灰色变异粒子群算法在电力负荷预测中的应用①

梁宽裕 [1], 梁 利 [2]

[1](甘肃省电力公司检修公司, 兰州 730070)
[2](兰州交通大学 交通信息工程及控制, 兰州 730070)

摘 要: 由于电力负荷量是电力系统发展的基础, 因此提高电力负荷量预测的准确性有利于电力系统的快速发展. 本文利用粒子群算法优化参数的良好性能和灰色预测法适合预测不确定因素影响系统的优势, 提出了灰色变异粒子群组合预测模型来预测电力负荷量, 提高了电力负荷预测的精度, 并通过实例对组合预测模型的预测精度和有效性进行了分析. 结果表明, 此组合预测模型的精度优于单一的灰色预测模型, 且优于其他几种预测算法, 该组合模型能很好地预测电力负荷量, 为电力系统的决策和发展提供了可靠的科学数据.

关键词: 灰色模型; 变异粒子群算法; 电力负荷; 预测

Application of Grey Particle Swarm Algorithm with Mutation in Forecasting of Power Load

LIANG Kuan-Yu[1], LIANG Li[2]

[1](Gansu Electric Power Maintenance Company, Lanzhou 730070, China)
[2](School of Automation & Electrical Engineering, Lanzhou Jiao tong University, Lanzhou 730070, China)

Abstract: Due to the electric power load is the basis of development of electric power system, our work intents to improve predicting accuracy of electric power load is beneficial to the development of electric power system. This paper by using the good performance of particle swarm algorithm to optimize the parameters and the advantage of grey prediction method for forecasting uncertainty factors affecting the system puts forward the grey mutation particle swarm combination forecasting model to predict urban public transit volume, improved the electric power load accuracy. Also through the examples analyzed prediction accuracy and effectiveness of the combination forecast model. The results show that the accuracy of the combination forecast model is better than that a single gray of forecasting model and other prediction algorithms, this model can well predict urban public transit volume which provides a reliable scientific data for the decision and development of electric power system.

Key words: grey model; particle swarm optimization with mutation; electric power load; prediction

电力负荷量是电力系统规划和发展的基础数据, 由于电力负荷量影响因素的随机性、不确定性和复杂性, 因此传统一些的预测方法预测的电力负荷量与实际负荷量之间存在较大的偏差[1-4]. 灰色理论适合于不确定、随机因素影响领域的预测, 并在电力预测领域中得到了广泛的应用[5]. 电力负荷的预测可看作是个灰色系统, 将灰色理论引入到电力负荷预测领域中, 用灰色预测法来预测未来的电力负荷[6-7]. 但传统灰色预测法在求解灰色预测法的参数时采用最小二乘法, 最终建立的模型求得的预测值与实际值拟合度较差, 预测结果误差较大, 预测的精度不高[8]. 针对以上问题, 本文在传统灰色预测法的基础上, 引入变异粒子群算法对灰色预测模型中的参数进行优化, 以提高其预测精度, 能对电力负荷进行准确地预测. 并选取 2005 年 1 月—12 月及 2006 年 1 月—8 月兰州市电力负荷量的实际数据, 对灰色变异粒子群组合预测模型的精度和可行性进行分析, 仿真结果得出该组合预测模型优于传统的 GM(1,1)(单变量一阶灰色预测模

① 收稿时间:2013-09-09;收到修改稿时间:2013-09-27

型)预测模型及其他几种预测算法, 用此组合预测模型来预测电力负荷, 能准确地预测出未来的电力负荷, 为电力系统的规划与建设提供准确的数据, 有利于电力系统的快速发展.

1 传统的灰色GM(1,1)模型

灰色系统采用将原始数据进行直接累加或者移动平均加权累加的方法, 生成具有一定规律的新数列, 且利用特定的曲线逼近其相应曲线, 以逼近的曲线作为模型, 对待预测系统进行预测. 该方法的优点是预测时需要的原始数据较少, 数据分布可以随机, 仅需原始时间数据序列即可[9].

