

DOI: 10.19783/j.cnki.pspc.190644

基于改进遗传算法的电网投资组合预测方法

刘巍¹, 李猛², 李秋燕², 王利利², 胡钊³, 凌汝晨⁴, 高玉芹³, 李智³

(1. 国网河南省电力公司, 河南 郑州 450000; 2. 国网河南省电力公司经济技术研究院, 河南 郑州 450052;
3. 武汉大学电气工程学院, 湖北 武汉 430072; 4. 国网浙江省电力公司嘉兴供电公司, 浙江 嘉兴 314000)

摘要: 提出了一种通过改进遗传算法并综合利用灰色预测 GM(1, N)模型、BP 神经网络模型、多元回归模型建立的电网投资组合预测模型。基于传统遗传算法对组合预测约束条件进行了优化并改进了遗传算法中交叉算子和变异算子, 从而使算法具有更强的全局搜索能力和收敛能力。利用所提出的组合预测模型对某地区电网投资进行预测的结果表明, 相比于单一预测模型和其他两种组合预测模型, 所提组合预测模型能充分利用原始数据的信息, 具有更高的预测精度。

关键词: 灰色预测; BP 神经网络; 多元回归; 遗传算法; 组合预测

Power grid portfolio forecasting method based on an improved genetic algorithm

LIU Wei¹, LI Meng², LI Qiuyan², WANG Lili², HU Po³, LING Ruchen⁴, GAO Yuqin³, LI Zhi³

(1. State Grid Henan Electric Power Company, Zhengzhou 450000, China; 2. State Grid Henan Economic Research Institute, Zhengzhou 450052, China; 3. School of Electrical Engineering, Wuhan University, Wuhan 430072, China;
4. Jiaying Power Supply Company, State Grid Zhejiang Electric Power Company, Jiaying 314000, China)

Abstract: This paper proposes a grid portfolio forecasting model established by an improved genetic algorithm and comprehensively using the grey prediction GM(1, N), BP neural network and multiple regression models. The traditional genetic algorithm is used to optimize the combined prediction constraints and improve the crossover operator and mutation operator in the genetic algorithm, so that the algorithm has stronger global search and convergence ability. The prediction results of a regional grid investment using the combined forecasting model proposed in this paper show that compared with the single forecasting model and the other two combined forecasting models, the proposed model can make full use of the original data and has higher prediction accuracy.

This work is supported by National High-tech R & D Program of China (863 Program) (No. 2015AA050101).

Key words: grey prediction; BP neural network; multiple regression; genetic algorithm; combined forecast

0 引言

随着我国经济的快速发展, 全社会用电量不断提升, 电网投资规模越来越大。因此, 电网企业应当在筹措资金的同时, 对电网投资需求进行有效预测^[1], 优化投资模式, 科学合理安排电力建设项目。

目前, 针对电网投资预测的研究较少。文献[1]基于协整理论研究最大负荷与电网投资之间的长期均衡关系, 提出误差修正模型对电网投资进行预测; 文献[2]基于灰色理论提出一种电网投资预测方法, 然而单一使用灰色预测模型对电网投资进行预测

时, 预测精度不高。文献[3]论证了社会用电量、电力负荷与省级基建总投资的关系, 并采用组合预测模型对省级基建总投资进行了预测; 文献[4]采用标准差法进行权重分配并建立组合预测模型, 结果表明, 该模型可以作为我国未来能源消费量预测的有效工具。文献[5]分析比较了几种灰色预测模型对电力消费预测结果的不同, 采用变权组合方法, 将不同灰色预测模型组合起来进行负荷预测, 但其取权重的方法并不能保证所得到的组合预测模型的最优性。文献[6]对电网公司保底服务实施后的增量配电网投资策略给出了投资建议。文献[7]基于遗传算法对电力系统短期负荷进行预测, 证明了综合利用变差分析模型和年度分解模型的组合预测模型比单一预测模型具有更高的预测精度。文献[8]建立多指标

基金项目: 国家高技术研究发展计划(863计划)(2015AA050101); 国网河南省电力公司科技项目(5217L017000X)

体系对 10 kV 配电网投资分配进行了评价, 用以引导电网投资方向。文献[9]提出一种考虑影响因素协调关系及滞后效应的新型中长期负荷预测方法, 消除了数据噪声的影响, 提高了预测精度。文献[10]提出了一种基于奇异谱分析的短期电价预测模型, 并以澳大利亚某电力市场电价数据进行了分析, 证明了模型的有效性。文献[11]结合粗糙集理论、混沌理论与 Elman 神经网络, 提出一种短期用电量预测模型, 该模型比单一 Elman 神经网络具有更高的预测精度。文献[12]分析讨论了日最大电力负荷的变化特征以及与气象因子之间的相关关系, 并通过多元回归建立日最大电力负荷预测模型。

本文综合利用 GM(1, N)模型、BP 神经网络模型、多元回归模型以弥补各自的不足, 并通过改进遗传算法建立了电网投资组合预测模型。实际预测表明, 组合预测模型的预测效果好, 与单一使用三种预测方法相比, 组合预测模型的预测精度最高。

