

DOI: 10.7667/PSPC162122

含有历史不良数据的电力负荷预测研究

杨慧霞^{1,2}, 邓迎君³, 刘志斌⁴, 姚睿⁵

(1. 许昌开普电气研究院, 河南 许昌 461000; 2. 河南省继电保护及自动化重点实验室, 河南 许昌 461000;
3. 许继集团有限公司, 河南 许昌 461000; 4. 上海电力学院, 上海 200090;
5. 北京四方继保自动化股份有限公司, 北京 100085)

摘要: 传统负荷预测算法在历史负荷序列无不良数据的条件下已能对短期负荷做出较为理想的预测。由于实际负荷数据在监测、集抄、存储过程中难免会产生错误或有所误差, 此时仍依靠传统预测算法进行负荷预测, 可能在某些时间节点会引起较大误差。为了解决此问题, 提出含有历史负荷序列不良数据辨识与修正能力且能对负荷进行相似度预测及负荷偏差纠正的预测模型。通过运用实际电力负荷数据进行验证, 该模型能较好地避免了不良数据的干扰, 有效地提高了含有不良数据的历史负荷序列的预测精度。

关键词: 短期负荷预测; 不良数据辨识; 相似度; 神经网络

Study on electric load forecasting with historical bad data

YANG Huixia^{1,2}, DENG Yingjun³, LIU Zhibin⁴, YAO Rui⁵

(1. Xuchang Ketop Electric Research Institute, Xuchang 461000, China; 2. Henan Key Laboratory of Relay Protection and Automation, Xuchang 461000, China; 3. XJ Group Corporation, Xuchang 461000, China; 4. Shanghai University of Electric Power, Shanghai 200090, China; 5. Beijing Sifang Automation Co., Ltd., Beijing 100085, China)

Abstract: Traditional load forecasting algorithm can predict short-term load when there is no bad data in historical load sequence. Actual load data will inevitably produce errors during the process of monitoring, collecting and storing, if the traditional prediction algorithm is still used for load forecasting, it may cause large errors at some time nodes. In order to solve this problem, this paper proposes a prediction model which can not only identify and correct the bad data of historical load sequence and but also predict the load similarity and correct the load deviation. By using the actual load data to verify the model, the model can better avoid the interference of bad data, and effectively improve the prediction accuracy of the historical load sequence with bad data.

This work is supported by National Natural Science Foundation of China (No. 61602295) and Natural Science Foundation of Shanghai (No. 16ZR1413100).

Key words: short-term load forecasting; bad data identification; similarity; neural networks

0 引言

短期负荷预测是电力负荷预测的重要组成部分, 准确的电力负荷预测对于制定发电计划、经济合理的电力调配计划、上网竞价计划以及控制电网经济运行、降低旋转储备容量、进行电力市场需求分析、避免重大事故、有效化解风险、保障生产和生活用电等方面具有十分重要的意义^[1]。目前广泛

用于负荷预测的算法主要有改进神经网络^[2], 基于最小信息损失法^[3], 时间序列分析法^[4]以及对现有若干算法的组合算法等。由于短期负荷存在随机因素太多、非线性程度强、算法参数设定等问题, 从某种程度上限制了短期负荷预测准确率的提高, 且随着当前主动配电网和分布式发电技术的迅速发展及其他特殊原因, 不可避免地对统计数据带来了重大影响, 产生了不良统计数据, 称“不良数据”, 不良数据直接影响了电力负荷预测精度。本文在仅包含历史负荷数据的情况下, 基于改进相似度分析的初步负荷预测, 即在对历史数据进行初步辨识之后,

基金项目: 国家自然科学基金(61602295); 上海市自然科学基金(16ZR1413100)

采用优化相似度标准, 找出历史周期中相似性较强的负荷数据进行初步预测, 然后利用 RBE 神经网络 (RBF NN) 的局部逼近特性, 对预测负荷值进行一定的误差纠正, 避免了局部极值问题, 从而进一步提高了负荷预测的精度, 满足了调度部门对于网络潮流的实时控制要求。