目前, 在灰色系统理论中应用最为普遍的一种预测模型是 GM(1,1), 其不受一般统计模型对原始数据各种要求的约束限制, 且考虑影响因素较少, 具有较强的有效性和实用性. 在建立GM(1,1)模型时, 首先要对原始数据数列进行处理, 构造出规律性较强的新数列, 即对原始数列进行一次累加, 生成新的数列. 其建模过程如下:

原始数据数列 $X^{(0)}$:

$$X^{(0)} = \{X^{(0)}(1), X^{(0)}(2), \cdots, X^{(0)}(n)\} \tag{1}$$

对(1)式进行一次累加生成新数列 $X^{(1)}$:

$$X^{(1)} = \{X^{(1)}(1), X^{(1)}(2), \cdots, X^{(1)}(n)\} \tag{2}$$

其中, $X^{(1)}(k) = \sum_{i=1}^{k} X^{(0)}(i)$ k=1 ,2 , …, n.

由于累加生成的(2)式新数列能将任意非负数列转化为非减的递增数列, 因此使该数列减弱了随机性, 加强了规律性.

对(2)式 $X^{(1)}$建立其白化方程为:

$$dX^{(1)}(t)/dt + aX^{(1)}(t) = u \;(t \geq 3) \tag{3}$$

式(3)是含一个变量的一阶微分方程, 记为GM(1,1).

参数数列 $\hat{a} = (a,u)^{\mathrm{T}}$, 运用最小二乘法求解参数:

$$\hat{a} = \begin{bmatrix} a \\ u \end{bmatrix} = \left(B^T B\right)^{-1} B^{\mathrm{T}} Y_N \tag{4}$$

式(4)中矩阵 B 为:

$$\mathbf{B} = \begin{bmatrix} -\frac{1}{2}\left(X^{(1)}(1) + X^{(1)}(2)\right) & 1 \\ -\frac{1}{2}\left(X^{(1)}(2) + X^{(1)}(3)\right) & 1 \\ \vdots & \\ -\frac{1}{2}\left(X^{(1)}(n-1) + X^{(1)}(n)\right) & 1 \end{bmatrix} \tag{5}$$

$$Y_N = \left[X^{(0)}(2), X^{(0)}(3), \ldots, X^{(0)}(n)\right]^{\mathrm{T}} \tag{6}$$

求得微分方程(3)的响应方程为:

$$\hat{X}^{(1)}(t+1) = (X^{(0)}(1) - \frac{a}{u})e^{-at} + \frac{a}{u} \tag{7}$$

对响应方程 $\hat{X}^{(1)}(t+1)$ 进行还原,求得预测值 $\hat{X}^{(0)}(t+1)$.

$$\hat{X}^{(0)}(t+1) = \hat{X}^{(1)}(t+1) - \hat{X}^{(1)}(t) \tag{8}$$

2 变异粒子群算法

1995 年 Kennedy 和 Eberhart 提出了粒子群算法(Particle Swarm Optimization Algorithm), PSO 算法最初思想源于对鸟群的群体扑食行为的研究. 在群体中, 各个个体通过信息共享和交流搜索出食物所在的位置, 即待优化问题的最优解. 在该算法中, 每个个体就是待优化问题的一个随机解, 即被称之为"粒子". 每个粒子具有各自一个适应值, 该适应值由待优化问题的目标函数决定, 每个粒子还具有各自的飞行速度和方向. PSO 算法开始先随机初始化一群粒子(随机解)及其速度, 然后每个粒子根据一定的公式更新自己的位置和速度, 迭代直到满足终止条件为止. 每一次迭代过程中, 每个粒子依据个体极值 P_i 和全局极值 P_g 来更新自身的飞行方向(位置)和速度, 最终找到全局位置最优的那个粒子(最优解), 即优化问题的最优解. 每个粒子更新自己的速度和位置的公式如下:

$$V_i(t+1) = wV_i(t) + c_1 rand()\left(P_i - X_i(t)\right) + c_2 rand()\left(P_g - X_i(t)\right)$$
$$X_i(t+1) = X_i(t) + V_i(t+1) \tag{9}$$

