

基于 IFOA-SVR 的断路器销量预测

张凌波[†], 刘 海

(华东理工大学 化工过程先进控制和优化技术教育部重点实验室, 上海 200237)

摘要: 为了提高供应链中销量预测的准确性, 提出一种改进森林优化算法 (Improved forest optimization algorithm, IFOA) 来优化销量预测. 首先, 引入量子系统中的 δ 势阱模型, 使得算法能在充分利用局部最优的同时避免陷入局部最优; 其次, 引入自适应局部播种步长, 从而优化算法的全局和局部寻优速度, 保证算法精度; 然后, 定义森林广域播种中的自适应转移率, 有效地平衡森林个体多样性与算法局部收敛能力之间的矛盾; 接着, 挖掘外部数据作为特征, 通过计算每个特征与销量的相关性及其显著性进行特征选择并对历史销量数据进行基于聚合经验模态分解 (Ensemble empirical mode decomposition, EEMD) 的特征提取; 最后, 将上述特征用于支持向量回归模型的建立, 并使用改进的森林优化算法对模型参数进行优化, 最终得到销量的准确预测.

关键词: 销量预测; 改进的森林优化算法; 特征选择; 特征提取; 支持向量回归; 数据挖掘

中图分类号: TP301

文献标志码: A

IFOA-SVR based sales volume prediction of circuit breaker

ZHANG Ling-bo[†], LIU Hai

(Key Laboratory of Advanced Control and Optimization for Chemical Process of Ministry of Education, East China University of Science and Technology, Shanghai 200237, China)

Abstract: To improve the accuracy of sales prediction in a supply chain, an improved forest optimization algorithm (IFOA) is proposed to optimize the prediction of sales volume. Firstly, the δ potential model in the quantum system is introduced to not only make the best of the local optimum information, but also improve the performance of avoiding being caught in local optimum. Then, the adaptive local seeding step is introduced so that both global search and local search velocities are optimized and at the same time, high solution accuracy is ensured. Adaptive transfer rate in the global seeding stage is defined to effectively balance the diversity of forest individuals against the characteristic of local convergence of the algorithm. Furthermore, correlation and the relevant significance between mined exogenous data and the sales data are calculated to carry out feature selection, and features of sales data are extracted based on ensemble empirical mode decomposition (EEMD). Finally, the mentioned features are used to build an IFOA support vector regression (IFOA-SVR) based predictive model so that the model can predict sales well.

Keywords: sales prediction; IFOA; feature selection; feature extraction; SVR; data mining

0 引 言

对于以制造业为主导的企业, 库存的优化对减小企业资金占用和提高服务效率有着重要意义. 基于销量预测的按订单装配策略是现在广泛采用的一种库存优化策略, 销量预测在其中占有指导性的地位^[1]. 本文旨在通过实现对断路器销量的准确预测来指导后续企业库存优化. 随着社会的发展、宏观经济的不断变动, 企业面临的环境也越发复杂, 导致产品的需求波动性增大, 使得销量预测也变得越来越困难. 由于销量数据具有高维、非线性和非平稳的特点^[2-3], 使用传统的单变量时间序列预测模型 (如: 差分自回归滑动平均 (ARIMA) 模型^[4]、门限自回归

(TAR) 模型^[5]、状态空间模型^[6]等) 已经无法完成高精度预测了.

本文通过挖掘与断路器销量有关的下游产业宏观经济数据^[7] (如房地产行业、电力行业、交通行业等产值和投资月度数据), 分别计算各变量与断路器销量数据的相关系数并进行显著性分析, 最终确定与销量显著相关的变量作为特征. 考虑到原始数据是最能直接反映销量变化的数据, 对原始数据进行基于聚合经验模态分解^[8]的特征提取^[9]后, 得到销量数据在几个不同频段的本征模态函数和一个趋势项, 它们能够分别反映出具有不同周期的经济活动对销量的影响. 最后基于以上特征, 对销量进行建模. 由于月度

收稿日期: 2018-03-22; 修回日期: 2018-09-21.

