

DOI: 10. 20040/j. cnki. 1000-7709. 2023. 20220741

基于社会学习多目标粒子群优化的中长期负荷组合预测方法

彭海洋^{1,2}, 张英敏¹

(1. 四川大学电气工程学院, 四川 成都 610065; 2. 国网四川省电力公司蓬安县供电分公司, 四川 南充 637800)

摘要: 精准的负荷预测对提高电网规划水平和准确指导投资具有重要意义。针对经验风险最小化的组合预测模型存在过拟合的缺点, 提出了一种基于社会学习多目标粒子群优化算法, 并利用偏最小二乘回归模型、支持向量回归模型、灰色预测 GM(1,1)模型, 引入权重的不确定性函数信息熵来表征期望风险, 综合考虑经验风险和期望风险的组合预测模型。仿真结果表明, 相比于单一预测模型和其他两种组合预测模型, 所提方法具有更高的预测精度, 社会学习多目标粒子群优化算法具有更强的全局搜索能力和优化性能。

关键词: 组合预测; 社会学习多目标粒子群优化; 偏最小二乘回归; 支持向量回归; GM(1,1); 熵

中图分类号: TM721

文献标志码: A

文章编号: 1000-7709(2023)04-0216-05

1 引言

中长期负荷预测是电网规划的基础, 精准的负荷预测对提高电网规划水平、精准布局电力设施具有重要意义。为最大程度地利用各预测模型的信息, 提高负荷预测精度, 张孟明等^[1]通过 BP 神经网络实现非线性组合预测; 周步祥等^[2]通过误差平方和最小建立分数阶灰色 Elman 组合模型, 提升负荷预测准确度; YONGXIU HE 等^[3]以均方误差最小构建组合预测模型, 利用 SA-CSO 算法求解权重, 较其他算法有更高预测精度。但根据误差指标最小确定权重的方法, 仅考虑组合预测的经验风险, 致使模型存在过拟合的缺点。鉴此, 本文综合考虑偏最小二乘回归模型(PLSR 模型)^[4]、支持向量回归模型(SVR 模型)^[5]、灰色预测 GM(1,1)模型以避免各自不足, 提出了一种综合考虑经验风险和期望风险的组合预测模型, 引入权重的不确定性函数信息熵来表征期望风险, 将权重的确定转化为求解关于同时考虑残差平方和最小与最大熵的优化问题, 应用社会学习多目标粒子群优化算法进行求解。并通过实例验证了该组合预测模型的有效性和算法的可行性。

2 PLSR 模型、SVR 模型与 GM(1,1) 模型

2.1 PLSR 模型

偏最小二乘回归模型(PLSR)^[4]结合了主成分分析、典型相关性分析和多元线性回归分析的优势, 能在样本少、自变量间存在严重的多重共线性条件下建模, 其结论更加符合实际。PLSR 建模主要包括数据标准化处理、主成分提取、交叉有效性检验、建立回归方程等步骤。单因变量 PLSR 模型的一般形式为:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_m x_m \quad (1)$$

式中, y 为负荷向量, 样本数为 n ; x_1, x_2, \dots, x_m 为 m 个样本数为 n 的负荷影响因子向量; $\beta_0, \beta_1, \dots, \beta_m$ 为回归系数。

2.2 SVR 模型

支持向量回归(SVR)^[5]在解决小样本、非线性等方面具有独特优势, 其核心思想是将有限样本映射到高维空间, 在高维空间中基于结构风险最小化原则构建的超平面进行线性回归, 从而获得原空间非线性回归的效果。

记 y_1, y_2, \dots, y_n 为 n 个年度最大负荷数据, $x_m = (x_{m1}, x_{m2}, \dots, x_{mm})$ 为 y_i 的 m 个影响因子, 选取 RBF 函数作为 SVR 的核函数, SVR 回归模型为:

$$y_j = f(x_{1j}, x_{2j}, \dots, x_{mj}) = \sum_{i=1}^m w_i \exp(-\varphi x_{ij} - \mathbf{x}^2) + b \quad (2)$$