1 不良负荷数据的辨识

电力系统中的不良数据是由于统计口径不同、通信错误、人为因素等原因随机产生的, 历史负荷数据中同样存在不良数据。对于不良数据的辨识依赖于电力负荷在相邻或相似时间段前后负荷不会发生突变; 规律性决定了负荷可以被修正的前提, 而随机性则体现了修正值在统计意义下的置信度。一般情况下认为, 时间相近、天气条件相似和日期类型相同的相似日期具有近似相同的日负荷曲线^[5]。本文仅讨论只依赖负荷数据情况下的负荷预测, 利用历史数据本身变化的内在联系来反应其他外部因素对于电力负荷的影响, 这样更有利于在相关外部因素数据缺乏的情况下进行短期负荷预测。

1.1 不良数据的辨识

从数理统计的角度分析负荷数据的异常与否可知, 多个统计日期的相同连续时段的负荷变化率近似服从正态分布^[6-7], 多个统计日期的负荷数据近似服从正态分布。对负荷数据及负荷变化率进行概率统计分析, 完成某时段内两个近似服从正态分布模型标准化残差向量的计算, 然后设定置信度, 从而完成该时间区间内负荷水平的置信区间估计。通过考察历史数据是否在置信区间内, 从而判断出该负荷数据是否异常。

在不良数据检测的过程中, 为了避免由于检测方法引起不良数据的误判, 此处引入不良数据带来的后果及特征作为判据, 将所有数据中具备这种特征的数据认定为异常值。因此进行如下假设:

1) 下标集合为 $I = \{1, 2, \dots, n\}$ 的输入序列 $T = \{x_1, x_2, \dots, x_n\}$, 由所有 $x_i (i \in I)$ 形成的 n 维样本向量记为 $X = [x_1, x_2, \dots, x_n]^T$ 。 T 中元素有两种情况, 若 i 位置有具体值, 则称 x_i 为 i 时刻的观测值 (设有 m 个, $m \leq n$), 从而形成 m 维观测向量 Z , 下标集合为 I_z ; 若 j 位置为不良数据, 形成 $l = n - m$ 维不良数据向量 U , 下标集合为 I_u 。

2) 设 S 为模型的参数向量 (假定 k 维)。由观测向量 Z 建立模型, 可以得到参数的估计值 \hat{S} , 记为 $\hat{S} = f_z(Z)$ 。

3) 由参数估计值计算出样本向量 X 的拟合值, 记为 $\hat{X} = h(\hat{S})$ 。 $H(S)$ 为 $h(S)$ 对应的雅克比矩阵 ($n \times k$ 阶):

$$H(S) = \frac{\partial h(S)}{\partial S} = \begin{bmatrix} h_{11} & \cdots & h_{1k} \\ \vdots & & \vdots \\ h_{n1} & \cdots & h_{nk} \end{bmatrix} \quad (1)$$

$h_z(S)$ 和 $h_u(S)$ 为与 I_z 相对应 $h(S)$ 分为 m 维和 l 维向量函数; 相应的雅克比矩阵 $H_z(S)$ 和 $H_u(S)$ 。

由于真实值 Z_0 与量测值 Z 存在 m 随机误差 V_z , 假设其分量 $v_i (i \in I_z)$ 服从 $N(0, \sigma_i^2)$ 分布, 所以 v_i 相互独立, 则 V_z 的方差阵为

$$R_z = E(V_z V_z^T) = \text{diag}[\sigma_i^2] \quad (2)$$

以其逆矩阵 R_z^{-1} 作为加权, 则目标函数为

$$\min J(S) = [Z - h_z(S)]^T R_z^{-1} [Z - h_z(S)] \quad (3)$$

将 $h_z(S)$ 在 $S^{(0)}$ 附近进行泰勒展开, 忽略二次以上的非线性项之后, 得到:

$$h_z(S) \approx h_z(S^{(0)}) + \left[\frac{\partial h_z(S)}{\partial S} \right]_{S=S^{(0)}} \cdot \Delta S \quad (4)$$