责任编辑: 董久祥.

[†]通讯作者. E-mail: zlb@ecust.edu.cn.

预测的时间粒度太大,数据量很少,考虑使用支持向量回归^[10]对销量进行建模和预测. SVM作为一种理论完备的统计学习方法,相较于其他机器学习模型结构更简单,特别是对于高维、非线性的小样本数据建模具有精度高的特点,但是要想达到高精度,必须依靠性能良好的优化算法对其参数进行寻优.

在过去的几十年间,人们提出了许多基于群体的随机智能优化算法,如遗传算法^[11]、粒子群算法^[12]、蚁群算法^[13]、差分进化算法^[14]、蜂群算法^[15]等,它们被广泛用于解决各类复杂的优化问题. Ghaemi等^[16]受到森林演化过程中不同环境下树生长状态不同的启发,于2014年提出了森林优化算法^[16]. 森林优化算法具有原理简单、参数少、新颖等优点,但在处理复杂问题时效果欠佳. 目前,学者们对森林优化算法的改进还比较少. Ghaemi等^[17]于2016年将该方法离散化后用于特征选择问题中; Chaghari等^[18]于2016年将森林优化算法与梯度下降法相结合用于模糊聚类问题中. 文献[19]提出了极端贪婪策略、波形步长、最优树优待和新型远处播种4种改进策略来改进森林优化算法,这些算法在一定程度上加快了算法的收敛速度和精度,但是极端贪婪策略会缩小种群规模,波形步长在寻优初期不具备优势,使得全局搜索过慢,最优树优待策略只利用了局部最优信息,会使算法更倾向于陷入局部最优. 本文提出的IFOA在引入势阱模型、自适应局部播种步长和自适应转移率改进算法的同时克服了上述不足.

1 改进的森林优化算法

森林优化算法在解决非线性连续型优化问题时效果较好,但是在处理复杂问题时,仍然具有收敛速度慢、收敛精度低且容易陷入局部最优的缺点,因此存在很大的改进空间. 在局部播种阶段,森林中的每棵0-age树都拥有同等的权利在自身周围进行播种,这样不仅最优树的经验得不到发挥,而且也浪费了大量资源,使算法效率低下. 此外,不论是森林形成初期还是末期,局部播种都是在同一种策略下进行的,这样不利于森林的自我调节. 原算法采用单一转移率引导广域播种,当转移率较小时,对于算法后期森林个体多样性的改善不够明显,当转移率较大时,又不利于算法的局部搜索. 针对FOA算法的这些问题,本文引入3种改进策略.

1.1 改进森林优化算法的 δ 势阱模型

势阱指的是粒子在某力场中运动,势能函数曲线在空间的某一有限范围内势能最小,形如陷阱^[20]. 量子系统中存在的这种势阱被称为 δ 势阱,势阱中的粒子与收敛点 p 之间存在某种吸引力,粒子的位置 x 与

收敛点 p 之间满足如下关系:

$$x = p \pm \frac{L}{2} \ln(1/\mu). \quad (1)$$

其中: $L = \frac{1}{\beta} = \frac{h^2}{m\gamma}$ 为 δ 势阱的步长, h 为普朗克常量, m 为粒子质量; μ 为(0,1)之间的随机数.

假设森林为一个量子系统,最终在某位置 p (收敛点)处生长的树长势最好,森林中每棵树都具有量子行为,收敛点 p 附近存在 δ 势阱,定义 δ 势阱的步长 L 为树 Tree_i 与当前所有树的平均位置 $\overline{\text{Tree}}$ 之间的距离,即 $L = 2\delta(\text{Tree}_i - \overline{\text{Tree}})$,其中 δ 为(0,1)之间的控制参数. 在局部播种之前,对每棵非最优树引入量子行为,即

$$\text{Tree}_i^{\text{new}} = \text{bestTree} + \delta(\text{Tree}_i - \overline{\text{Tree}}) \cdot \ln(1/\mu). \quad (2)$$

其中: bestTree 为最优树, Tree 的age维在量子行为中不改变. 这样,非最优树不仅获得了最优树的生长经验,而且还具有跳出局部最优的一个动量.