其中, $V_i(t)$是粒子 i 在第 t 次迭代的速度; $X_i(t)$是粒子 i 第 t 次迭代的位置; rand()是随机数, 取值为(0,1)之间数; c_1、c_2 是学习因子, 一般在(0,2)间取值; w 是惯性因子. 粒子群算法虽然有很好的鲁棒性, 但容易陷入局部最优. 为克服该算法的缺点, 文献[9]提出对该算法进行改进, 避免该算法陷入局部最优, 使得在优化中达到全局最优. 本文基于此文献改进 PSO 算法加入变异算子的思想,在粒子群算法中加入变异因子, 即在粒子陷入局部最优时, 按照一定的方式对部分最优解加入变异算子, 避免了陷入局部最优, 在全局中搜索出最优解. 首先判断粒子的群体适应度方差 σ_2, 当 σ_2 等于或低于设定阈值时, 粒子群陷入了局部最优, 粒子找到的解是局部最优[8], 这时每个粒子按照(10)式判定是否初始化, 即对部分粒子初始化, 扰动公式如下:

$$p = |g_{best}/g_i| \begin{cases} g_{\min} \leq p \leq g_{\max} & \text{不初始化} \\ \text{其他} & \text{初始化} \end{cases} \tag{10}$$

其中, g_{best} 为当前粒子群群体最优解; g_i 为个体粒子 i 最优解; g_{min} 为非扰动下限值; g_{max} 为非扰动上限值. 为了表述本文加入变异算子的性能优于文献[9], 以一简单的函数为测试对象, 给出了本文加入变异因子使粒子群算法跳出局部最优的变异算法与带变异算子的自适应粒子群优化算法(PSO with Hybrid Mutation Operator)的收敛性能比较.

测试函数为:

$$f(x) = x^2 + 2 \tag{11}$$

求解 $f(x)$的最小值, 在测试中学习因子采用非对称形式(提高收敛速度), c_1 =0.4, c_2 =0.9; 惯性权重为 ω_{min}=0.2, ω_{max}=0.8; 种群数 n=50; 最大迭代次数 n_{max}=30. 两种算法的性能比较仿真结果如图 1 所示.

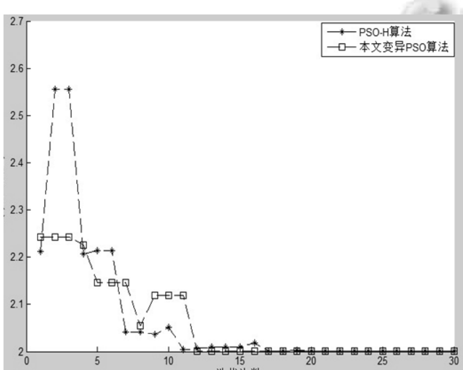

图 1　函数 $f(x)$寻优进化曲线图

测试结果表明, PSO-H 算法在第 17 次达到最优值零, 而本文加入变异因子后, 在第 12 次达到最优解, 该算法的性能明显优于 PSO-H 算法, 避免了 PSO 陷入局部收敛, 具有良好的性能, 同时也说明了加入变异算子改进粒子群算法的可行性和优越性.