式中, $\Delta S = S - S^{(0)}$, 欲使 $J(S)$ 最小必须满足式 (5)。

$$\frac{\partial J(S)}{\partial S} = -2 \left[\frac{\partial h_z(S)}{\partial S} \right]^T R_z^{-1} [Z - h_z(S)] = 0 \quad (5)$$

求得

$$\hat{S} = S^{(0)} + (H_z^{-1} R_z^{-1} H_z)^{-1} H_z^T R_z^{-1} [Z - h_z(S^{(0)})]$$

式中, H_z 的取值为 $H_z(S_0)$ 。

定义负荷数据的残差向量 $r = Z - \hat{Z}$, 其中 Z 为 m 维观测向量, \hat{Z} 为观测向量 Z 的样本估计值, 且有

$$Z = h_z(S_0) + V_z \quad (6)$$

$$\hat{Z} = h_z(S_0) + H_z(\hat{S} - S_0) \quad (7)$$

即

$$r = V_z - H_z (H_z^T R_z^{-1} H_z)^{-1} H_z^T R_z^{-1} V_z =$$

$$[E - H_z (H_z^T R_z^{-1} H_z)^{-1} H_z^T R_z^{-1}] V_z = W V_z \quad (8)$$

式中: S_0 为某系统参数的真实值; \hat{S} 为用 Z 进行参数估计的值; V_z 为 m 维观测误差向量, 其分量 v_i 是期望为 0, 方差为 σ^2 的正态分布且独立的随机变量; R_z 为 V_z 的方差矩阵, 可表示为 $\text{diag}[\sigma_i^2]$; $h_z(S_0)$ 为 n 维观测向量函数; $H_z(S)$ 为 $h_z(S)$ 对应的雅克比矩

阵; E 为单位矩阵; $W = E - H_z(H_z^T R_z^{-1} H_z)^{-1} H_z^T R_z^{-1}$ 。

定义标准化残差向量:

$$r_N = (\text{diag}[WR_z])^{-\frac{1}{2}} \cdot WV_z \quad (9)$$

由于 r_i 为 v_i 的线性组合, 从而 r_{N_i} 也是 v_i 的线性组合, 前文假设 v_i 的均值为 0, 则 r_{N_i} 的均值也为 0;

由于 $(\text{diag}[WR_z])^{-\frac{1}{2}} WR_z (\text{diag}[WR_z])^{-\frac{1}{2}}$ 的对角元素全为 1, 即 r_{N_i} 的方差为 1, 由此可知 r_{N_i} 为服从标准正态分布的随机变量。所以对于历史电力负荷数据中含有不良数据的监测流程大致可以表示为图 1, 为了方便讨论, 假设每次检验过程中只有一个不良数据。

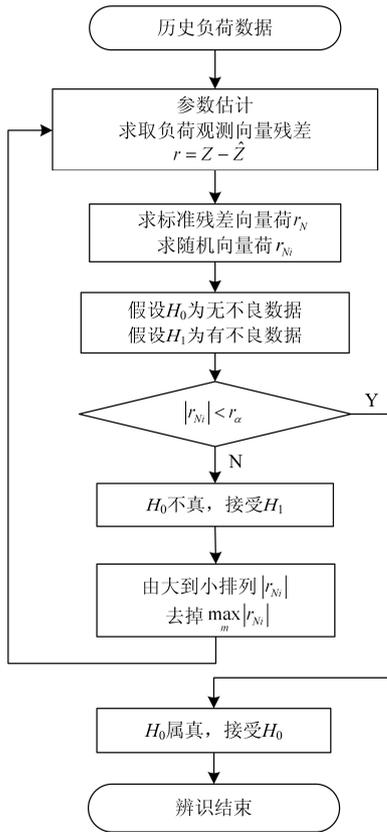


图 1 含有不良历史数据负荷预测流程图

Fig. 1 Flowchart of electric load forecasting with historical bad data

1.2 不良数据的修正

通过不良数据的辨识过程之后, 可能检测出不良数据的存在, 若对这些数据不作处理, 会严重影响电力负荷预测的计算结果, 最终导致此次预测对实际生产过程的实效。为了达到较好的建模效果, 需要对不良数据值进行处理, 兼顾考虑简单和复杂情况下的修正过程, 本文采用几种方式对不良数据