1.2 改进森林优化算法的自适应局部播种步长

对于最优解为最小值的最小化问题,随着迭代次数的增加,森林中的最优适应度 bestFitness 应该是逐步减小的. 绝大多数基本的群智能优化算法都会面临难以跳出局部最优的困境,此时的适应度会保持不变或者变化非常缓慢. 对于此,本文提出如下森林提升度的概念:

$$f = \frac{\text{bestFitness}(\text{iter} - 1) - \text{bestFitness}(\text{iter})}{\text{bestFitness}(\text{iter} - 1)}. \quad (3)$$

在最小化问题中,森林提升度定义为前一次最优适应度与当前最优适应度之差与前一次最优适应度的比值, iter 为当前迭代次数, $f \in [0, 1]$. 对于局部播种的步长,采用如下自适应权重调节:

$$w = \begin{cases} \frac{1}{1 + \exp\left(\frac{\text{iter} - 2500}{100}\right)}, & f \geq f_0; \\ 0.5 \times \cos\left(\frac{\text{iter}}{\pi}\right), & f < f_0. \end{cases} \quad (4)$$

其中 f_0 为权重切换阈值,取0.04.

森林形成之初需要大面积扩张,此时森林提升度大,局部播种步长应当尽可能大,权重 w 采用指数形式,其数值接近于1. 森林形成后期,森林提升度较小,此时算法很容易陷入局部最优,采用余弦权重调节步长,有助于跳出局部最优,最终局部播种记为

$$x_{kj} = x_{ij} + w \cdot (-\Delta x + \lambda \cdot 2\Delta x). \quad (5)$$

1.3 改进森林优化算法的自适应转移率

森林演化中的广域播种受启发于远处传播的种子长势更优,这一点可由森林的逃逸假说(Escape hypothesis)以及殖民假说(Colonization hypothesis)解

释^[16]. 在森林发展后期, 森林中树的多样性严重不足, 相反, 聚集度就会很高. 分别定义最优适应度水平 S_{best} 和平均适应度水平 S_{mean} 如下:

$$S_{best}(iter) = \frac{\text{bestFitness}(iter)}{\sum_{i=1}^M \text{fitness}(iter)}, \quad (6)$$

$$S_{mean} = \frac{1}{\text{treeNum}(iter)}. \quad (7)$$

其中: S_{best} 为最优适应度与所有个体适应度之和的比值, 在最小化问题中, 最优适应度为 treeNum 棵树中适应度最小的; S_{mean} 取算术平均. 森林聚集度 S 可以定义为最优适应度水平与平均适应度水平的比值, 即

$$S(iter) = \frac{S_{best}}{S_{mean}}. \quad (8)$$

$S \in [0, 1]$, S 越接近于 1 说明聚集度越高, 个体多样性越小.

广域播种能有效解决森林个体多样性不足、全局寻优能力弱的问题, 按照下式对广域播种转移率进行调节, 可以有效平衡森林个体多样性与算法局部收敛能力之间的矛盾.

$$\text{Transfer Rate} = \begin{cases} 0.10, & S(iter) < S_0; \\ 0.15, & S(iter) \geq S_0. \end{cases} \quad (9)$$

其中: S_0 为聚集度阈值, 当 $S < S_0$ 时, 森林多样性高, 采用较低转移率, 当 $S \geq S_0$ 时, 森林多样性低, 采用较高转移率, 让备选森林中更多的树参与广域播种以提高森林个体多样性.