3　灰色变异粒子群组合预测模型的建立

3.1 灰色 GM(1,1)模型局限性分析

文献[8]研究表明, GM(1,1)模型运用最小二乘法求解参数时, 由于(3)式将 $\hat{X}^{(1)}(1) = X^{(1)}(1) = X^{(0)}(1)$ 作为已知条件, 因此, 所求解的参数存在较大的系统误差, 无法满足拟合条件 $\sum_{t=1}^{n}(\hat{X}^{(1)}(t) - X^{(1)}(t)) = 0$, 求得的预测方程不一定是最优的预测方程, 结果会影响预测的精度, 所建立的预测模型的精度方差比 C 及小误差概率 P 较差, 精度评价表如表 1 所示[10]. 由于粒子群算法可以用于参数优化研究中[11], 因此, 本文运用变异粒子群算法优化此模型的参数 a、u, 在可行解范围内寻求最优参数解, 以最优参数来建立预测模型, 提高灰色 GM(1,1)的预测精度, 能准确地预测未来的电力负荷量.

表 1　模型精度表

精度等级	P-精度	C-精度
优	0.95≤P	C≤0.35
良	0.80≤P<0.95	0.35<C≤0.50
中	0.70≤P<0.80	0.50<C≤0.65
差	P<0.70	0.65<C

3.2 灰色变异粒子群组合模型建立过程

由表 1 可知, 方差比 C 越小, 预测的精度越高, 本文以方差比为目标函数, 在 a、u 的可行解范围内寻求满足目标函数最小的最优参数 a、u 的值, 建立精度较高的预测模型.

方差比: $$\mathrm{C} = S_2 / S_1 \tag{12}$$

其中, S_1 为原始数据的均方差, S_2 残差的均方差.

建立组合预测模型的步骤如下:

(1) 读取原始数据序列.

(2) t=1 时, 初始化粒子群. 随机初始化粒子的位置 x 和速度 v; 设定粒子的数目 n; 设定其他参数值. 每个粒子都是二维向量, 分别代表参数 a 和 u.

(3) 设定非扰动下限值 g_{min} 及非扰动上限值 g_{max}; 设定适应度方差阈值.

(4) 随机初始化全局最优解 g_{best} 及其局部最优 g_i.

(5) 根据(9)式每个粒子更新自己的速度和位置, 并不断更新全局最优粒子.

(6) 求解适应度函数值. 每个粒子依据(12)式计算自身的适应值. 适应值是评价粒子位置优劣的依据.

(7) 每个粒子更新自己的搜索的最优值和群体最优值.

(8) 计算适应度方差值 σ_2. 如果 σ_2 等于零或者低于阈值, 则陷入局部最优, 转至步骤(10), 否则转至步骤(9).

(9) 判断是不是达到最大迭代次数, 若是, 则输出最优参数 a、u, 否则跳至步骤(5).

(10) 根据(10)式, 对部分粒子进行扰动变异, 转至步骤(6).

(11) 根据步骤(10)求解的最优参数 a 和 u, 建立预测模型, 计算出预测数据.

4　实例分析

原始数据数列的选取为 2005 年 1 月－12 月电力

负荷量的历史数据. 在 MATLABR2007b 环境下实现了传统单一 GM(1,1)灰色预测模型和灰色变异粒子群组合预测模型预测电力负荷的仿真. 在实验中学习因子 c_1 =0.4, c_2 =0.9; 惯性权重为 ω_{min}=0.2, ω_{max}=1.2; 种群数 n=30; 最大迭代次数 n_{max}=200. 两种算法的性能比较仿真结果结果如表 2 所示.

表 2　仿真结果表

月份	原始值/亿千瓦时	GM (1, 1)预测值/亿千瓦时	相对误差/%	组合预测值万/亿千瓦时	相对误差/%
1	36.02	34.32	4.72	35.42	1.67
2	30.99	32.91	6.20	30.55	1.42
3	34.85	33.37	4.25	34.50	1.0
4	33.45	33.85	1.18	33.43	0.06
5	36.53	34.33	3.28	36.10	1.18
6	37.1	34.81	6.17	36.09	2.72
7	35.26	35.30	0.11	35.25	0.03
8	34.12	35.80	4.92	33.71	1.20
9	31.85	36.31	14.00	31.00	2.67
10	36.03	36.83	2.22	36.20	0.56
11	39.50	37.35	5.44	38.47	2.61
12	39.06	37.88	3.02	38.60	1.18

仿真结果可以看出, 组合模型的预测相对误差低于 GM(1,1)预测数据的预测相对误差, 该组合模型预测出的电力负荷量更接近实际电力负荷量的值, 误差相对较小, . 因此表 2 表明, 将灰色预测与变异粒子群算法结合, 建立的组合预测模型能很好的预测电力负荷量, 预测误差明显低于单一 GM(1,1)预测模型的预测误差. 两种预测模型的 C,P 精度比较及平均误差如表 3 所示.