1 灰色预测 GM(1, N)模型、BP 神经网络模型与多元回归模型

1.1 灰色预测 GM(1, N)模型

灰色预测 GM(1, N)模型具有所需建模信息少、预算方便、预测精度高等特点^[13-14]。预测原理是对某一数据序列通过累加生成一组趋势明显的新数据序列, 再按该序列的增长趋势建立模型进行预测, 然后通过累减进行逆向计算, 恢复原始数据序列, 进而得到预测结果, 在本文中 GM(1, N)是由 $N-1$ 个投资额影响因素和电网投资额本身所构成的系统状态模型, 从而将相互关联的影响因素作为一个整体来进行研究。其建模流程为

1) 形成累加序列 $y^{(1)}(k)$ 和 $x_j^{(1)}(k)$

设数据序列为 $y^{(0)} = (y^{(0)}(1), y^{(0)}(2), \dots, y^{(0)}(n))$, $y^{(0)}$ 代表每年的投资额, n 为数据个数。与该序列相关的 $N-1$ 个因素序列, 即投资额的影响因素为

$$\begin{cases} x_1^{(0)} = (x_1^{(0)}(1), x_1^{(0)}(2), \dots, x_1^{(0)}(n)) \\ \vdots \\ x_{N-1}^{(0)} = (x_{N-1}^{(0)}(1), x_{N-1}^{(0)}(2), \dots, x_{N-1}^{(0)}(n)) \end{cases} \quad (1)$$

对各序列进行累加以便弱化其波动性和随机性, 得到累加序列, 即

$$y^{(1)}(k) = \sum_{i=1}^k y^{(0)}(i), k=1, 2, \dots, n \quad (2)$$

$$x_j^{(1)}(k) = \sum_{i=1}^k x_j^{(0)}(i), j=1, 2, \dots, N-1 \quad (3)$$

2) 生成 $y^{(1)}(k)$ 的邻均值等权序列 $z^{(1)}(k)$

$y^{(1)}(k)$ 的邻均值等权序列 $z^{(1)}(k)$ 为

$$z^{(1)}(k) = 0.5y^{(1)}(k-1) + 0.5y^{(1)}(k), k=2, 3, \dots, n \quad (4)$$

通过上述序列构成的 GM(1, N)模型为

$$y^{(0)}(k) + az^{(1)}(k) = \sum_{i=1}^{N-1} b_i y^{(1)}(k) \quad (5)$$

式中: a 为发展系数; b_i 为驱动系数。

3) 构造矩阵 B 与常数项向量 Y_n

对所形成的累加生成数据进行均值处理构造矩阵 B 与常数项向量 Y_n 分别为

$$B = \begin{bmatrix} -z^{(1)}(2) & x_1^{(1)}(2) & \cdots & x_{N-1}^{(1)}(2) \\ -z^{(1)}(3) & x_1^{(1)}(3) & \cdots & x_{N-1}^{(1)}(3) \\ \vdots & \vdots & \ddots & \vdots \\ -z^{(1)}(n) & x_1^{(1)}(n) & \cdots & x_{N-1}^{(1)}(n) \end{bmatrix}, Y_n = \begin{bmatrix} y^{(0)}(2) \\ y^{(0)}(3) \\ \vdots \\ y^{(0)}(n) \end{bmatrix} \quad (6)$$

4) 求解发展系数 a 和驱动系数 b_i

令 $\beta = (a, b_1, b_2, \dots, b_{N-1})$, 由最小二乘参数估计可得

$$\beta = (B^T B)^{-1} B^T Y_n \quad (7)$$

5) 求取预测值 $\hat{y}^{(0)}(k)$

灰色预测 GM(1, N)模型的第 k 个预测值为

$$\hat{y}^{(0)}(k) = -az^{(1)}(k) + \sum_{i=1}^{N-1} b_i x_i^{(1)}(k) \quad (8)$$

1.2 BP 神经网络预测模型

本文中以投资额影响因素作为输入值, 投资额作为输出值, 对 BP 神经网络进行训练。BP 神经网络^[15-17]的过程分为两个阶段, 即信号前向传播和误差反向传播。

1) 信号前向传播

假设网络含有 n 个节点和 L 层, 第一层为输入层, 最后一层为输出层, 其余层为隐含层。取隐含层和输出层的作用函数为 Sigmoid 函数, 即

$$f(x) = \frac{1}{1 + e^{-x}} \quad (9)$$

设给定 N 个样本 $(x_k, y_k)(k=1, 2, \dots, N)$, 对某一输入 x_k , 网络的输出为 y_k , 节点 i 的输出为 O_{ik} 。对于第 l 层第 j 个单元 ($l \in L$), 当网络输入第 k 个样本时, 节点 j 的输入 $net_{jk}^{(l)}$ 和输出 $O_{jk}^{(l)}$ 分别为

$$net_{jk}^{(l)} = \sum_i w_{ji}^{(l)} O_{ik}^{(l-1)} \quad (10)$$

$$O_{jk}^{(l)} = f(net_{jk}^{(l)}) \quad (11)$$

式中: $O_{ik}^{(l-1)}$ 表示当输入第 k 个样本时, 第 $l-1$ 层第 i 个节点的输出; $w_{ji}^{(l)}$ 为第 l 层节点 i, j 间的权值系数。