1.4 改进森林优化算法伪代码

Input: LifeTime, Area Limit, LSC, Δx , GSC, f_0 , S_0

Output: Best fitness

Process:

- 1) Initialize forest with random trees and set their ages 0
- 2) Sort trees by fitness

- 3) While $FES < 10\ 000D$ do
- 4) for $i = 1 : \text{size}(\text{Forest})$
- 5) $\text{Tree}_i^{\text{new}} = \text{bestTree} + \delta(\text{Tree}_i - \overline{\text{Tree}}) \cdot \ln(1/\mu)$
- 6) end for
- 7) $f = 1 - \text{bestFitness}(iter) / \text{bestFitness}(iter - 1)$
- 8) if $f \geq f_0, w = w_0$
- 9) else $w = w_1$
- 10) end if
- 11) if $\text{age} == 0$
- 12) for $j = 1 : \text{LSC}$
- 13) $x_{kj} = x_{ij} + w \cdot (-\Delta x + \lambda \cdot 2\Delta x)$
- 14) $\text{age} = \text{age} + 1$
- 15) end for
- 16) end if
- 17) Remove trees with age greater than LifeTime to Candidate Forest
- 18) Sort trees by fitness and remove trees to Candidate Forest
- 19) $S = S_{best} / S_{mean}$
- 20) if $S < S_0, \text{Transfer Rate} = 0.1$
- 21) else $\text{Transfer Rate} = 0.15$
- 22) end if
- 23) Choose Transfer Rate trees of Candidate Forest
- 24) for $k = 1 : \text{size}(\text{selected trees})$
- 25) Change GSC dimensions of each tree with random value
- 26) end for
- 27) Update the best tree and set its age 0

2 实验及结果分析

为了验证改进 IFOA 的寻优性能, 选取如表 1 所示的 6 个经典连续无约束测试函数进行 30 维和 50 维实验, 并将实验结果与改进的人工蜂群算法 (MABC) 和全局最优人工蜂群算法 (GABC) 相比较^[21].

表 1 无约束测试函数

Function	Expression	C	Range
Sphere	$f_1(x) = \sum_{i=1}^D x_i^2$	US	$[-100, 100]^D$
Exponential	$f_2(x) = \exp\left(0.5 \sum_{i=1}^D x_i\right)$	UN	$[-10, 10]^D$
Quartic	$f_3(x) = \sum_{i=1}^D i x_i^4 + \text{rand}(1)$	MS	$[-1.28, 1.28]^D$
Rosenbrock	$f_4(x) = \sum_{i=1}^{D-1} [100(x_{i+1} - x_i^2) + (x_i - 1)^2]$	MN	$[-10, 10]^D$
Griewank	$f_5(x) = 1/4\ 000 \sum_{i=1}^D x_i^2 - \prod_{i=1}^D \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1$	US	$[-600, 600]^D$
Weierstrass	$f_6(x) = \sum_{i=1}^D \sum_{k=0}^K a^k \cos(2\pi b^k (x_i + 0.5)) - D \sum_{k=0}^K a^k \cos(2\pi b^k 0.5), a = 0.5, b = 3, K = 20$	MS	$[-1, 1]^D$

为了能作出更客观的比较,实验取相同的共性参数,森林规模限制 Area Limit 为 40,最大适应度评价次数选为 5000D(D 为问题维度),运行 30 次. 其余特性参数 LifeTime、 Δx 、LSC、GSC、 f_0 、 S_0 将通过正交实验选出最优参数组合.

2.1 算法参数选择

实验指标选为每个函数测试 30 次、每次最大 30000 次适应度评价下的平均最优适应度. 参数 LifeTime、 Δx 、LSC、GSC、 f_0 、 S_0 根据初步程序运行结果经验各选出两个水平,其中 Δx 的选取取决于搜索空间的大小, L 为搜索空间一维长度. 方差分析中在

95% 的置信区间下,当显著性水平小于 0.05 时,可以认为该参数的改变对于结果的影响是显著的. 通过 SPSS 软件计算,最终确定最优参数组合为: 6、L/40、1、3、0.04、0.90.

2.2 实验结果

对 6 个测试函数分别使用 FOA 和 IFOA 进行寻优,并与两种改进的 ABC 算法进行比较,实验结果如表 2 所示(最优结果加粗显示).

