

[文章编号] 1003—4684(2019)04-0030-05

基于 DE-GWO-LSSVM 模型的用电负荷预测

刘雨薇, 刘 辉, 陈馨凝, 李侯君, 邹琪骁

(湖北工业大学电气与电子工程学院, 湖北 武汉 430068)

[摘 要] 为了提高负荷预测的拟合精度,提出一种基于优化灰狼算法的最小二乘支持向量机负荷预测模型,针对标准灰狼算法精度低、收敛速度慢、易陷入局部最优的缺点,采用差分算法优化标准灰狼算法。利用改进的灰狼算法优化最小二乘支持向量机的两个主要参数,建立功率负荷预测研究模型。通过实例分析获得负荷预测结果,利用三种评价指标对比了四种算法模型。实验表明,改进灰狼算法优化最小二乘支持向量机的改进评价指标数值较低,拟合曲线精度更高。

[关键词] 负荷预测; 灰狼优化算法; 最小二乘向量机

[中图分类号] TM715.1

[文献标识码] A

电力系统负荷预测问题是使用已知的历史负荷数据来优化和拟合目标时间段内的预测电力负荷值,该预测负荷数据对指导未来供电需求量,节约电力成本具有重要意义。电力负荷预测的方法主要分为两类:基本预测方法和新兴的人工智能预测方法。传统的基本预测方法包括自回归滑动平均模型、混沌理论预测方法、卡尔曼滤波方法等。这些方法预测及时,但是预测精度相对较低,且不适用于非稳定、非线性的负荷预测。人工智能预测方法在解决非线性时间序列预测方法方面具有更好的效果,包括人工神经网络和支持向量机等。

实验证明,传统的支持向量机(SVM)算法对模型拟合的效果优于其他机器学习算法^[1],因此,被广泛应用于解决线性或非线性系统的分类、拟合回归、模式识别等问题中。基于传统的标准算法,最小二乘支持向量机(LSSVM)改变了原始 SVM 算法中的不等式约束,将原问题转化为求解线性方程的问题,提高了求解的速度^[2]。在非线性的负荷预测领域,LSSVM 也表现出更多的优势^[3]。核宽度参数 σ 和正则化参数 C 的选择决定了 LSSVM 模型的拟合效果,因此所选参数的优化是研究的重点。文献[4]提出了一种利用混合粒子群算法(PSO)优化的混合短期电力负荷预测的优化模型。文献[5]解决了微电网超短期负荷预测中负荷数据的非高斯和高维影

响预测模型精度问题,提出了一种基于局部保持投影的最小二乘支持向量机(LPP-LSSVM)算法。文献[6]通过使用仿生蝙蝠算法(BA)改进了 LSSVM 模型,以提高短期电力负荷预测的准确性。

灰狼优化算法是 Mirjalili 等^[7]提出的一种新兴的智能仿生算法,然而,对于复杂的大样本数据问题,GWO 算法很容易陷入局部最优解,这使得算法后来的收敛速度变慢^[8]。本文利用差分算法优化标准的灰狼算法,同时优化最小二乘支持向量机模型的参数寻优过程,建立了混沌灰狼算法-最小二乘支持向量机的(DEGWO-LSSVM)电力负荷预测模型。将四个不同的模型预测效果进行对比,证明了本算法拟合效果的优越性。

1 基于 LSSVM 模型的预测

支持向量机(Support Vector Machine)是 Vapnik 等人以线性分类器为设计基础,基于结构风险最小化提出的一种得到全局最优化的机器学习模型,被广泛应用于解决线性或非线性系统的分类、拟合回归和高维空间的模式识别等问题中^[9]。

1999 年,Suykens^[10]根据式(1)改变了原 SVM 算法中的不等式约束,提出了最小二乘支持向量机(Least Squares Support Vector Machine,LSSVM)方法,该算法方便了原问题的求解,改进了运行后期

[收稿日期] 2019-04-28

[基金项目] 国家自然科学基金(41601394)

[第一作者] 刘雨薇(1994-),女,湖北武汉人,湖北工业大学硕士研究生,研究方向为电气工程

[通信作者] 刘 辉(1962-)男,湖北武汉人,理学博士,湖北工业大学教授,研究方向为电气工程

速度变慢的缺点,提升了非线性系统数据处理的精度。近年来最小二乘向量机算法在负荷预测领域也得到了广泛的应用,本文采用 DE-GWO 算法优化最小二乘支持向量机的寻优过程。

$$\begin{cases} \min J_1(\boldsymbol{\omega}, e) = \mu E_w + \zeta E_D = \frac{1}{2} \mu \boldsymbol{\omega}^T \boldsymbol{\omega} + \frac{1}{2} \zeta \sum_{i=1}^N e_i^2 \\ \text{s.t. } y_i = \boldsymbol{\omega}^T \varphi(x_i) + b + e_i, i = 1, \dots, N \end{cases}$$