2) 误差反向传播

误差函数定义为

$$E_k = \frac{1}{2} \sum_j (y_{jk} - \bar{y}_{jk})^2 \quad (12)$$

总误差为

$$E = \frac{1}{2N} \sum_{k=1}^N E_k \quad (13)$$

定义

$$\delta_{jk}^{(l)} = \frac{\partial E_k}{\partial net_{jk}^{(l)}} \quad (14)$$

因此有

$$\frac{\partial E_k}{\partial w_{ij}^{(l)}} = \frac{\partial E_k}{\partial net_{jk}^{(l)}} \cdot \frac{\partial net_{jk}^{(l)}}{\partial w_{ij}^{(l)}} = \frac{\partial E_k}{\partial net_{jk}^{(l)}} O_{ik}^{(l-1)} = \delta_{jk}^{(l)} O_{ik}^{(l-1)} \quad (15)$$

此时分两种情况进行讨论:

(1) 若节点 j 为输出层节点, 则 $O_{jk}^{(l)} = \bar{y}_{jk}$, 故有

$$\delta_{jk}^{(l)} = \frac{\partial E_k}{\partial net_{jk}^{(l)}} = \frac{\partial E_k}{\partial \bar{y}_{jk}} \cdot \frac{\partial \bar{y}_{jk}}{\partial net_{jk}^{(l)}} = -(y_k - \bar{y}_{jk}) f'(net_{jk}^{(l)}) \quad (16)$$

(2) 若节点 j 为隐含层节点, 则

$$\delta_{jk}^{(l)} = \frac{\partial E_k}{\partial net_{jk}^{(l)}} = \frac{\partial E_k}{\partial O_{jk}^{(l)}} \cdot \frac{\partial O_{jk}^{(l)}}{\partial net_{jk}^{(l)}} = \frac{\partial E_k}{\partial O_{jk}^{(l)}} f'(net_{jk}^{(l)}) \quad (17)$$

式中, $O_{jk}^{(l)}$ 为第 $(l+1)$ 层的输入, 计算时应从第 $(l+1)$ 层回推。在第 $(l+1)$ 层第 m 个节点, 有

$$\frac{\partial E_k}{\partial O_{jk}^{(l)}} = \sum_m \frac{\partial E_k}{\partial net_{mk}^{(l+1)}} \cdot \frac{\partial net_{mk}^{(l+1)}}{\partial O_{jk}^{(l)}} = \sum_m \frac{\partial E_k}{\partial net_{mk}^{(l+1)}} w_{mj}^{(l+1)} = \sum_m \delta_{mk}^{(l+1)} w_{mj}^{(l+1)} \quad (18)$$

将式(18)代入式(17)中, 得

$$\delta_{jk}^{(l)} = \sum_m \delta_{mk}^{(l+1)} w_{mj}^{(l+1)} f'(net_{jk}^{(l)}) \quad (19)$$

综上所述可得

$$\begin{cases} \delta_{jk}^{(l)} = \sum_m \delta_{mk}^{(l+1)} w_{mj}^{(l+1)} f'(net_{jk}^{(l)}) \\ \frac{\partial E_k}{\partial w_{jk}^{(l)}} = \delta_{jk}^{(l)} O_{jk}^{(l-1)} \end{cases} \quad (20)$$

因此, L 层 BP 神经网络算法步骤如下。

- 1) 设定初始权值系数。
- 2) 重复以下过程直到满足 $E < \varepsilon$, ε 为精度。
- (1) 对样本 $k=1, \dots, N$

前向过程计算: 计算每层节点的 $O_{jk}^{(l-1)}$ 、 $net_{jk}^{(l)}$

和 \bar{y}_k 。

反向过程计算: 对各层 $(l=L-1, \dots, 2)$, 计算 $\delta_{jk}^{(l)}$ 。

(2) 修正权值

$$w_{ij}^{(t+1)} = w_{ij}^{(t)} - \mu \frac{\partial E}{\partial w_{ij}^{(t)}} \quad (21)$$

式中: t 为迭代次数; μ 为步长且 $\mu > 0$;

$$\frac{\partial E}{\partial w_{ij}^{(t)}} = \sum_{k=1}^N \frac{\partial E_k}{\partial w_{ij}^{(t)}}。$$

3) 结束。

1.3 多元回归模型

在实际经济问题中, 电网投资额受多个因素的影响。因此, 多元回归模型的一般形式为

$$y_i = \beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \dots + \beta_n x_{ni} + \mu_i, i=1, 2, \dots, k \quad (22)$$

式中: y_i 为投资额; x_{qi} ($q=1, 2, \dots, n$) 为投资额影响因素; n 为序列长度; $\beta_0, \beta_1, \beta_2, \dots, \beta_n$ 为回归系数, 可通过最小二乘等方法求得; 参变量 μ_i 的样本观测值在参数估计过程中始终取 1。