式中, y_j 为第 j 年度最大负荷实际值; w_i 为权值

收稿日期: 2022-04-13, 修回日期: 2022-06-28

作者简介: 彭海洋(1991-), 男, 硕士研究生、工程师, 研究方向为负荷预测、电网规划, E-mail: 842829790@qq.com

通讯作者: 张英敏(1974-), 女, 博士、教授、硕导, 研究方向为电力系统稳定与控制, E-mail: zhangyingmin@scu.edu.cn

系数; b 为偏置; φ 为核函数系数; \mathbf{x} 为测试数据向量。

对在高维空间建立的优化问题,采用网格搜索法进行参数寻优。对样本数据进行最大-最小归一化处理,缩放到 $[0, 1]$ 标准值再输入模型中,提高运算效率和结果准确性。即:

$$\min L(\mathbf{w}) = \frac{1}{2} \|\boldsymbol{\omega}\|^2 + c \sum_{i=1}^n |y_j - f(x_{1j}, x_{2j}, \dots, x_{mj})|_{\epsilon} \quad (3)$$

式中, $L(\cdot)$ 为优化目标; \mathbf{w} 为权值向量; c 为惩罚系数; ϵ 为不敏感损失参数。

2.3 GM(1,1)模型

灰色模型 GM(1,1) 实质上是将无规律的原始数据进行累加后建立单因素的一阶灰微分方程,由灰微分方程得到时间响应式,再通过累减还原进行预测。设初始最大负荷序列 $\mathbf{Y}^{(0)} = [y^{(0)}(1), y^{(0)}(2), \dots, y^{(0)}(n)]$, 做 n 次一阶累加后生成序列 $\mathbf{Y}^{(1)} = [y^{(1)}(1), y^{(1)}(2), \dots, y^{(1)}(n)]$, 建立灰微分方程,其中 $z^{(1)}(k) = 0.5[y^{(1)}(k) + y^{(1)}(k-1)]$, a 为发展系数, b 为灰色作用量。

$$y^{(0)}(k) + az^{(1)}(k) = b \quad k=2, 3, \dots, n \quad (4)$$

按最小二乘法确定参数 a, b , 则可求出 GM(1,1) 预测模型:

$$\hat{y}^{(0)}(k+1) = (1 - e^a)(y^{(0)}(1) - b/a)e^{-ak} \quad k=1, 2, \dots, n \quad (5)$$

3 中长期负荷组合预测模型建立及求解

3.1 中长期负荷组合预测模型

以最大负荷为例构建组合预测模型,记 $f(t)$ 为第 t 年负荷真实值 ($t=1, 2, \dots, n$), $\hat{f}_k(t)$ 为第 k 个预测模型在第 t 年负荷预测值 ($k=1, 2, \dots, m$), w_k 为第 k 个负荷预测模型权重系数。由 m 个预测模型构建组合预测模型,组合预测模型在第 t 年的残差为 e_t 。计算公式分别为:

$$\hat{f}(t) = \sum_{k=1}^m w_k \hat{f}_k(t) \quad (6)$$

$$e_t = f(t) - \sum_{k=1}^m w_k \hat{f}_k(t)$$

在组合模型中各模型权重的确定常以经验风险最小为原则,采用残差平方和最小求解最佳权重 w_k 。实际上仅考虑经验风险最小,易使组合预测存在过拟合现象,即历史数据拟合准确度高,未来预测结果准确度低,泛化能力差。为了提高

组合预测模型的泛化能力,考虑组合模型中单一预测模型权重的随机性,引入权重的不确定性函数信息熵来表征预测的期望风险。合理的权重应使熵值最大,即期望风险最小。

$$\begin{aligned} \max h &= - \sum_{k=1}^m w_k \ln w_k \Leftrightarrow \min h = \sum_{k=1}^m w_k \ln w_k \\ \text{s. t. } &\sum_{k=1}^m w_k = 1; 0 < w_k \leq 1; k=1, 2, \dots, m \end{aligned} \quad (7)$$