FOA 和 IFOA 对 Quartic 函数 30 维和 50 维的 30 次平均寻优适应度曲线如图 1 所示,其他实验结果图具有类似效果.

表 2 优化结果对比

Function	D	Mean \pm Std.			
		MABC	GABC	FOA	IFOA
F_1	30	2.22e-22 \pm 1.15e-22	7.37e-33 \pm 6.44e-33	2.10e-2 \pm 7.30e-3	0 \pm 0
	50	4.62e-24 \pm 2.59e-24	9.84e-32 \pm 1.03e-31	1.85e-1 \pm 6.19e-2	0 \pm 0
F_2	30	7.23e-66 \pm 2.32e-68	7.18e-66 \pm 1.54e-76	7.17e-66 \pm 2.16e-81	7.17e-66 \pm 2.16e-81
	50	3.48e-104 \pm 3.06e-104	2.67e-109 \pm 2.26e-119	2.67e-109 \pm 9.62e-90	1.32e-109 \pm 4.24e-98
F_3	30	1.23e+2 \pm 2.50	5.35e+2 \pm 1.48e+2	3.14e-2 \pm 7.70e-3	1.80e-3 \pm 1.50e-3
	50	4.00e+2 \pm 5.71	1.50e-1 \pm 2.09e-2	9.58e-2 \pm 2.20e-2	1.70e-3 \pm 3.10e-4
F_4	30	1.45e+5 \pm 4.13e+5	3.05 \pm 8.13	4.44e+1 \pm 3.01e+1	2.37e+1 \pm 8.60e-1
	50	1.34e+5 \pm 6.70e+5	5.03 \pm 1.94	8.23e+1 \pm 3.68e+1	4.60e+1 \pm 9.81e-1
F_5	30	7.16e-7 \pm 1.45e-6	1.78e-17 \pm 8.88e-17	5.58e-2 \pm 3.28e-2	0 \pm 0
	50	1.49e-8 \pm 1.63e-8	0 \pm 0	1.84e-1 \pm 5.41e-2	0 \pm 0
F_6	30	5.79e+2 \pm 6.58e+1	1.37e-31 \pm 4.61e-33	5.20e-1 \pm 2.08e-1	0 \pm 0
	50	1.15e+3 \pm 6.09e+1	1.98e-31 \pm 8.48e-32	1.57 \pm 5.20e-1	0 \pm 0




图 1 测试函数收敛对比

2.3 实验结果分析

1) 由表 2 可知,在 6 个测试函数中,IFOA 算法在 5 个测试函数中的寻优结果都是最好的,且其中 3 个函数都能求得最优解. 在寻优结果不是最好的测试函数中,IFOA 的寻优精度优于其余两个算法. 从寻优结果的标准差来看,IFOA 的算法稳定性在 30、50 维问题中都表现了与精度同样好的效果.

2) 从图 1 可以看出,IFOA 明显表现出比 FOA 更快的收敛速度和更高的寻优精度. 事实上,IFOA 在所有寻优结果为最优的函数上,经历最大 4000 次左右

的适应度评价就可以寻得最优,而 FOA 在大部分问题中都无法寻得最优.

3 基于 IFOA-SVR 的销量预测及结果分析

考虑到销量数据的高度非线性和非平稳性,本文将基于 EEMD 特征提取的单变量时间序列预测方法与基于宏观经济数据的多变量预测方法相结合,对销量进行建模和预测,综合了单变量短期预测优势和多变量长期预测优势^[22].