2 电网投资组合预测模型及其求解

为进一步提高电网投资的预测精度, 本文提出了电网投资组合预测模型以及改进的遗传算法并用于模型求解。

2.1 电网投资组合预测模型

设 $y(k)$ ($k=1, 2, \dots, n$) 为第 k 年电网投资实际值, $f_i(k)$ 为第 i ($i=1, 2, \dots, l$) 种预测模型所得到的第 k 年电网投资预测值, w_i 为第 i 种预测模型权重。 $e_i(k)$ 为第 i 个预测模型第 k 年电网投资预测误差, 则有

$$y(k) = \sum_{i=1}^l w_i (f_i(k) + e_i(k)) \quad (23)$$

设 $\hat{y}(k)$ 为利用电网投资组合模型得到的第 k 年预测值, 则有

$$\hat{y}(k) = \sum_{i=1}^l w_i f_i(k) \quad (24)$$

构造以预测误差平方和最小为目标的电网投资组合预测模型如式(25)所示, 其中的目标函数在各领域的应用最为广泛, 且计算较为简单。

$$\begin{cases} \min \sum_{k=1}^n \left(y(k) - \sum_{i=1}^l w_i f_i(k) \right)^2 \\ \text{s.t.} \quad \sum_{i=1}^l w_i = 1, \\ \quad \quad \quad 0 \leq w_i \leq 1 \end{cases} \quad (25)$$

2.2 电网投资组合预测模型求解

式(25)所描述的预测模型为一非线性规划

问题, 可以采用遗传算法求解。遗传算法^[18-20]模拟生物进化的过程, 从一个初始种群开始, 进行一系列选择、交叉和变异的操作, 直至达到收敛条件, 得到最优解。

2.2.1 约束处理

本文将式(25)中的等式约束处理为不等式约束, 即

$$w_I = 1 - \sum_{i=1}^{I-1} w_i, \sum_{i=1}^{I-1} w_i \leq 1, w_i \geq 0 \quad (26)$$

式中, w_I 为第 I 个预测模型权重。这就将式(25)转变为具有 I 个不等式约束条件的非线性规划问题。因此, 式(24)转化为

$$\hat{y}(k) = \sum_{i=1}^{I-1} w_i f_i(k) + (1 - \sum_{i=1}^{I-1} w_i) f_I(k) \quad (27)$$

对于非线性规划问题求解中不满足约束的个体, 在计算其适应度时, 一般施加一个罚函数以降低个体适应度, 使个体被遗传到下一代的机会减小。因此, 对式(28)所示的具有 n 个不等式约束条件的非线性规划问题:

$$\begin{cases} \min & f(X) \\ \text{s.t.} & g_j(X) \geq 0, \quad j=1, 2, \dots, n \end{cases} \quad (28)$$

取评估函数为

$$F(X) = f(X) - P(X) \quad (29)$$

式中, 罚函数 $P(X)$ 为

$$P(X) = \begin{cases} 0, & \text{若 } X \text{ 可行} \\ \sum_{j=1}^n r_j \cdot g_j(X), & \text{其他} \end{cases} \quad (30)$$

式中, r_j 为第 j 个约束条件 $g_j(X)$ 的可变罚系数。

2.2.2 编码

采用二进制编码时, 遗传算法具有更强的搜索能力, 因此本文采用二进制编码。设种群规模为 M , 即包含 M 个个体, 每个个体的染色体中含有 $I-1$ 个基因, 分别对应 w_1, w_2, \dots, w_{I-1} , 每个基因由 n 位二进制串构成, n 值根据权重的精度来确定。

2.2.3 改进交叉算子

遗传算法中, 交叉算子的作用是产生新个体以增大算法的全局搜索能力。简单遗传算法中的交叉概率为一常数, 没有考虑到算法初期群体质量差、而后期群体质量好的特点。本文提出的自适应交叉概率为

$$p_c^q = \begin{cases} p_{c,\max} \times e^{-q/Q}, & p_{c,\max} \times e^{-q/Q} < p_{c,\min} \\ p_{c,\min}, & \text{其他} \end{cases} \quad (31)$$

式中: q 表示第 q 次迭代; Q 为迭代次数;

$p_{c,\max}$ 、 $p_{c,\min}$ 分别为预设的最大交叉概率和最小交叉概率。由式(31)可知, p_c^q 随着 q 的增大而减小。在算法初期, 交叉概率大, 可以得到更多的个体, 保证有足够快的计算速度; 在算法后期, 降低交叉概率, 以确保算法能够稳定收敛。

2.2.4 改进变异算子

遗传算法中变异算子的主要作用是增大种群个体的多样性。变异率过大, 进化随机性增强, 算法不易收敛; 变异率过小, 种群多样性过小, 容易使算法陷入局部最优解。变异率的设计所遵循的原则为: (1) 适应度越大的个体应当具有较小的变异率以保留优良特性, 适应度越小的个体应具有较大的变异率; (2) 随着迭代次数的增加, 变异率逐渐减小使算法趋向稳定。因此, 本文根据以上原则改进了自适应变异率, 即

$$p_m^q = \begin{cases} e^{-|f(X_i)/f_{\max}| - q/Q} \times p_{m,\max}, & \\ \text{若 } e^{-|f(X_i)/f_{\max}| - q/Q} \times p_{m,\max} > p_{m,\min}; & (32) \\ p_{m,\min}, & \text{其他} \end{cases}$$

式中: f_{\max} 为当前种群最大适应度; $p_{m,\max}$ 为预设的最大变异概率; $p_{m,\min}$ 为预设的最小变异概率; $f(X_i)$ 为待变异个体的适应度。由式(32)可知, 当 $f(X_i)$ 或 q 增大时, p_m^q 减小。