(1)

2 改进灰狼算法

2014 年, Mirjalili 等人依据灰狼群捕食猎物过程中种群内部的等级制度分工,提出了一种元启发式仿生算法——灰狼(Grey Wolf Optimizer, GWO)算法^[7],模拟仿照灰狼群捕食猎物工程中,进行游走、包围、追捕、攻击等狩猎行为来完成目标问题的优化过程。该方法全局寻优能力强,收敛速度快、参数较少,故在人工智能预测领域也得到了良好的寻优效果^[11]。

2.1 标准的灰狼算法

灰狼依靠着狼群内严格的等级制度来完成狩猎捕食过程,以狼群的社会等级建立金字塔模型,从上至下依次分为 α 、 β 、 δ 和 ω 四个等级。围猎由狼 α 占主导地位,灰狼群以猎物为圆心从各个方向实施围捕,在头狼 α 的领导下,由最靠近猎物的 β 、 δ 实施行动,剩余狼群 ω 填补空缺以防止猎物逃脱。狼群反复多次地攻击,逐渐缩小包围圈最终将猎物捕获。因此,对于所有的优化类问题,即是利用 GWO 算法求解猎物最佳坐标的问题。




图 1 灰狼算法原理

狼群对猎物进行围攻过程如下式所示:

$$D = |CX_p(t) - X(t)|$$

$$X(t+1) = X_p(t) - AD$$

$$C = 2r_1$$

$$A = a(2r_2 - 1)$$

(2)

(3)

(4)

式中: C 为摆动因子, A 为收敛因子, $X_p(t)$ 、 $X(t)$ 分别为第 t 次迭代后猎物和灰狼位置, $r_1 = \text{rand}(0, 1)$, $r_2 = \text{rand}(0, 1)$ 。

GWO 算法利用 α 、 β 、 δ 狼群获得潜在猎物位置的最优解,使得其他狼群可以更新自己的猎捕位

置,这种围捕猎物的过程数学公式描述如下。

$$D_\alpha = |C_1 X_\alpha(t) - X(t)|$$

$$D_\beta = |C_2 X_\beta(t) - X(t)|$$

$$D_\delta = |C_3 X_\delta(t) - X(t)|$$

$$X_1 = X_\alpha(t) - A_1 D_\alpha$$

$$X_2 = X_\beta(t) - A_2 D_\beta$$

$$X_3 = X_\delta(t) - A_3 D_\delta$$

根据下式计算迭代后种群内个体的新位置:

$$X(t+1) = \frac{(X_1 + X_2 + X_3)}{3}$$

2.2 改进的灰狼算法

Storn 等^[12]为了更新种群的多样性,提出了一种基于全局优化的方法——差分算法。该方法主要通过种群进行变异、交叉、选择等机制产生新的种群,得到最优解。

在 D 维空间中,用 POP 代表种群,有下列定义:

$$\text{POP} = \{X^1, X^2, \dots, X^k, \dots, X^{\text{psize}}\}$$

$$X^k = (X_1^k, X_2^k, \dots, X_p^k, \dots, X_d^k)$$

k 表示第 k 个个体, $k = 1, 2, \dots, \text{psize}$, psize 表示样本群的规模, $p = 1, 2, \dots, d$ 。

1) 在搜索空间随机生成初始种群

$$X_p^k = X_p^k(\text{low}) + (X_p^k(\text{up}) - X_p^k(\text{low})) \times \text{rand}(0, 1)$$

(5)

$X_p^k(\text{low})$ 代表第 k 个个体的第 p 个分量的下界, $X_p^k(\text{up})$ 代表第 k 个个体的第 p 个分量的上界, $\text{rand}(0, 1)$ 表示 $[0, 1]$ 之间的随机数。

2) 变异操作

变异个体由下式生成:

$$V^i(\tau) = X^{r_1}(\tau) + M \cdot (X^{r_2}(\tau) - X^{r_3}(\tau))$$

(6)

式中, M 为缩放因子, $r_1 \neq r_2 \neq r_3 \neq i$; $\tau = 0, 1, 2, \dots, \tau_{\max}$ 表示迭代次数。

3) 交叉操作

$$U_j^k(\tau) = \begin{cases} V_j^k(\tau), \text{rand}(0, 1) \leq CR \text{ 或 } j = \text{rand}(1, d) \\ X_j^k(\tau), \text{rand}(0, 1) > CR \text{ 或 } j \neq \text{rand}(1, d) \end{cases}$$