3.1 外部数据特征选择与销量特征提取

销量数据来源于国内某公司 3 年断路器销量数据. 考虑公司需要以月为周期对物料和生产进行计划,取每月的总销量作为实验数据进行建模和预测. 外部数据主要从断路器下游产业中获取,下游产业主要包括房地产市场、工业领域、电力领域、轨道交通领域等. 通过检验各特征在不同时延下与销量的 Pearson 相关系数,使相关系数绝对值最大的时延即为最佳时延,然后选出与销量具有相关性的特征(认为相关系数绝对值大于 0.3 为具有相关性),则特征选

择可等价于求解下述优化问题:

$$\min_{\tau_i} - \sum_{i=1}^N |\rho_{X f_i}(\tau_i)|. \quad (10)$$

其中: $X(t)$ 为产品销量; $f_i(t)$ 为第 i 个特征; $N = 86$ 为特征个数; τ_i 为 $X(t)$ 相对于 $f_i(t)$ 的时间延迟, 最长延迟取一个季度, τ_i 取 0,1,2,3. 分别确定了每个特征的延迟 τ_i 之后, 选出具有相关性的特征, 对相关性进行显著性分析. 选出 14 组显著相关的外部数据作为特征, 包括房屋施工面积、房地产投资工程款、发电机组总产量等. 由于时间序列具有高维特性, 考虑通过集合经验模态分解^[23]对原始数据进行分解, 将其分解为多个频段的特征, 每个频段可能是由具有不同周期的经济活动共同作用所导致的, 将其作为特征实际上是对销量内在模式的挖掘和利用, 该特征提取工作对提高预测精度有一定帮助.

3.2 支持向量回归

支持向量机 (Support vector machine, SVM) 是一种基于统计机器学习理论的分类器, 其在线性不可分小样本数据中具有比其他分类器更好的分类精度和泛化能力, 而支持向量回归是一种基于 SVM 的用于解决回归问题的模型. 由于本实验数据具有数据量少、非线性强的特点, 选用带径向基核函数的 SVR 对数据进行建模和预测.

自定义目标函数 $\text{obj}(\gamma, C, \varepsilon, \lambda)$, 并构造以下无约束优化问题:

$$\min_{\gamma, C, \varepsilon, \lambda} \text{obj}(\gamma, C, \varepsilon, \lambda) = \min_{\gamma, C, \varepsilon, \lambda} [\lambda \mu_{|\hat{y}|}(\gamma, C, \varepsilon) + (1 - \lambda) \sigma_{|\hat{y}|}(\gamma, C, \varepsilon)]. \quad (11)$$

其中: $|\hat{y}| = |\hat{y}(\gamma, C, \varepsilon, \lambda) - y|$ 为预测值与真实值之间残差的绝对值, $\mu_{|\hat{y}|}$ 和 $\sigma_{|\hat{y}|}$ 分别为残差绝对值的均值和标准差, $\lambda \in (0, 1)$ 为用于调节目标函数中均值和标准差权重的控制参数. 核参数 γ 定义了单个样本对整个超平面的影响, 惩罚系数 C 决定了模型的泛化能力, 容许间隔 ε 同样也会通过影响模型复杂程度影响模型泛化能力, γ 和 C 越大、 ε 越小时, 模型越复杂, 过拟合风险越高^[24], 考虑采用在连续型无约束优化问题中具有优异寻优能力的 IFOA 来优化目标函数(11).

对销量分别建立 ARIMA 模型和 SVR 模型并分别使用传统的 Grid Search、PSO 以及本文中的 FOA 和 IFOA 算法对上述 $\text{obj}(\gamma, C, \varepsilon, \lambda)$ 进行优化, 搜索空间取 $[0.001, 100]^4$ (λ 参数会作归一化处理), 由于数据量较少, 选择前 24 组数据作为训练集, 后 6 组数据作为测试集, 预测结果如图 2 和图 3 所示.