点处的值进行相应的插补, 以达到对检测出的不良数据值的修正目的。其具体过程大致依据以下原则, 对于短期负荷的预测所用的历史数据的修正可以进行如下处理: (1) 考虑同一类日期时间、同一时刻的历史负荷数据的负荷波动、负荷波动率, 将相邻负荷的最大变化率作为阈值, 如果待处理数据变化率超过某一阈值, 则取阈值代替; (2) 对于连续出现的异常负荷数据, 如图 2 所示, 可以综合考虑历史相同时间, 即选择历史相同时段的平均值与某历史时间负荷相加求得要修正时间的负荷值, 其修正值可根据式(10)计算得出。(3) 除(1)、(2)两种情况之外的复杂情况下, 采用拉格朗日插值法对不良点进行负荷值的插补。

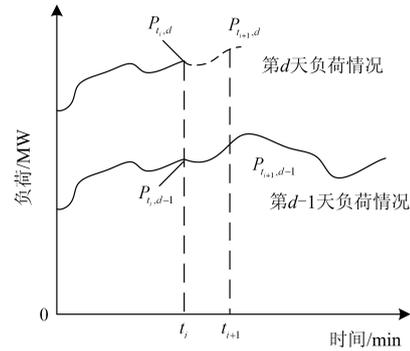


图 2 历史数据修正依据示意图

Fig. 2 Sketch map of historical data correction

$$P_{t_{i+1},d} = P_{t_{i+1},d-1} + \frac{1}{i} \sum_0^i (P_{t_i,d} - P_{t_i,d-1}) \quad (10)$$

利用拉格朗日插值法时, 首先从原始负荷的数据集中确定自变量和因变量, 取出缺失值前后的 5 个数据(前后不足 5 个数据的, 将仅有的数据组成一组), 根据取出的 10 个数据组成一组, 再利用式(11)、式(12)进行插值处理, 对全部不良数据依次进行插补, 直到全部完成为止。

$$l_i(x) = \frac{(x - x_0) \cdots (x - x_{i-1})(x - x_{i+1}) \cdots (x - x_n)}{(x_i - x_0) \cdots (x_i - x_{i-1})(x_i - x_{i+1}) \cdots (x_i - x_n)} \quad (11)$$

$$L_n(x) = \sum_{i=0}^n l_i(x) p_i \quad (12)$$

式中: x 为不良负荷值所对应的下表序号; x_i 为非不良数据负荷值 p_i 的下标序号; $L_n(x)$ 为不良数据点的插值结果。

2 负荷序列的相似度预测模型

由于短期负荷曲线存在周期性和连续性, 因此在相似或相同时间段内符合序列在变化趋势上有一定的相似性, 即虽然相同周期内负荷数值各不相

同^[8], 但是当外部影响因素大致相同时, 其负荷变化趋势基本相同, 峰谷负荷出现的时间基本相同, 如图 3 所示, 采用某地每隔 15 min 采样点的几条日负荷曲线。基于此分析可以建立负荷模型, 即待预测负荷 \hat{p} 可以用一个基于历史基本负荷的预测值 \hat{p}_t 与一个负荷波动值 \hat{p}_ε 与调节参数 α 的乘积相加来表示, 此处引入调节参数 α 。根据待预测负荷当前的实际需要选择其数值, 此时更有利于准确预测负荷(式(13))。

$$\hat{p} = \hat{p}_t + \alpha \hat{p}_\varepsilon \quad (13)$$

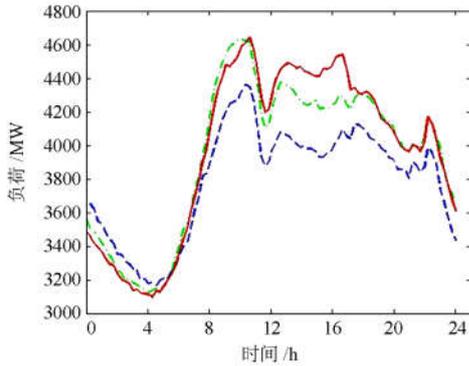


图 3 相同时间周期不同日期的负荷变化趋势

Fig. 3 Load change trend with the same time period and different dates

选取待预测负荷时间节点的前 i 个负荷数据构成向量 $P_i = (p_{t_1}, p_{t_2}, \dots, p_{t_i})$, 通过对负荷向量之间的相似度进行排序, 求取负荷数据相似度, 如式(14)所示。

