]. Pattern Recognition and Artificial Intelligence, 2020, 33(2): 95-105.
- [26] DONG H B, PANG J W, HAN Q L. Gray extreme learning machine prediction method [J]. Computer Science, 2015, 42(5): 78-81, 105.
- [27] BARATA J C A, HUSSEIN M S. The Moore-Penrose pseudoinverse: A tutorial review of the theory [J]. Brazilian Journal of Physics, 2012, 42(1): 146-165.
- [28] WANG J. Research on the linkage relationship between coal-coke-iron prices [J]. Coal Economic Research, 2008, 2: 13-16.
- [29] LAURITZEN S L. The EM algorithm for graphical association models with missing data [J]. Computational Statistics & Data Analysis, 1995, 19(2): 191-201.
- [30] AZLI H, TITRI S, LARBES C. MPPT-Based improved salp swarm algorithm for improving performance and efficiency of photovoltaic system under partial shading condition [C] // IC-AIRES 2020: Artificial Intelligence and Renewables Towards an Energy Transition. 2020: 478-486.
- [31] MIRJALILI S, LEWIS A. The whale optimization algorithm [J]. Advances in Engineering Software, 2016, 95: 51-67.
- [32] MIRJALILI S, MIRJALILI S M, LEWIS A. Grey wolf optimizer [J]. Advances in Engineering Software, 2014, 69: 46-61.
- [33] SHEHAB M, ABUALIGAH L, AL HAMAD H, et al. Moth-flame optimization algorithm: variants and applications [J]. Neural Computing and Applications, 2020, 32(14): 9859-9884.
- [34] XIA P F, NI Z W, ZHU X H, et al. Selective ensemble approach based on reverse binary glowworm swarm optimization and diversity measure [J]. Journal of Systems Science and Mathematical Sciences, 2021, 41(3): 730-746.



ZHU Xuhui, born in 1991, Ph.D, lecturer, master supervisor, is a member of China Computer Federation. His main research interests include intelligent computing, ensemble learning, deep learning and smart manufacturing.



NI Zhiwei, born in 1963, Ph.D, professor, Ph.D supervisor. His main research interests include artificial intelligence, machine learning and edge computing.