式中, h 为单一模型权重的不确定性,表征预测的期望风险。

同时考虑经验风险最小和期望风险最小的原则,将各模型权重的确定转化为求解关于同时考虑残差平方和最小与最大熵的多目标优化问题,建立组合模型:

$$\begin{cases} \min z = \sum_{t=1}^n (f(t) - \sum_{k=1}^m w_k \hat{f}_k(t))^2 \\ \min h = \sum_{k=1}^m w_k \ln w_k \\ \text{s. t. } \sum_{k=1}^m w_k = 1; 0 < w_k \leq 1; k=1, 2, \dots, m \end{cases} \quad (8)$$

式中, z 为历史数据拟合的残差平方和,表征预测的经验风险。

3.2 SLPSO 算法

在经典的 PSO 算法中,种群中各粒子与全局最优、个体最优粒子信息共享,学习的多样性不足,使算法易陷入局部最优。受人类社会学习机制的启发,提出了一种具有混合策略的社会学习粒子群优化(SLPSO)算法^[6]。首先根据每个粒子的适应度值递增的顺序对种群进行排序,为每个粒子构建一个学习的示例池(图 1)。除具有最佳适应度值的粒子 m 外,其他粒子将通过向具有更好适应度值的那些粒子学习,即模仿学习。




图 1 粒子排序和行为学习

Fig. 1 Particle sorting and behavior learning

在每个维度上,粒子从当前种群的平均行为中学习,即社会学习。SLPSO 更新方程为:

$$\mathbf{X}_i^j(t+1) = \begin{cases} \mathbf{X}_i^j(t) + \Delta \mathbf{X}_i^j(t+1) & p_i \leq P_i^l \\ \mathbf{X}_i^j(t) & \text{其他} \end{cases} \quad (9)$$

$$\Delta \mathbf{X}_i^j(t+1) = \text{rand}_1 \Delta \mathbf{X}_i^j(t) + \text{rand}_2 I_i^j(t) + \text{rand}_3 \epsilon \mathbf{C}_i^j(t) \quad (10)$$

$$\begin{cases} I_i^j(t) = \mathbf{X}_k^j(t) - \mathbf{X}_i^j(t) & i < k \leq m \\ \mathbf{C}_i^j(t) = \overline{\mathbf{X}^j}(t) - \mathbf{X}_i^j(t) \end{cases} \quad (11)$$

$$\overline{\mathbf{X}^j}(t) = \frac{1}{m} \sum_{i=1}^m \mathbf{X}_i^j(t) \quad (12)$$

$$\begin{cases} m = 100 + \lfloor \frac{D}{10} \rfloor \\ P_i^1 = [1 - (i-1)/m]^{\alpha \log \frac{D}{100}} \\ \epsilon = \beta D / 100 \\ i = 1, 2, \dots, m-1 \end{cases} \quad (13)$$

式中, p_i 、 rand_1 、 rand_2 、 rand_3 均为 $[0, 1]$ 上均匀分布的随机数; α 、 β 均为预置参数; m 、 D 分别为种群大小和搜索维度; P_i^1 为粒子 i 学习率; ϵ 为社会因子; I_i 、 C_i 分别为粒子 i 的模仿行为和社会影响行为; $\overline{\mathbf{X}^j}$ 当前种群中所有粒子在第 j 维上的平均行为; \mathbf{X}_k 粒子 k ($i < k \leq m$) 的行为; $\Delta \mathbf{X}_i$ 为行为校正量; $\lfloor \cdot \rfloor$ 、 $\lceil \cdot \rceil$ 表示向下和向上取整。

在 SLPSO 中, 行为校正量 $\Delta \mathbf{X}_i^j$ 由三部分组成。第一部分称为随机惯性分量, 用以提高 PSO 的种群多样性; 第二部分称为模仿部分, 表示粒子可以从它的示例池中不同的粒子中模仿学习, 与经典粒子群算法从 p_{best} 学习不同; 第三部分称为社会学习, 表示粒子从整个群体的集体行为学习, 而不是从 g_{best} 学习。因此, SLPSO 混合学习策略可以增强种群的多样性, 避免陷入局部最优。三个 $[0, 1]$ 上均匀分布的随机数 rand_1 、 rand_2 、 rand_3 替代了经典 PSO 中的三个控制参数 (ω, c_1, c_2), 减轻了参数设置负担。