2.2.5 算法流程

1) 初始化

令迭代次数 $q=0$ 。随机生成一个初始种群 $P(0)$ 。其中第 m 个个体的权重 $w_1(m,0), w_2(m,0), \dots, w_{I-1}(m,0)$ 取值方式为首先从区间 $[0,1]$ 上随机选取一个值 $w_1(m,0)$, 再从区间 $[0, 1 - \sum_{i=1}^z w_i(m,0)]$ 随机选取

$w_{z+1}(m,0)$ ($z=1, 2, \dots, I-2$), 进而将 $w_1(m,0), w_2(m,0), \dots, w_{I-1}(m,0)$ 表示为 $I-1$ 位二进制串。

2) 计算评估函数

计算种群 $P(q)$ 中每个个体 $w(m,q) = \{w_1(m,q), w_2(m,q), \dots, w_{I-1}(m,q)\}$ 的适应度 $Fit(w(m,q))$, 即

$$Fit(w(m,q)) = C_{\max} - f(w(m,q)) \quad (33)$$

式(33)中, 目标函数为

$$f(w(m,q)) = \sum_{k=1}^n \left(y(k) - \sum_{i=1}^{I-1} w_i(m,q) f_i(k) - (1 - \sum_{i=1}^{I-1} w_i(m,q)) f_I(k) \right)^2$$

C_{\max} 为每一代中误差平方和最大值和惩罚函数最大值之和。按式(30)计算评估函数 $F(w(m,q))$ 。

3) 繁殖、交叉、变异

计算每代中个体生存概率, 即

$$p_i^{(q)} = \frac{F(w_i(m, q))}{\sum_{i=1}^M F(w_i(m, q))} \quad (34)$$

通过“轮盘赌法”随机选择个体进行繁殖, 并将繁殖生成的个体组成父代 $P'(q+1)$ 。以 p_c^q 的概率交换两个父代之间对应分量完成交叉操作。交叉结束后, 再以 p_m^q 的概率改变每个个体二进制串上每一位从而完成变异操作。

4) 循环

当达到迭代次数或小于设定误差时, 停止计算。否则, 转入步骤 2), 继续进行计算适应度、复制、杂交、变异等操作。

5) 求解组合预测模型预测值

将由遗传算法所得到的最优个体各基因二进制串解码转换成十进制值后, 利用式(27)就可以求得组合预测模型预测值。

本文所提出的电网投资组合预测模型求解的流程如图 1 所示。

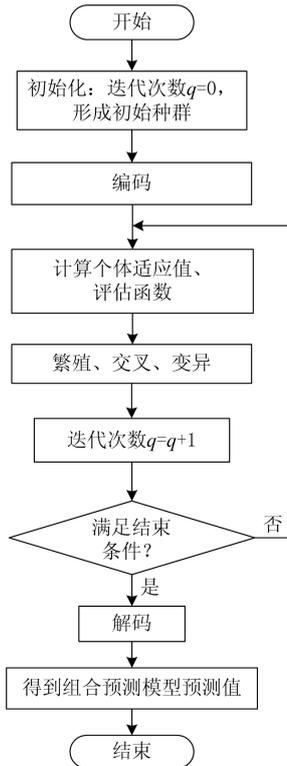


图 1 电网投资组合预测模型的求解流程

Fig. 1 Solution flow of grid portfolio forecasting model

3 算例分析

电网投资受社会用电量、供电可靠性、用电负荷、线损率、电源结构、宏观政策等方面的影响^[1,21-22]。河南某地区电网近 10 年投资、负荷、全社会用电量、

供电人口、变电容量、供电可靠率和线损率数据如表 1 所示。

首先, 采用灰色关联法^[23-24]分析各影响因素与电网投资额的关联度, 计算得到各影响因素的关联系数变化图如图 2 所示。由图 2 可以看出, 全社会用电量和最大负荷与电网投资额在各时间点上的关联系数明显大于其他因素。而计算其关联度可知, 全社会用电量和最大负荷与电网投资额的关联度分别为 0.673 9、0.673 1, 也远大于其余因素。

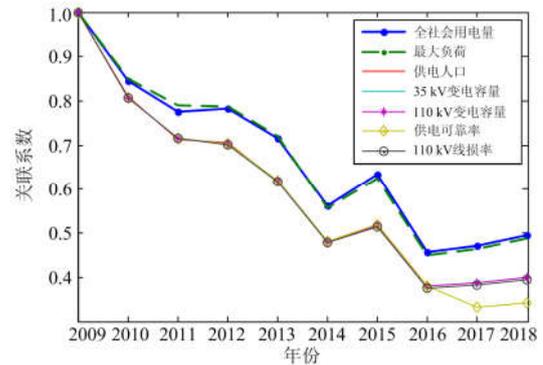


图 2 关联系数变化图

Fig. 2 Correlation coefficient change chart

因此, 本文采用社会用电量和负荷作为自变量, 对电网投资额进行预测。对该地区电网 10 年间的投资数据分别采用灰色预测 GM(1, N)模型、BP 神经网络、多元回归模型、文献[3]的组合预测模型、文献[4]的组合预测模型和本文的组合预测模型分别进行预测, 并与实际值进行对比, 预测值和残差如表 2 所示。灰色预测 GM(1, N)模型、BP 神经网络、多元回归模型和本文的组合预测模型预测值的相对误差曲线如图 3 所示。文献[3]的组合预测模型、文献[4]的组合预测模型和本文的组合预测模型预测值的相对误差曲线如图 4 所示。