$$\text{Sim}(P_i, P_j) = \frac{\sum_{k=1}^n p_{t_{ik}} \cdot p_{t_{jk}}}{\sqrt{(\sum_{k=1}^n p_{t_{ik}}^2) \cdot (\sum_{k=1}^n p_{t_{jk}}^2)}} \quad (14)$$

式中: $p_{t_{ik}}$ 为历史负荷数据向量 P_i 在时间点 t_k 处的取值; $p_{t_{jk}}$ 为待预测负荷数据向量 P_j 在时间点 t_k 处的取值。

选取负荷数据相似度的值高于预先设定的某一数值 β 的 m 组负荷数据进行基于历史负荷部分的相似度预测, 如式(15)所示。

$$\hat{p}_t = \mu \cdot p_n \quad (15)$$

式中, $p_n = (p_1, p_2, \dots, p_l, \dots, p_m)$, p_l 为高于 β 的 m 组数据中第 l 条数据在时间点 $n+1$ 处的取值;

$$\mu = (\mu_1, \mu_2, \dots, \mu_l, \dots, \mu_m)^\top, \quad \mu_l = \frac{\text{Sim}(P_l, P_j)}{\sum_{l=1}^m \text{Sim}(P_l, P_j)}$$

3 RBF 网络对负荷波动值的误差纠正

由于负荷的变化趋势受到多方面的因素影响, 例如温度、湿度、经济发展、大型活动等。虽前文中根据相似度比较高的历史负荷变化趋势进行短期预测负荷值, 待预测负荷在一定程度上与历史数据有一定的相似关系^[9-10], 但是受到一些外部因素影响时, 或多或少的会偏离其相似轨迹, 这部分偏差往往与偏差因素之间没有明确的关联关系。因此, 采用 RBF 神经网络的输入到输出的映射是非线性的, 隐含层到输出层是线性的, 且 RBF 网络是局部逼近的神经网络^[11], 因而采用 RBF 神经网络能够任意逼近负荷波动值, 且在收敛速度上也优于 BP 网络。

根据解决问题的特点, 建立 RBF 网络的结构如下: 从已收集的相似数据中选取前 n 个时间采样点, 和不同日的前 m 个同一时间采用点的负荷值作为输入向量; 根据以往学习经验设置训练补偿和阈值, 通过比较训练后的误差、算法收敛速度和网络性能来确定隐含层神经元个数和隐含层层数^[12-13]; 输出层仅包含一个输出量 \hat{p}_ε , 即预测时刻的负荷偏差值, 多输入单输出的 RBF 预测网络结构如图 4 所示。

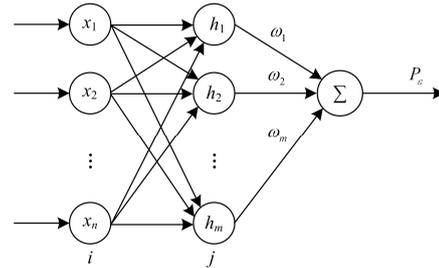


图 4 多输入单输出 RBF 神经网络

Fig. 4 Multi input single output RBF neural network

在 RBF 预测网络中 $\mathbf{P} = [x_1, x_2, \dots, x_n]^\top$ 为预测预测网络的输入向量。设网络的径向基向量, 如式(16)所示。

$$\mathbf{H} = [h_1, h_2, \dots, h_m]^\top \quad (16)$$

式中, h_j 为高斯函数(式(17))。

$$h_j = \exp\left(-\frac{\|\mathbf{X} - \mathbf{C}_j\|^2}{2b_j^2}\right) \quad j = 1, 2, \dots, m \quad (17)$$