3.3 基于 SLMOPSO 算法的组合模型权重求解

组合预测模型为一多目标优化问题, 可采用社会学习多目标粒子群优化 (SLMOPSO) 算法求解。

3.3.1 等式约束处理

组合预测模型中权重约束集合包含等式约束, 智能算法对等式约束的处理略显吃力, 因此采用罚函数将权重等式约束转化为目标函数极值问题求解, 最终目标函数为:

$$\begin{cases} \min z = \sum_{t=1}^n (f(t) - \sum_{k=1}^m \omega_k \hat{f}_k(t))^2 + \lambda (\sum_{k=1}^m \omega_k - 1)^2 \\ \min h = \sum_{k=1}^m \omega_k \ln \omega_k \\ 0 < \omega_k \leq 1; k = 1, 2, \dots, m \end{cases} \quad (14)$$

式中, λ 为惩罚因子。

3.3.2 SLMOPSO 算法求解权重流程

SLMOPSO 算法求解组合预测模型权重系数具体步骤如下。

步骤 1 参数设置。基本粒子数 m , 预置参数 α 、 β ; 最大迭代次数 i_{iterMax} , 外部档案规模 N 。

步骤 2 种群初始化, 外部存档初始化。在给定的解空间内初始化种群 $P(0)$ 、外部存档 $R(0)$ 。

步骤 3 筛选初始种群 pareto 解集, 放入存档 $R(0)$ 。根据优化问题公式计算初始种群 $P(0)$ 各粒子适应度值, 然后对 $P(0)$ 进行非支配排序, 挑选 pareto 解集 $P_a(0)$ 并存入 $R(0)$ 。

步骤 4 构建存档集 $R(0)$ 随机网格 G 。

步骤 5 对 $R(0)$ 集合个体进行优劣排序, 根据序列号选择 $R(0)$ 最优个体作为全局最优, 记为 $g_{\text{best}}(0)$ 。

步骤 6 迭代更新 $t \leq i_{\text{iterMax}}$, 即构建种群 $P(t-1)$ 的随机网格 G , 对种群 $P(t-1)$ 个体进行优劣排序, 采用社会学习和行为校正进行种群 $P(t-1)$ 粒子个体位置更新, 记为 $P(t)$, 并进行社会学习和行为校正, 更新 $P(t-1)$ 内个体最优位置 $p_{\text{best}}(t-1)$, 记为 $p_{\text{best}}(t)$ 。对 $P(t)$ 进行非支配排序, 更新存档 $R(t-1)$, 记为 $R(t)$ 。更新 $R(t)$ 随机网格 G 。更新 $R(t)$ 集合个体优劣排序, 记录全局最优 $g_{\text{best}}(t)$ 。根据存档规模 N 限制, 剔除 $R(t)$ 集合内多余粒子个体。检查算法终止条件。若达到最大迭代次数, 则停止迭代; 否则 $t = t + 1$, 转到步骤 6。

步骤 7 输出最优粒子 $g_{\text{best}}(t)$, 即单一预测模型的权重系数。

4 算例分析

4.1 实例验证

为验证所提组合模型预测精度, 选取平均绝对误差 (M_{MAE}) 和平均绝对百分比误差 (M_{MAPE}) 作为预测性能评价指标。

$$M_{\text{MAE}} = \frac{1}{n} \sum_{i=1}^n |f(t) - \hat{f}(t)| \quad (15)$$

$$M_{\text{MAPE}} = \frac{1}{n} \sum_{i=1}^n \left| \frac{f(t) - \hat{f}(t)}{f(t)} \right| \times 100\% \quad (16)$$