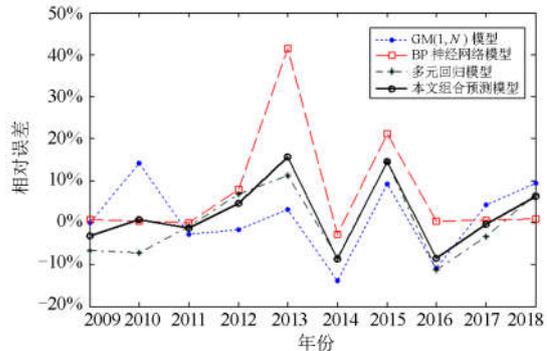


图 3 三种单一预测模型和本文组合预测模型预测值的相对误差曲线

Fig. 3 Relative error curves of the predicted values of the three single prediction models and the combined prediction models

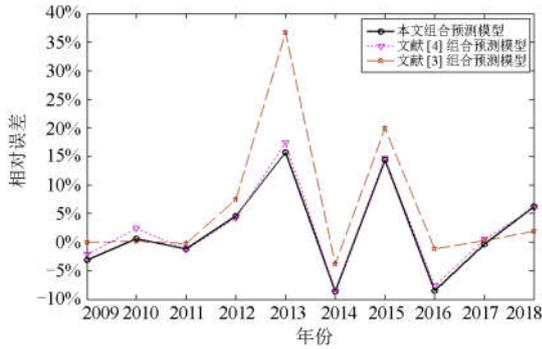


图 4 三种组合预测模型预测值的相对误差曲线

Fig. 4 Relative error curve of predicted values of three combined prediction models

本文以预测误差平方和最小为目标函数, 使得组合预测法的误差平方和最小, 并减少局部年份出现较大误差的情况。由图 3 可知, 组合预测模型预测值相对误差曲线总是位于单一预测模型预测值相对误差曲线之间。在三个单一预测模型预测误差均为正或均为负时, 组合预测模型的预测误差不大,

而在三个单一预测模型预测误差不同时为正或为负时, 组合预测模型的预测误差可以比单一预测模型预测误差更小。因此, 组合预测模型的预测结果优于单一预测模型的预测结果。

由图 4 可知, 文献[4]组合预测模型与本文组合预测模型相对误差曲线比较接近, 但对于本文目标函数而言, 它不是最优的。而文献[3]组合预测模型相对误差曲线波动较大, 有些年的预测误差过大, 说明本文算法的组合预测法在降低相对误差的同时也使其值更为均衡。

经过计算可得, 灰色预测 GM(1, N)模型、BP 神经网络模型、多元回归模型和本文组合预测模型预测结果的相对误差绝对值的平均值分别为 6.93%、7.82%、7.70%和 6.34%, 相对误差的方差分别为 0.007 9、0.019 2、0.008 2 和 0.007 1。由此可知, 本文的组合预测模型预测精度最高, 其相对误差绝对值的平均值最低, 且相对误差分布更加均匀, 不会出现某个时间节点预测值相对误差特别大的情况。文献[3-4]中组合预测模型预测结果的相对误差

表 1 河南某地区电网近 10 年投资、负荷、全社会用电量数据

Table 1 Data of investment, load, and total social electricity consumption in a region of Henan in the past 10 years

年份	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018
投资额/百万元	15.400	24.120	29.970	30.750	37.904	54.755	49.467	75.000	73.360	70.520
全社会用电量/亿 kWh	8.37	9.49	10.54	11.18	12.72	14.32	15.4	17.04	17.51	17.99
最大负荷/MW	180	206	236	245	277	302	321	352	363	374
供电人口/万人	81.1	81.3	80.4	81.5	80.3	80.8	81.6	81.2	81.4	81.6
35 kV 变电容量/MVA	300	300	300	300	300	300	300	300	300	300
110 kV 变电容量/MVA	540	540	540	540	540	540	540	540	540	540
供电可靠率/%	99.77	99.78	99.83	99.82	99.81	99.81	99.99	99.99	1.00	1.00
110 kV 线损率/%	10.2	10.2	10.2	10.1	10.1	9.9	9.9	9.5	9.5	9.5

表 2 各模型投资预测值与实际值的比较

Table 2 Comparison of predicted and actual values of each model investment

年份	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018
实际值	15.400	24.120	29.970	30.750	37.904	54.755	49.468	75.000	73.360	70.520
GM(1, N)模型预测值	15.400	27.534	29.140	30.211	39.079	47.207	54.018	66.802	76.469	77.125
残差	0.000	-3.414	0.830	0.539	-1.175	7.548	-4.550	8.198	-3.109	-6.605
BP 神经网络模型预测值	15.521	24.185	29.963	33.209	53.579	53.188	59.894	75.327	73.722	71.198
残差	-0.121	-0.065	0.007	-2.459	-15.675	1.567	-10.426	-0.327	-0.362	-0.678
多元回归模型预测值	14.365	22.392	29.708	32.832	42.187	50.231	56.653	66.582	70.922	75.374
残差	1.035	1.728	0.262	-2.082	-4.283	4.524	-7.185	8.418	2.438	-4.854
本文组合预测模型预测值	14.923	24.277	29.602	32.161	43.852	50.024	56.622	68.611	73.150	74.940
残差	0.477	-0.157	0.368	-1.411	-5.948	4.731	-7.154	6.389	0.210	-4.420
文献[3]组合模型预测值	15.400	24.146	29.903	33.045	51.827	52.640	59.322	74.091	73.557	71.866
残差	0.000	-0.026	0.067	-2.295	-13.923	2.116	-9.854	0.909	-0.197	-1.346
文献[4]组合模型预测值	15.067	24.709	29.586	32.034	44.486	50.058	56.699	69.251	73.678	74.744
残差	0.333	-0.589	0.384	-1.284	-6.582	4.698	-7.231	5.749	-0.318	-4.224