式中, 网络第 j 个节点的中心向量为 $\mathbf{C}_j = [c_{j1}, \dots, c_{jm}]^\top$ 。

设网络的基宽向量为 $\mathbf{B} = [b_1, \dots, b_m]^\top$, b_j 为节点 j 的基函数宽度参数, 且为大于 0 的数值。网络的权向量为 $\mathbf{W} = [w_1, w_2, \dots, w_m]$ 。因此 RBF 预测网

络的输出如式(11), RBF 预测网络的逼近模型如图 5 所示。

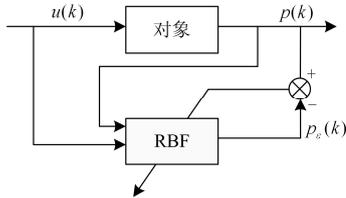


图 5 RBF 预测网络的逼近模型

Fig. 5 Approximation model for RBF prediction network

网络性能指标函数如式(17), 通过考察网络的指标函数的最优取值, 得出较为合理的短期预测负荷的波动值^[14]。

$$p_\varepsilon(t) = \sum_{j=1}^m w_j \cdot h_j \quad (18)$$

$$E(t) = \frac{1}{2} [y(t) - y_\varepsilon(t)]^2 \quad (19)$$

4 实例分析

已知我国北方某地 2008 年的每隔 15 min 进行一次监测的负荷数据, 以预测 6 月 28 日的负荷为例, 该时间节点之前的历史负荷数据作为预测的基础数据。为了验证算法的有效性, 以正常数据和含有不良数据的历史负荷序列进行预测, 此处假设历史数据(6 月 26 日、6 月 27 日)存在空数据和因测量错误引起的错误数据。假设 6 月 26 日 12 时数据为空值, 6 月 27 日 12 时数值输入错误(将 3999.97 误填为 3666.67), 通过对两种情况下负荷预测结果和实际负荷数据进行对比求取相对误差, 从而验证算法的有效性。

取小概率 $\alpha=5\%$ 作为假设检验的依据, 查询标准正态分布表可知其概率密度 $\gamma_{5\%} = 1.645$ 。RBF 的神经网络的参数设定为: 输入层、隐含层和输出层节点数分别为 96、4 和 1, 迭代次数 100 次, 学习效率 0.1, 目标误差 0.01。在预测开始之前, 经过对历史数据的辨识准确地锁定了历史负荷序列中不良数据的位置, 对于空数据位置取 2008 年 6 月 28 日之前各个工作日 12 时数据求和取平均值来代替; 对于错误数据位置采用“近大远小”原则对 1 至 5 月各月 28 日 12 时数据加权求取。

图 6 和图 7 分别为 2008 年 6 月 28 日的实际负荷曲线、正常历史数据预测曲线、含有不良数据且进行和不进行不良数据处理的 4 条负荷曲线。

通过图 6 和图 7 的负荷变化趋势可知, 由于历史负荷数据中存在不良数据, 如果负荷预测之前不进行辨识与修正, 那么就会在预测过程中产生较大影响。

从图 6 可以看出, 利用含有不良数据的历史序列进行负荷预测, 在 12 时的预测结果出现了局部极值的情况, 负荷曲线出现瞬间的跃变, 且对其以后的部分时间点的负荷预测结果造成了一定的影响^[15-16]。