式中, n 为样本的个数; $f(t)$ 、 $\hat{f}(t)$ 分别为第 t 年最大负荷的实际值和组合预测值。

以四川某地区 2009~2021 年国民生产总值、人口分布、最高温度、供电量作为最大负荷影响因素, 如表 1 所示。其中国民生产总值、城镇化率、

最高温度等数据来源于当地政府相关部门;最大负荷、供电量数据来源于当地供电公司。选择 2009~2018 年数据为训练样本集,预测该地区 2019~2021 年的最大负荷,分别用 PLSR 模型、SVR 模型和 GM(1,1)模型训练得到的样本值(表 2)。再根据本文组合预测方法,利用单一模型预测得到的样本数据建立组合预测,在 Matlab 中编程,应用 SLMOPSO 求解权重系数。SLMOPSO 参数设置 $m=100, \alpha=0.5, \beta=0.01$;外部档案规模 $N=50; i_{iterMax}=500$ 。求出 PLSR 模型、SVR 模型和 GM(1,1)模型权重系数分别为 0.231、0.447、0.322。

表 1 四川省某地区 2009~2021 年历史数据

Tab. 1 Historical data such as load and power supply in a region of Sichuan Province from 2009 to 2021

年份	最大负荷/MW	供电量/ $10^8 \text{ kW} \cdot \text{h}$	国民生产总值/亿元	城镇化率/%	最高温度/ $^{\circ}\text{C}$
2009	624	29.04	671.72	35.76	39.4
2010	755	37.18	806.43	35.90	39.6
2011	845	44.46	981.48	37.55	39.6
2012	1 049	48.39	1 083.02	39.34	39.7
2013	1 127	52.80	1 283.71	40.89	38.5
2014	1 292	52.79	1 391.70	42.43	39.4
2015	1 542	54.90	1 463.40	43.82	38.5
2016	1 643	60.32	1 592.97	45.07	39.8
2017	1 803	65.70	1 838.25	46.47	40.6
2018	1 900	74.91	2 115.73	48.14	39.7
2019	2 110	78.99	2 322.22	49.72	39.1
2020	2 136	83.20	2 401.08	50.22	38.2
2021	2 447	90.32	2 601.98	51.35	39.6

表 2 多种模型训练得到的样本值

Tab. 2 Sample values obtained from multiple model training

年份	MW			
	真实值	PLSR 预测值	SVR 预测值	GM(1,1)预测值
2009	624	597	642	624
2010	755	730	747	818
2011	845	923	919	915
2012	1 049	1 062	1 067	1 023
2013	1 127	1 225	1 145	1 144
2014	1 292	1 321	1 310	1 279
2015	1 542	1 413	1 348	1 430
2016	1 643	1 562	1 571	1 599
2017	1 803	1 752	1 784	1 788
2018	1 900	1 994	1 919	1 999

经计算,训练过程 PLSR 模型、SVR 模型、GM(1,1)模型和本文组合预测模型平均绝对误差分别为 62.4、45.9、45.9、44.1 MW,平均绝对百分比误差分别为 5.0%、3.65%、3.76%、3.05%。

根据求解出的权重,预测 2019~2021 年的最大负荷,并与仅考虑残差平方和最小的最优组合模型、等权组合模型比较,结果见表 3。经计算 PLSR、SVR、GM(1,1)、最优组合模型、等权组合模型:本文组合模型平均绝对误差分别为 58.3、163.4、278.7、166.8、53.5、27.2 MW,平均绝对百分比误差分别为 2.70%、7.20%、12.38%、7.43%、2.45%、1.27%。

表 3 多种模型预测结果及结果分析

Tab. 3 Prediction results and result analysis of various models

年份	真实值	PLSR 预测值	SVR 预测值	GM(1,1) 预测值	最优组合模型预测值	等权组合模型预测值	本文组合模型预测值
	2019	2 110	2 159	2 007	2 235	2 178	2 134
2020	2 136	2 242	1 986	2 499	2 369	2 242	2 210
2021	2 447	2 428	2 210	2 795	2 646	2 477	2 449

算例结果表明,本文组合预测模型平均绝对误差为 27.2 MW,平均绝对百分比误差为 1.27%,与仅考虑残差平方和最小的最优组合模型、等权组合模型相比,其预测精度最高;在权重不确定的情况下,考虑期望风险的等权组合预测模型性能优于仅考虑残差平方和最小的最优组合模型;单一预测模型中拟合最差的 PLSR 模型表现出较好预测性能;反之,拟合较好的 SVR 模型、GM(1,1)模型预测性能表现不佳,泛化能力低。