(7)

式中: CR 为交叉概率因子, $\text{rand}(1, d)$ 为 $[1, d]$ 之间的随机整数, d 为样本维数。

4) 选择操作

保证子代种群的优越性

$$X^k(\tau+1) = \begin{cases} X^k(\tau), f(U^k(\tau)) > f(X^k(\tau)) \\ U^k(\tau), f(U^k(\tau)) \leq f(X^k(\tau)) \end{cases}$$

尽管 GWO 算法在许多领域都体现出其算法的优越性,但同其他智能算法一样,当训练对象为大数据样本时,易陷入局部最优解、计算速度变慢、精度变低。因此本文利用差分算法更新狼群最优位置,避免 GWO 算法陷入局部最优^[13]。

3 DE-GWO 优化 LSSVM 模型

基于 DE-GWO-LSSVM 模型的用电负荷预测方法,即利用 DE 算法优化标准灰狼算法,采用改进灰狼算法完善 LSSVM 算法的参数寻优过程。模型前期准备步骤如下:

1)样本的划分。将整个样本空间划分为两组数据:训练数据和测试数据,训练样本数据用来帮助模拟建立数学模型,测试样本数据用来对模型预测效果进行检验。

2)核函数的选取。核函数的选取关系到模型性能的优良。针对大数据样本时,处理过程相对不会太复杂的优点,本文核函数选取径向基核函数:

$$K(x, x_i) = \exp[-\frac{\|x - x_i\|^2}{2\sigma^2}]$$

其中: σ 为核宽度参数; $\|x - x_i\|$ 表示 x 距离中心点 x_i 的距离。

3)归一化处理。归一化处理将数据结果落到 $[0,1]$ 之间,使模型的计算速度更加快速,对样本库中初始数据进行归一化处理,其转换函数如下:

$$x_i^* = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \tag{8}$$

其中: x_i 表示样本实际值; x_{\max} 、 x_{\min} 分别表示样本数值中的最大值、最小值。同时预测结果数据还要利用式(8)进行反归一化处理。

基于 DE-GWO-LSSVM 模型的负荷预测研究算法预测步骤如下:

- 步骤 1:设置各项初始参数。
- 步骤 2:根据式(5)初始化种群,其中 X 由最小二乘向量机的核宽度参数 σ 和正则化参数 C 构成。
- 步骤 3:计算个体适应度值,并按从高到低顺序进行排列,以排名前三位的个体位置 X_α 、 X_β 和 X_δ 作为上层狼。
- 步骤 4:利用式(2)更新父代种群个体的位置。
- 步骤 5:根据式(6)、(7)利用差分算法机制进行变异、交叉更新,产生新子代。
- 步骤 6:根据式(8)更新父代种群,再根据式(3)、(4)更新 C 、 A 和 a 。
- 步骤 7:更新父代 P_α 、 P_β 和 P_δ ,再次对灰狼父代群体进行排序。对算法终止条件进行判断,当满足条件,返回父代 P_α 和 $f(P_\alpha)$,输出得到的最优解 C 、 σ 。
- 步骤 8:根据核宽度参数 σ 和正则化参数 C 建立 LSSVM 模型。

4 实验分析

DE-GWO-LSSVM 模型算法流程见图 2。

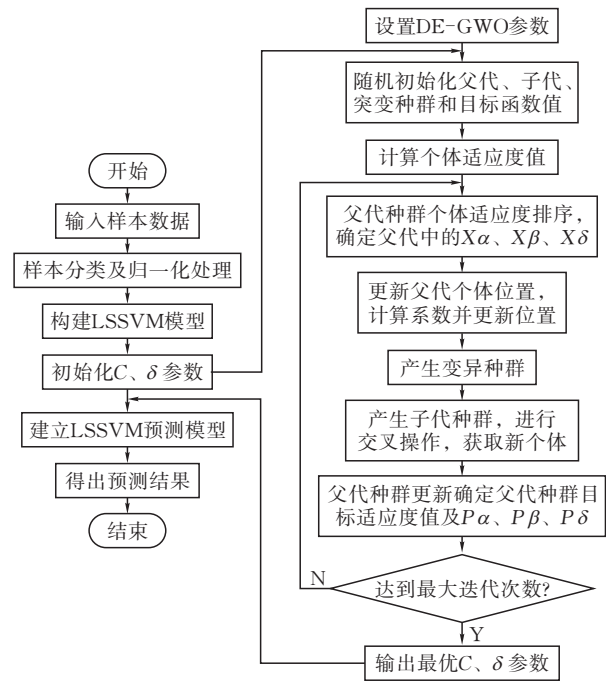


图 2 DE-GWO-LSSVM 回归预测算法流程图

4.1 数据来源

本文数据选用 2001 年欧洲智能技术网络 EUNITE(European Network on Intelligent Technologies)举办的中期电力负荷预测竞赛中提供的历史负荷数据。该历史数据样本包括某地区 1997 年、1998 年中每隔半小时记录的全年电力负荷数值,要求预测 2019 年整个 1 月的日最大电力负荷值。