表 3　精度比较表

	GM (1, 1)预测精度	组合预测精度
C 精度	47.216%	25.03%
P 精度	96%	90%
平均误差	1.723%	0.592%

由该表可知, 以方差比为目标函数, 运用变异粒子群算法搜索最优的参数 a、u, 建立的预测模型平均误差小于单一传统的 GM(1,1)预测模型的平均误差. 两种模型求解预测值与实际值的拟合趋势如图 2 所示.

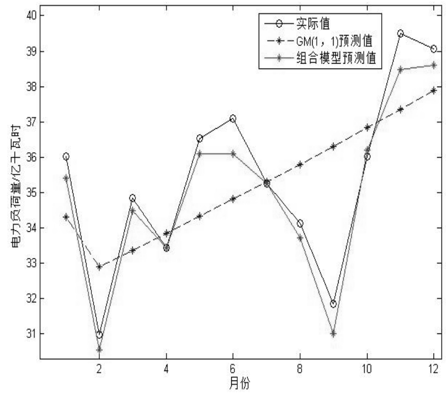

图 2　拟合曲线图

图 2 可知, 组合预测模型预测的电力负荷量与实际的电力负荷量拟合较好, 更接近实际数据. 而单一 GM(1,1)预测模型所预测的电力负荷量与实际电力负荷量拟合较差, 偏差较大. 相比灰色变异粒子群组合模型预测精度较高, 更具有实用性.

为了进一步说明组合预测模型的优越性,选取 2006 年 1 月-8 月兰州市电力负荷量为原始数据进行与 PSR-SVM(融合相空间重构理论与支持向量机组合模型)、SA-MPS-SVM(融合算法和支持向量机组合预测模型)对比, 验证此组合预测模型预测的优越性. 支持向量回归参数为 C=72.4, R_2=5.5, E=0.062 ;最大代数为 10000.

预测值如表 4 所示, 对比仿真图如图 3 所示.

表 4　预测值表(亿千瓦时)

月份	实际值	GM(1,1)预测	PSR-SVM 预测	SA-MPS-SVM 预测	灰色变异粒子群预测
1	37.28	35.12	35.43	36.01	37.00
2	32.00	35.09	34.02	30.50	31.28
3	37.29	36.16	38.12	38.10	37.60
4	37.62	37.26	37.34	37.36	37.50
5	40.87	38.40	38.02	38.26	39.80
6	41.25	39.57	42.10	42.02	40.90
7	40.18	40.78	40.68	40.76	39.88
8	40.07	42.03	42.33	41.54	39.88

几种模型的相对平均误差对比如表 6 所示.

几种模型的相对误差比较如图 4 所示.

由表 5、6 可知, 组合预测模型的相对误差小于单一GM(1,1)预测模型的相对误差, 从图4可看出组合预测模型的相对误差曲线明显低于单一 GM(1,1)预测模

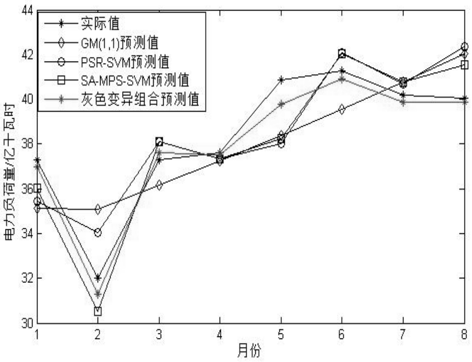

图 3 预测值对比仿真图

表 5 相对误差对比表(%)