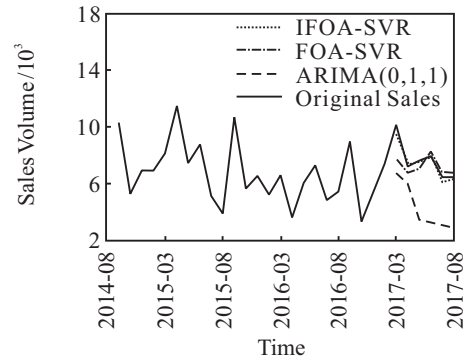


图 2 ARIMA 和 FOA-SVR 模型预测结果

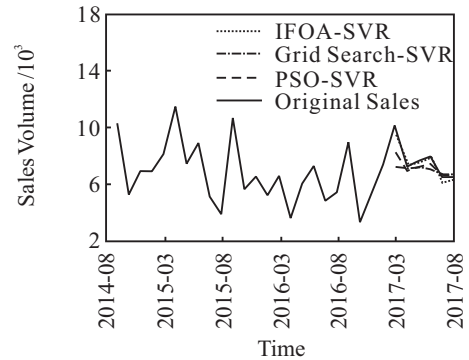


图 3 优化 SVR 模型预测结果

从图 2 中可以看出, 使用 ARIMA 模型的单变量销量预测的结果非常差, 使用 FOA-SVR 的销量预测结果明显优于 ARIMA, 而 IFOA-SVR 更优. 分别选取 RMSE、MAPE、 R^2 对预测结果进行度量: ARIMA 的预测结果为 $\text{RMSE} = 3562.7385$, $\text{MAPE} = 0.4488$, $R^2 = 0.5128$; FOA-SVR 的预测结果为 $\text{RMSE} = 786.0978$, $\text{MAPE} = 0.0839$, $R^2 = 0.4576$; IFOA-SVR 预测结果为 $\text{RMSE} = 313.1365$, $\text{MAPE} = 0.0273$, $R^2 = 0.9660$. ARIMA 模型的预测结果虽然从拟合优度来看优于 FOA-SVR, 但是由于误差指标相差太大, 预测结果更差, IFOA 的预测结果无论从误差还是拟合优度角度都更优. 图 3 比较了 IFOA 与传统优化算法的预测结果, 明显可以看到, IFOA 要优于 PSO 和 Grid Search. 从指标来看, PSO-SVR 的预测结果为 $\text{RMSE} = 836.2661$, $\text{MAPE} = 0.0773$, $R^2 = 0.9541$, 虽然 PSO-SVR 的拟合优度接近于 IFOA-SVR, 但是误差方面相差较大, 预测效果不佳, Grid Search-SVR 预测结果较 PSO-SVR 更差. 从预测数值误差和曲线趋势来看, IFOA-SVR 都要优于其他模型.

4 结论

本文提出的 IFOA 在 6 个测试函数上都表现出了比 FOA 更快的收敛速度和更高的求解精度, 说明在求解大规模复杂连续无约束优化问题上, IFOA 具有较好的性能. 销量预测在使用宏观经济数据和特征

提取数据后相较于单变量时间序列建模和预测精度有很大提升. 从3大指标上来看, IFOA相比于FOA及其他传统优化算法, 对SVR参数寻优效果更好, 模型达到的预测精度更高, 对断路器的库存优化有着较大的指导意义.

改进的优化算法IFOA在多模不可分离测试函数上的寻优表现仍较差, 在接下来的工作中将会更加注重改善算法跳出局部最优的性能. 在销量建模预测阶段, 由于数据量较少, 未能分出验证集数据来增强模型泛化能力, 在获得更多企业数据后会完善这部分工作.

参考文献(References)