4.2 实例分析

1)样本数据的选取及分类。选取每年同时期的电力负荷值作为样本数据,模型精确度更高,因此从原始数据中选取合适数据作为样本总体,将其分为两部分:以 1997 年 1 月—1997 年 12 月的日最大电力负荷值为训练样本,以 1998 年 1 月—2 月的日最大电力负荷值为测试样本。

2)预测的方式:本文采用因果预测方法,以第 1、2、3 天的日最大负荷值为输入量,输出第 4 天的日最大负荷值,再以第 2、3、4 天的日最大负荷值为输入量,输出第 5 天的日最大负荷值,以此类推,完成预测目标。

3)评价指标。本文采用 MAE、MSE、MAPE 三个指标来对比评价实验预测结果,公式如下:

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_i - \hat{Y}_i|$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{(Y_i - \hat{Y}_i)}{Y_i} \right|$$

式中： Y_i 为实际值； \hat{Y}_i 为预测值； n 表示样本总数。
MAE、MSE、MAPE 数值越小，则模型的预测拟合程度越好，精度越高。

4)适应度函数的选取。本文以 MSE 作为适应度函数。

5)模型参数设置。本文模型大迭代次数 maxIt 取 200,变量维数取 2,种群数目 nPop 取 50。差分算法中,缩放因子 M_{\max} 、 M_{\min} 分别为 0.8、0.2,交叉概率因子 CR 取 0.2。

6)预测结果。利用 1998 年 12 月的日最大负荷值预测出 1999 年 1 月的日最大负荷值。模型预测结果见图 3。




图 3 模型预测结果

模型在迭代过程中,随着迭代次数的增加,每代的适应度值变化曲线如图 4 所示。可见在迭代次数较少的情况下,DE-GWO-LSSVM 模型可快速收敛到最优解,同时,种群前期在最佳适应度值附近波动,之后波动范围逐渐平缓,种群迭代次数到 120 次之后,种群个体最优适应度值基本稳定,种群的更新基本停止。




图 4 模型迭代曲线

为了验证本文提出的模型算法的优越性,分别建立 LSSVM、PSO-LSSVM、GWO-LSSVM、DE-GWO-LSSVM 四种模型对数据样本进行短期负荷预测模型对比,不同模型下的预测结果见图 5。为使预测的结果更直观,将 2019 年 1 月前 15 天的模型预测值和实际值的数值单独列出(表 1),同时比较不同模型的精确效果,利用均方误差(MSE)作为模型对比的主要参考指标,以平均绝对百分误差(MAPE)、平均绝对误差(MAE)作为模型对比的辅助参考指标进行分析,比较不同模型的评价指标数值(表 2)。




图 5 不同算法下的模型预测结果

表 1 2019 年 1 月 1 日-1 月 15 日日最大电力负荷预测值及误差

日期	实际值	预测值			
		LSSVM	PSO-LSSVM	GWO-LSSVM	HGWO-LSSVM
1 月 1 日	677	717.66	704.07	680.81	677.07
1 月 2 日	718	750.63	739.78	733.28	724.32
1 月 3 日	738	709.26	717.26	724.95	731.96
1 月 4 日	709	726.17	725.34	724.31	719.24
1 月 5 日	745	717.60	722.25	730.67	743.60
1 月 6 日	749	743.86	746.18	747.71	747.72
1 月 7 日	734	742.17	738.10	733.28	733.54
1 月 8 日	679	732.52	723.47	718.13	690.03
1 月 9 日	748	743.82	756.32	750.26	749.28
1 月 10 日	739	743.11	740.39	739.52	739.57
1 月 11 日	756	735.58	748.51	749.17	752.10
1 月 12 日	763	750.24	753.44	757.96	761.83
1 月 13 日	752	752.50	753.28	753.08	752.99
1 月 14 日	738	740.58	736.91	736.49	737.45
1 月 15 日	699	737.80	731.63	726.73	712.65