单位: 百万元

绝对值的平均值分别为 7.17%和 6.47%，相对误差的方差分别为 0.016 1 和 0.007 2。因此，本文组合预测模型预测精度也比其余两种组合预测模型的预测精度高。使用本文组合预测模型可预测后一年的投资额为 8 025.3 万元。

4 结论

本文综合应用灰色预测 GM(1, N)模型、BP 神经网络模型、多元回归模型，提出了一种针对电网投资预测的组合预测模型，并通过将等式约束处理为不等式约束以及改进交叉算子和变异算子提高了遗传算法的收敛速度。算例分析结果表明，本文所提出的组合预测模型能够综合三种预测方法的优势，提高预测精度，从而更有效地预测电网投资额，有利于电网企业合理进行投资分配规划，实现投资的科学化、标准化、精益化。

此外，若将组合预测模型的目标函数改为不可微函数，例如绝对预测误差和、最大误差绝对值和预测误差全距等，这类目标函数的计算较为复杂，利用传统计算方法很难得出结果。而采用本文算法只需将其中的目标函数做相应替换，计算非常简便。

参考文献

- [1] 赵会茹, 杨璐, 李春杰, 等. 基于协整理论和误差修正模型的电网投资需求预测研究[J]. 电网技术, 2011, 35(9): 193-198.
ZHAO Huiru, YANG Lu, LI Chunjie, et al. Research on prediction to investment demand of power grid based on co-integration theory and error correction model[J]. Power System Technology, 2011, 35(9): 193-198.
- [2] 胡柏初, 胡刚, 胡朝华, 等. 基于灰色预测的电网基建投资测算模型[J]. 电子科技大学学报, 2013, 42(6): 890-894.
HU Baichu, HU Gang, HU Zhaohua, et al. Grid infrastructure investment calculation model based on gray prediction[J]. Journal of University of Electronic Science and Technology of China, 2013, 42(6): 890-894.
- [3] 胡卫利, 程亮, 马倩, 等. 基于改进粒子群组合算法的电网基建年度投资预测[J]. 电网与清洁能源, 2014, 30(11): 52-56.
HU Weili, CHENG Liang, MA Qian, et al. Prediction of annual power grid infrastructure investment based on hybrid algorithm of improved PSO[J]. Power System and Clean Energy, 2014, 30(11): 52-56.
- [4] 卢奇, 顾培亮, 邱世明. 组合预测模型在我国能源消费系统中的建构及应用[J]. 系统工程理论与实践, 2003, 23(3): 24-30.
LU Qi, GU Peiliang, QIU Shiming. Construction and application of combined forecasting model in China's energy consumption system[J]. System Engineering Theory and Practice, 2003, 23(3): 24-30.
- [5] 周宏, 黄婷, 戴韧, 等. 几种灰色模型用于电力消费中期预测研究[J]. 电网技术, 2000, 24(7): 49-54.
ZHOU Hong, HUANG Ting, DAI Ren, et al. Study on alternative grey models to forecast middle term electric power consumption[J]. Power System Technology, 2000, 24(7): 49-54.
- [6] 陈立, 王蓓蓓, 黄俊辉, 等. 电网公司保底服务实施后的增量配电网投资策略[J]. 电力系统自动化, 2018, 42(20): 39-44.
CHEN Li, WANG Beibei, HUANG Junhui, et al. Asset investment strategy adapting default service of incremental distribution network for grid companies[J]. Automation of Electric Power Systems, 2018, 42(20): 39-44.
- [7] 谢开贵, 李春燕, 俞集辉. 基于遗传算法的短期负荷组合预测模型[J]. 电网技术, 2001, 25(8): 20-23.
XIE Kaigui, LI Chunyan, YU Jihui. Genetic algorithm based combination forecasting model for short term load[J]. Power System Technology, 2001, 25(8): 20-23.
- [8] 方略, 程浩忠, 柳璐, 等. 基于多指标体系的 10 kV 配电网投资分配评价[J]. 华东电力, 2014, 42(6): 1092-1097.
FANG Lüe, CHENG Haozhong, LIU Lu, et al. Evaluation of 10 kV distribution network investment allocation based on multi-index system[J]. East China Electric Power, 2014, 42(6): 1092-1097.
- [9] 张志, 杜延菱, 崔慧军, 等. 考虑关联因素的智能化中长期电力负荷预测方法[J]. 电力系统保护与控制, 2019, 47(2): 24-30.
ZHANG Zhi, DU Yanling, CUI Huijun, et al. Intelligent mid-long electricity load forecast method considering associated factors[J]. Power System Protection and Control, 2019, 47(2): 24-30.
- [10] 胡卫利, 程亮, 马倩, 等. 基于奇异谱分析的短期电价预测[J]. 电力系统保护与控制, 2019, 47(1): 115-121.
HU Weili, CHENG Liang, MA Qian, et al. Short-term electricity price forecasting based on singular spectrum analysis[J]. Power System Protection and Control, 2019, 47(1): 115-121.
- [11] 吴佳懋, 李艳, 符一. 基于粗糙集-混沌时间序列 Elman 神经网络的短期用电量预测[J]. 电力系统保护与控制, 2019, 47(3): 23-30.