- [1] Guo X, Liu C, Xu W, et al. A prediction-based inventory optimization using data mining models[C]. The 7th Int Joint Conf on Computational Sciences and Optimization. Beijing: IEEE Computer Society, 2014: 611-615.
- [2] Ahn H I, Spangler W S. Sales prediction with social media analysis[C]. 2014 Annual SRII Global Conf. San Jose: IEEE, 2014: 213-222.
- [3] Box G E P, Jenkins G M. Time series analysis: Forecasting and control[J]. J of Time, 2010, 31(4): 238-242.
- [4] Widowati, Putro S P, Koshio S, et al. Implementation of ARIMA model to asses seasonal variability macrobenthic assemblages[J]. Aquatic Procedia, 2016, 7: 277-284.
- [5] Narayan P K. The behaviour of US stock prices: Evidence from a threshold autoregressive model[J]. Mathematics & Computers in Simulation, 2006, 71(2): 103-108.
- [6] Snyder R D, Ord J K, Koehler A B, et al. Forecasting compositional time series: A state space approach[J]. Monash Econometrics & Business Statistics Working Papers, 2015, 33(2): 502-512.
- [7] Sagaert Y R, Aghezzaf E H, Kourentzes N, et al. Tactical sales forecasting using a very large set of macroeconomic indicators[J]. European J of Operational Research, 2017, 264(2): 558-569.
- [8] Wu Z H, N Huang E. Ensemble empirical mode decomposition: A noise-assisted data analysis method[J]. Advances in Adaptive Data Analysis, 2009, 1(1): 1-41.
- [9] Yu K, Lin T R, Tan J W. A bearing fault diagnosis technique based on singular values of EEMD spatial condition matrix and Gath-Geva clustering[J]. Applied Acoustics, 2017, 121: 33-45.
- [10] Vapnik V, Cortes C. Support vector networks[J]. Machine Learning, 1995, 20(3): 273-297.
- [11] Koza J R. Genetic programming for economic modeling[C]. Intelligent Systems for Finance and Business. New York: John Wiley & Sons, Inc, 1995: 251-269.
- [12] Kennedy J, Eberhart R. Particle swarm optimization[C]. IEEE Int Conf on Neural Networks. Perth: IEEE, 2002: 1942-1948.
- [13] Chen Z, Zhou S, Luo J. A robust ant colony optimization for continuous functions[J]. Expert Systems with Applications, 2017, 81: 309-320.
- [14] Guo Z, Liu G, Li D, et al. Self-adaptive differential evolution with global neighborhood search[J]. Soft Computing, 2017, 21(13): 3759-3768.
- [15] Karaboga D, Basturk B. A powerful and efficient algorithm for numerical function optimization: Artificial bee colony (ABC) algorithm[J]. J of Global Optimization, 2007, 39(3): 459-471.
- [16] Ghaemi M, Feizi-Derakhshi M R. Forest optimization algorithm[J]. Expert Systems with Applications, 2014, 41(15): 6676-6687.
- [17] Ghaemi M, Feizi-Derakhshi M R. Feature selection using forest optimization algorithm[J]. Pattern Recognition, 2016, 60: 121-129.
- [18] Chaghari A, Feizi-Derakhshi M R, Balafar M A. Fuzzy clustering based on Forest optimization algorithm[J]. J of King Saud University—Computer and Information Sciences, 2016, 30(1): 25-32.
- [19] 聂大千. 森林优化算法的改进及离散化研究[D]. 兰州: 兰州大学信息科学与工程学院, 2016.
(Nie D G. Research on improvements and discretization of forest optimization algorithm[D]. Lanzhou: School of Information Science & Engineering, Lanzhou University, 2016.)
- [20] Da Q. Research on the improvement of quantum potential well-based particle swarm optimization algorithm[J]. Acta Physica Sinica, 2012, 61: 302-379.
- [21] Liang Z, Hu K, Zhu Q, et al. An enhanced artificial bee colony algorithm with adaptive differential operators[J]. Applied Soft Computing, 2017, 58: 480-494.
- [22] Chayama M, Hirata Y. When univariate model-free time series prediction is better than multivariate[J]. Physics Letters A, 2016, 380(31/32): 2359-2365.
- [23] Huang N E, Shen Z, Long S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis[J]. Proceedings Mathematical Physical & Engineering Sciences, 1998, 454(1971): 903-995.
- [24] Duan W Y, Han Y, Huang L M, et al. A hybrid EMD-SVR model for the short-term prediction of significant wave height[J]. Ocean Engineering, 2016, 124: 54-73.

作者简介

张凌波(1974—), 男, 副教授, 博士, 从事工业过程建模、控制与优化、智能优化算法等研究, E-mail: zlb@ecust.edu.cn;

刘海(1994—), 男, 硕士生, 从事机器学习与智能优化的研究, E-mail: 15385927443@163.com.

(责任编辑: 闫妍)