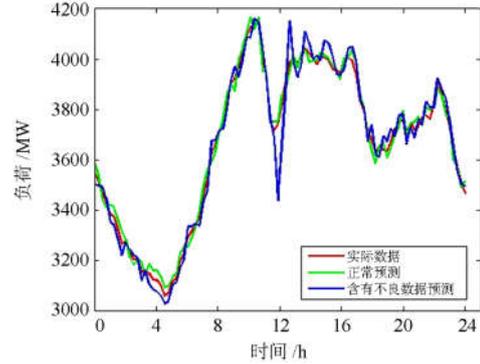


图 6 未处理历史不良数据的预测结果

Fig. 6 Predicted results of untreated historical data

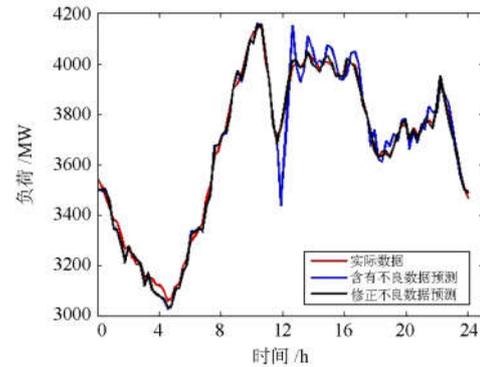


图 7 修正历史不良数据的预测结果

Fig. 7 Revised historical bad data forecast results

表 1 为预测结果的统计指标对比, 在历史负荷序列存在的情况下, 直接进行预测, 误差平方和可达 259 363, 相对误差平方和可达 185.1563, 最大相对误差为 -8.024%, 准确程度较差。在对于不良数据进行辨识和修正之后预测误差平方和可达 78 722, 相对误差平方和可达 61.496 13, 最大相对误差为 1.53%, 且通过与无不良数据的历史负荷序列相比, 虽然在相对误差平方和与最大的误差有一定差别, 但基本满足了短期负荷预测的精度要求。

表 1 三种预测方式统计特性对比

Table 1 Comparison of statistical characteristics of three forecasting methods

	直接预测	含不良数据	修正预测
绝对误差平方和	54 140	259 363	78 722
相对误差平方和	43.680 34	185.1563	61.496 13
最大误差/%	1.532 06	-8.024 46	-1.654 62

5 结论

电力系统短期负荷是电力系统经济运行的影响因素之一, 对提高整个电力系统安全稳定经济高效有着非常重要的意义^[17-21]。本文通过分析含有不良数据的历史传统负荷序列在传统预测算法所得结果有一定偏差的特点^[22-23], 提出了针对历史负荷数据的不量数据辨识、相似度预测以及负荷偏差修正于一体的预测模型。通过利用某地 2008 年负荷数据进行试验分析, 且将几种情况下预测结果的部分统计指标进行对比发现, 该方法取得了良好的预测结果, 能够很好地为电力系统的优化决策提供依据。