表 2 各模型预测误差指标

预测模型	MAPE	MSE	MAE
LSSVM	0.0254	0.0577	0.0187
PSO-LSSVM	0.0231	0.0514	0.0173
GWO-LSSVM	0.0227	0.0491	0.0168
HGWO-LSSVM	0.0203	0.0452	0.0152

从图 5 的实验结果可以看出,经过改进灰狼算法优化后的最小二乘向量机的回归拟合效果较好,最基础的最小二乘向量机算法拟合程度较差,组合改进的算法比单一算法的预测精度更强,说明对最小二乘向量机的参数优化是十分有必要的。组合算法 GWO-LSSVM, PSO-LSSVM 预测结果表现出不同程度的提高,前者算法比后者算法的拟合曲线精确,而本文提出的模型,模型的拟合效果最好,特别在突变的极值点和局部最值点时,优化后的灰狼算法模型能更好的预测到数值的变化,预测精度有显著提高。

从表 1 中数据来看,基础的 LSSVM 算法预测效果最差,预测值与真实值之间误差较大,不能起到模拟预测的效果。GWO 算法明显优于 PSO 算法的优化效果,而优化后的灰狼算法与标准灰狼算法的预测数值相差较小,且更为精确。从表 2 中可以看出,在最基础的标准算法下,灰狼算法各项评价指标均低于粒子群算法的优化评价指标,证明了灰狼算法的优越性。在利用差分算法优化灰狼算法的最佳狼群位置,使其避免陷入局部最优解,优化后的 DE-GWO-LSSVM 预测模型的三项指标明显优于其余优化预测模型,验证了本文算法具有较高的稳定性,表现出很高的预测准确度。

5 结束语

LSSVM 算法近年来在电力负荷预测领域得到了广泛的应用。本文利用改进优化的仿生学灰狼算法,对最小二乘支持向量机的参数进行优化。利用差分算法优化标准灰狼算法,更新狼群最优位置,以解决传统的灰狼算法计算运行后期难以跳脱局部最优、训练收敛速度变慢导致模型精度变低的问题,同时结合了 LSSVM 在处理非线性、小样本系统数据时具有更强的学习能力强的优势,建立了 DE-GWO-LSSVM 的混合电力负荷预测模型,提高了模型的拟合精度和收敛速度。本文结合实例分析,对比了不同拟合模型的精度和预测结果,优化后的 DE-GWO-LSSVM 预测模型的三项评价指标明显

优于其余优化预测模型,验证了本文算法具有较高的稳定性,表现出很高的预测准确度。

[参 考 文 献]

[1] Chen B J , Chang M W , Member, et al. Load forecasting using support vector machines; a study on EU-NITE competition 2001 [J]. IEEE Transactions on Power Systems, 2004, 19(4):1821-1830.

[2] abikunda samuel. 基于 LS_SVM 的电力系统短期负荷预测研究[D].北京:华北电力大学,2014.

[3] 代鑫波,崔勇,周德祥,等.基于主成分与粒子群算法的 LS-SVM 短期负荷预测[J].电测与仪表,2012,49(6):5-9.

[4] 马玉鑫.基于 LPP-LSSVM 的微电网超短期负荷预测算法[J].上海电气技术,2019,12(1):42-45,53.

[5] 郝晓弘,刘鹏娟,汪宁渤.混沌优化 PSO-LSSVM 算法的短期负荷预测[J].兰州理工大学学报,2019,45(1):85-90.

[6] 公政,姜文,王来河,等.基于 BA-LSSVM 的短期电力负荷预测研究[J].电子质量,2017(3):1-4,9.

[7] Mirjalili S, Mirjalili S M, Lewis A. Grey wolf optimizer[J]. Advances in Engineering Software, 2014, 69: 46-61.

[8] El-Fergany A A, Hasanien H M. Single and multi-objective optimal power flow using grey wolf optimizer and differential evolution algorithms[J]. Electric Machines & Power Systems, 2015, 43(13):1548-1559.

[9] Cortes C, Vapnik V. Support-vector networks[J]. Machine Learning, 1995, 20(3):273-297.

[10] Suykens J A K, Vandewalle J. Least squares support vector machine classifiers[J]. Neural Processing Letters, 1999, 9(3):293-300.

[11] Das K R, Das D, Das J. Optimal tuning of PID controller using GWO algorithm for speed control in DC motor[C]// International Conference on Soft Computing Techniques & Implementations, 2015.

[12] Storn R, Price K. Differential evolution-a simple and efficient heuristic for global optimization over continuous spaces[J]. Journal of Global Optimization, 1997, 11(4):341-359.

[13] 金星,邵珠超,王盛慧.一种基于差分进化和灰狼算法的混合优化算法[J].科学技术与工程,2017(16):271-274.