- WU Jiamao, LI Yan, FU Yi. Short-term power consumption prediction based on rough set chaotic time series Elman neural network[J]. Power System Protection and Control, 2019, 47(3): 23-30.
- [12] 石玉恒, 赵娜, 王凌, 等. 北京地区日最大电力负荷预测模型初探[J]. 中国电力, 2019, 52(8): 157-163.
SHI Yuheng, ZHAO Na, WANG Ling, et al. Study on forecasting model of maximum daily power load in Beijing area[J]. Electric Power, 2019, 52(8): 157-163.
- [13] 詹崇森, 荣喜民. 基于扰动因子的 GM(1,N)模型数值算法[J]. 统计与决策, 2019(12): 27-30.
ZHAN Tangsen, RONG Ximin. GM(1,N) model numerical algorithm based on disturbance factor[J]. Statistics and Decision-making, 2019(12): 27-30.
- [14] 靳春旭, 董福贵. 长期风电负荷预测方法比较[J]. 广东电力, 2018, 31(9): 70-76.
JIN Chunxu, DONG Fugui. Comparison of long-term wind load forecasting methods[J]. Guangdong Electric Power, 2018, 31(9): 70-76.
- [15] LIPPMANN R P. An introduction to computing with neural nets[M]. ACM, 1988.
- [16] WU Guoqiang. Fault detection method for ship equipment based on BP neural network[C] // International Conference on Robots & Intelligent System, 2018, Changsha, China: 556-559.
- [17] 徐卫东, 聂一雄, 周文文, 等. 基于反向传播神经网络的载流导体本体温度仿真计算[J]. 广东电力, 2017, 30(11): 104-108.
XU Weidong, NIE Yixiong, ZHOU Wenwen, et al. Temperature simulation of current-carrying conductor body based on back-propagation neural network[J]. Guangdong Electric Power, 2017, 30(11): 104-108.
- [18] 周明, 孙树栋. 遗传算法原理及应用[M]. 北京: 国防工业出版社, 1999.
- [19] 汪惟源, 乔颖, 窦飞, 等. 基于改进遗传算法的海上风电场集电系统拓扑优化[J]. 中国电力, 2019, 52(1): 69-74.
WANG Weiyuan, QIAO Ying, DOU Fei, et al. Optimization of offshore wind farm collector systems based on improved genetic algorithm[J]. Electric Power, 2019, 52(1): 63-68.
- [20] 边霞, 米良. 遗传算法理论及其应用研究进展[J]. 计算机应用研究, 2010, 27(7): 2425-2429.
BIAN Xia, MI Liang. Development on genetic algorithm theory and its applications[J]. Application Search of Computers, 2010, 27(7): 2425-2429.
- [21] 季立伟, 杨丽萍, 费改英. 电网工程投资影响因素分析及预测[J]. 中国电力企业管理, 2016(6): 85-92.
JI Liwei, YANG Liping, FEI Gaiying. Analysis and forecast of factors affecting power grid engineering investment[J]. China Power Enterprise Management, 2016(6): 85-92.
- [22] 张兴平, 牛玉琴, 赵旭. 中国电力消费协整关系模型[J]. 中国电机工程学报, 2008, 28(13): 114-119.
ZHANG Xingping, NIU Yuqin, ZHAO Xu. Cointegration analysis of electricity consumption in China[J]. Proceedings of the CSEE, 2008, 28(13): 114-119.
- [23] 王丽, 朱文广, 杨为群, 等. 基于灰色神经网络与灰色关联度的中长期日负荷曲线预测[J]. 武汉大学学报: 工学版, 2019, 52(1): 58-64, 70.
WANG Li, ZHU Wenguang, YANG Weiqun, et al. Medium and long-term daily load curve prediction based on grey neural network and grey correlation degree[J]. Engineering Journal of Wuhan University, 2019, 52(1): 58-64, 70.
- [24] 邓威, 刘俐, 李勇, 等. 基于 GCA 和 LSTM 神经网络的配电网网损预测[J]. 广东电力, 2019, 32(9): 154-159.
DENG Wei, LIU Li, LI Yong, et al. Distribution network loss forecasting based on GCA and LSTM neural network[J]. Guangdong Electric Power, 2019, 32(9): 154-159.

收稿日期: 2019-06-05; 修回日期: 2019-07-12

作者简介:

刘巍(1983—), 男, 工学硕士, 教授级高工, 主要研究方向为智能电网技术; E-mail: Liuwei830610@163.com

李锰(1986—), 男, 工学硕士, 高级工程师, 主要研究方向为配电网规划技术; E-mail: hnlimn@163.com

李秋燕(1981—), 女, 工学硕士, 高级工程师, 主要研究方向为配电网规划技术。E-mail: 343670567@qq.com

(编辑 魏小丽)