月份	GM(1,1)预测	PSR-SVM预测	SA-MPS-SVM 预测	灰色变异粒子群预测
1	5.80	4.96	3.41	0.75
2	9.66	6.31	4.69	2.25
3	3.03	2.22	2.17	0.83
4	0.96	0.74	0.69	0.32
5	6.04	6.97	6.39	2.62
6	4.07	2.06	1.87	0.85
7	1.49	1.24	1.44	0.75
8	4.89	5.64	3.67	0.47

表 6 平均误差对比表

	GM(1,1)预测	PSR-SVM预测	SA-MPS-SVM预测	灰色变异粒子群预测
平均误差	4.49%	3.77%	3.04%	1.11%

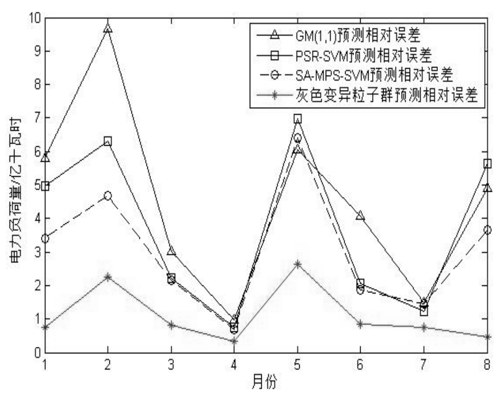

图 4 相对误差图

型的相对误差曲线. 实例表明, 变异粒子群组合预测模型的预测精度明显高于单一 GM(1,1)预测模型及其其他几种预测算法的预测精度, 预测值更接近实际值, 运用此组合预测模型更能准确地预测未来月份的电力负荷的大小.

5 结语

本文结合灰色理论与变异粒子群算法建立了一种灰色变异粒子群组合预测模型, 通过具体的函数验证了算法的优越性, 并通过实例验证分析表明, 组合预测模型的预测精度明显高于单一 GM(1,1)预测模型及其其他几种算法. 因此, 运用变异粒子群算法优化传统灰色预测模型的参数, 明显提高了预测精度, 将此组合模型运用到电力负荷预测中, 预测数据与实际数据拟合较好, 能准确地预测出电力负荷量, 为电力系统的发展与规划提供科学的基础依据, 促进电力系统的快速发展.

参考文献

1 陆宁,刘颖.基于算法融合的自适应短期负荷组合预测模型研究.电力系统保护与控制,2012,40(21):109–113.

2 蓝玉龙,覃珍琴.基于相空间重构理论的电力负荷预测.计算机仿真,2012,29(4):341–344.

3 牛勇,王震宇,王红军.改进灰色模型在中长期电力负荷预测中的应用.上海电力学院学报,2009,29(2):64–69.

4 郑文琛,吉培荣,罗贤举.改进无偏 GM(1,1)模型及其在电力负荷预测中的应用.电力保护与控制,2008,36(5):36–41.

5 朱常青,王秀和,张鑫等.基于灰关联加权组合模型的电力负荷预测研究.电力系统及其自动化学报,2006,18(2) 79–81.

6 阮萍,雷镇,王华.基于灰色系统和人工神经网络的中长期电力负荷预测.计算机应用,2004,24(S1):285–286.

7 程松林,任利伟.基于灰色和神经网络的最优组合预测分析.上海电机学院学报,2009,12(2):157–160.

8 张大海,汪世芳.灰色预测公式的理论缺陷及改进.系统工程理论与实践,2002,22(8):1–3.

9 赵志刚,常成.带变异算子的自适应粒子群优化算法.计算机工程与应用,2011,47(17):42–44.

10 邓聚龙.灰理论基础.武汉:华中科技大学出版,2002.

11 李松,刘力军,刘颖鹏.改进 PSO 优化 BP 神经网络的混沌时间序列预测.计算机工程与应用,2011(9).