4.2 算法性能测试

为验证 SLMOPSO 算法有效性,选择 ZDT 系列^[7]测试函数,采用反世代距离(IGD)作为性能评价指标,计算公式为:

$$I_{IGD}(P, Q) = \sum_{i=1}^{|P|} \frac{d(P_i, Q)}{|P|} \quad (17)$$

式中, I_{IGD} 为反世代距离值; P 为真实的 Pareto 前沿; Q 为待测试算法获取的近似 Pareto 解集; $d(P_i, Q)$ 为 P 中个体 i 到 Q 的最小欧氏距离, $|P|$ 为分布在真实 Pareto 前沿上的解集个数。

选取 CMOPSO 算法^[8]作为对比,算法参数 $w=0.9, c_1=c_2=1.45$ 。在 Windows 11 系统、AMD Ryzen 5 PRO 3500U w/ Radeon Vega Mobile Gfx 2.10 GHz 处理器、Matlab R2016b 中对比试验,两种算法种群数 $m=100$,最大迭代次数 $I_{iterMax}=300$,外部档案规模 $N=100$,独立运行 10 次计算 IGD 值见表 4。IGD 在均值附近两种算法寻优效果对比见图 2。

表 4 两种算法在不同测试函数获得 IGD 值

Tab. 4 Two algorithms to obtain IGD values on different test functions

算法/测试函数	指标	ZDT1	ZDT2	ZDT3	ZDT6
CMOPSO	平均值	8.400×10^{-3}	5.918×10^{-1}	5.262×10^{-2}	9.030×10^{-3}
	标准差	5.621×10^{-4}	1.731×10^{-1}	6.707×10^{-2}	1.394×10^{-3}
SLMOPSO	平均值	9.210×10^{-3}	1.014×10^{-2}	1.215×10^{-2}	8.920×10^{-3}
	标准差	9.181×10^{-4}	1.035×10^{-3}	4.940×10^{-3}	4.750×10^{-4}

由表 4、图 2 可知,CMOPSO 在 ZDT2 测试上无法收敛到真实的 Pareto 前沿,在 ZDT1 上寻优效果较 SLMOPSO 算法更好;SLMOPSO 算法在 ZDT {1, 2, 3, 6} 测试中都能收敛到真实的 Pareto 前沿,并在 ZDT2、ZDT3、ZDT6 较 CMOPSO 算法得到更小的 IGD 值,说明算法求

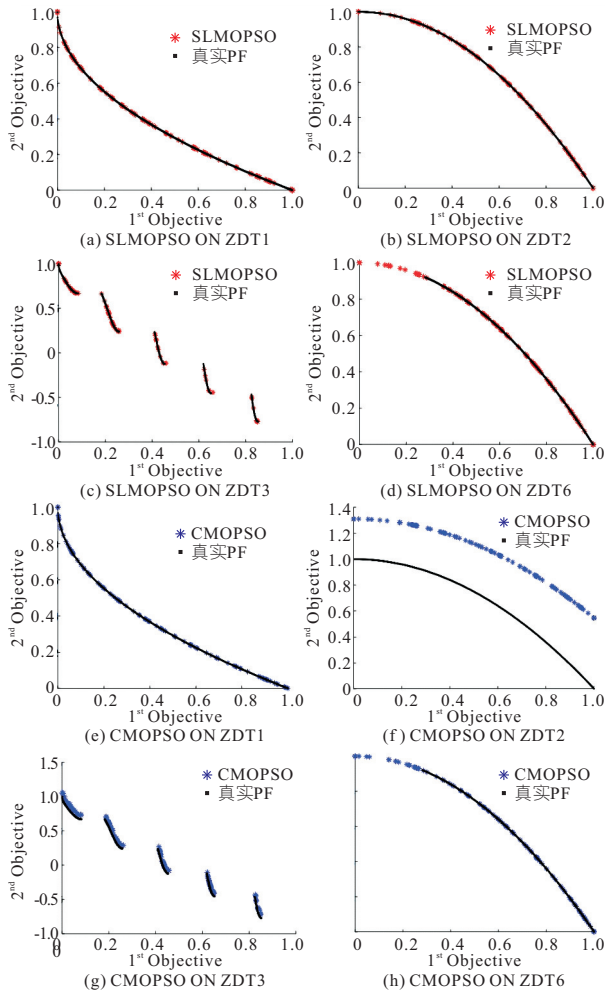


图 2 SLMOPSO 算法、CMOPSO 算法在多个 ZDT 函数上的测试结果

Fig. 2 Test results of SLMOPSO and CMOPSO algorithm on multiple ZDT functions

解的 Pareto 解集收敛性和分布性更好,越接近真实的 Pareto 前沿。

5 结论

a. 引入权重的不确定性函数即信息熵表征预

测期望风险,提出了一种综合考虑经验风险和期望风险的组合预测方法,克服了过拟合的缺点,进一步提高模型的泛化能力,实例验证表明所提方法的预测精度较高。

b. 社会学习多目标粒子群优化算法的混合学习策略,可增强种群多样性,提升寻优能力,经测试该算法求解多目标优化问题是可行的。

参考文献:

- [1] 张孟明,牛东晓,关哲. 中长期电力负荷组合预测[J]. 华北电力技术,2004(6):45-47,50.
- [2] 周步祥,罗燕萍,张百甫,等. 基于分数阶灰色 Elman 组合模型的中长期负荷预测[J]. 水电能源科学,2019,37(2):192-195.
- [3] YONGXIU HE, MEIYAN WANG, FENGTAO GUANG, et al. Research on the method of electricity demand analysis and forecasting: the case of China[J]. Electric power systems research, 2020, 187: 106408.
- [4] 王雁凌,吴梦凯. 经济新常态下基于偏最小二乘回归的中长期负荷预测模型[J]. 电力自动化设备, 2018, 38(3): 133-139.
- [5] 张运厚,李婉莹,董福贵. 基于 DE-GWO-SVR 的中长期电力需求预测[J]. 中国电力, 2021, 54(9): 83-88.
- [6] RAN CHENG, YAO CHUJIN. A social learning particle swarm optimization algorithm for scalable optimization[J]. Information sciences, 2015, 291(6): 43-60.
- [7] ZITZLER E, DEB K, THIELE L. Comparison of multiobjective evolutionary algorithms: empirical results[J]. Evolutionary computation, 2000, 8(2): 173-95.
- [8] CARLOS A. COELLO COELLO, GREGORIO TOSCANO PULIDO, M. SALAZAR LECHUGA. Handling multiple objectives with particle swarm optimization[J]. IEEE trans. evolutionary computation, 2004, 8(3): 256-279.

Medium-and Long-term Load Combination Forecasting Method Based on Social Learning Multi-objective Particle Swarm Optimization

PENG Hai-yang^{1,2}, ZHANG Ying-min¹

(1. School of Electrical Engineering, Sichuan University, Chengdu 610065, China;

2. Peng'an County Power Supply Branch, State Grid Sichuan Electric Power Company, Nanchong 637800, China)

Abstract: Accurate load forecasting is of great significance for improving the level of grid planning and accurately guiding investment. In view of the shortcoming of over-fitting in the combined forecasting model of empirical risk minimization, a combined forecasting model based on social learning multi-objective particle swarm optimization algorithm was proposed in term of partial least squares regression model, support vector regression model and grey prediction GM (1,1) model. The uncertainty function information entropy of weight was introduced to represent the expected risk, and the empirical risk and expected risk were comprehensively considered in the model. The simulation results show that the proposed method has higher prediction accuracy than the single forecasting model and the other two combined forecasting models, and the social learning multi-objective particle swarm optimization algorithm has stronger global search ability and optimization performance.

Key words: combined forecasting; social learning multi-objective particle swarm optimization; partial least squares regression; support vector regression; GM(1,1); entropy