参考文献

- [1] 王建军. 智能挖掘电力负荷预测研究及应用[M]. 北京: 中国水利水电出版社, 2013.
- [2] 杨茂, 董骏城, 罗芫, 等. 基于近似熵的电力系统负荷预测误差分析[J]. 电力系统保护与控制, 2016, 44(23): 24-29.
YANG Mao, DONG Juncheng, LUO Yuan, et al. Study of power system load forecasting errors based on approximate entropy[J]. Power System Protection and Control, 2016, 44(23): 24-29.
- [3] 张栋梁, 严健, 李晓波, 等. 基于马尔可夫链筛选组合预测模型的中长期负荷预测方法[J]. 电力系统保护与控制, 2016, 44(12): 63-67.
ZHANG Dongliang, YAN Jian, LI Xiaobo, et al. Mid-long term load forecasting based on Markov chain screening combination forecasting models[J]. Power System Protection and Control, 2016, 44(12): 63-67.
- [4] 马哲, 舒勤. 基于 ESPRIT 分解算法的短期电力负荷预测[J]. 电力系统保护与控制, 2015, 43(7): 90-96.
MA Zhe, SHU Qin. Short term load forecasting based on ESPRIT integrated algorithm[J]. Power System Protection and Control, 2015, 43(7): 90-96.
- [5] 孙宏斌, 陈佳, 江曦源, 等. 最小信息损失综合短期负荷预测(一)—理论[J]. 中国电机工程学报, 2016, 36(17): 4513-4521.
SUN Hongbin, CHEN Jia, JIANG Xiyuan, et al. Mini-mum information loss synthesis short term load forecasting (one) - theory[J]. Proceedings of the CSEE, 2016, 36(17): 4513-4521.
- [6] 李东东, 覃子珊, 林顺富, 等. 基于混沌时间序列法的微网短期负荷预测[J]. 电力系统及其自动化学报, 2015, 27(5): 14-18.
LI Dongdong, TAN Zishan, LIN Shunfu, et al. Short term load forecasting based on chaotic time series method[J]. Proceedings of the CSU-EPSA, 2015, 27(5): 14-18.
- [7] 张伟. 基于人体舒适度指数的配电网短期负荷预测方法[J]. 电力系统保护与控制, 2013, 41(9): 74-79.
ZHANG Wei. A distribution short-term load forecasting based on human comfort index[J]. Power System Protection and Control, 2013, 41(9): 74-79.
- [8] 李霄, 王昕, 郑益慧, 等. 基于改进最小二乘支持向量和预测误差校正的短期风电负荷预测[J]. 电力系统保护与控制, 2015, 43(11): 63-69.
LI Xiao, WANG Xin, ZHENG Yihui, et al. Short term wind load forecasting based on improved LSSVM and error forecasting correction[J]. Power System Protection and Control, 2015, 43(11): 63-69.
- [9] 张超. 基于时间序列法超短期负荷预测改进方法的研究[D]. 沈阳: 辽宁工业大学, 2015.
ZHANG Chao. Study on the improved method of super short term load forecasting based on time series method[D]. Shenyang: Liaoning University of Technology, 2015.
- [10] 王志宏. 基于时间序列的电力系统短期负荷预测研究[D]. 广州: 华南理工大学, 2012.
WAN Zhihong. Research on short term load forecasting of power system based on time series[D]. Guangzhou: South China University of Technology, 2012.
- [11] 贺辉. 电力负荷预测和负荷管理[M]. 北京: 中国电力出版社, 2012.
- [12] 刘金琨. 系统辨识理论与 Matlab 仿真[M]. 北京: 电子工业出版社, 2013.
- [13] 鲁宝春, 赵深, 田盈, 等. 优化系数的 NGM(1, 1, k)模型在中长期电量预测中的应用[J]. 电力系统保护与控制, 2015, 43(12): 98-103.
LU Baochun, ZHAO Shen, TIAN Ying, et al. Mid-long term electricity consumption forecasting based on improved NGM (1, 1, k) gray model[J]. Power System Protection and Control, 2015, 43(12): 98-103.
- [14] 祖向荣, 田敏, 白焰. 基于模糊聚类与函数小波核回归的短期负荷预测方法[J]. 电力自动化设备, 2016, 36(10): 134-140.
ZU Xiangrong, TIAN Min, BAI Yan. Short term load forecasting method based on fuzzy clustering and function wavelet kernel regression[J]. Electric Power Automation Equipment, 2016, 36(10): 134-140.
- [15] 陈伟根, 滕黎, 刘军, 等. 基于遗传优化支持向量机的变压器绕组热点温度预测模型[J]. 电工技术学报, 2014, 29(1): 44-51.

- CHEN Weigen, TENG Li, LIU Jun, et al. Transformer winding hot-spot temperature prediction model of support vector machine optimized by genetic algorithm[J]. Transactions of China Electrotechnical Society, 2014, 29(1): 44-51.
- [16] 田野. 基于动量因子的神经网络群电流负荷预测模型[J]. 电力系统保护与控制, 2016, 44(17): 31-38.
- TIAN Ye. A forecasting model for current load of neural network group based upon momentum factor[J]. Power System Protection and Control, 2016, 44(17): 31-38.
- [17] 李辉. 用马尔可夫法改进残差 GM(1,1)模型中长期负荷预测[J]. 陕西电力, 2017, 45(5): 75-77, 82.
- LI Hui. Residual error GM(1,1) model improved by Markov method of long-term and mid-term load forecasting[J]. Shaanxi Electric Power, 2017, 45(5): 75-77, 82.
- [18] 万强, 王清亮, 王睿豪, 等. 基于支持向量机的某地区电网短期电力负荷预测[J]. 电网清洁能源, 2016, 32(12): 14-20.
- WAN Qiang, WANG Qingliang, WANG Ruihao, et al. Short-term load forecasting of a regional power grid based on support vector machine[J]. Power System and Clean Energy, 2016, 32(12): 14-20.
- [19] 胡杨, 常鲜戎. 基于改进 EMD-PSVM 的短期负荷预测[J]. 陕西电力, 2016, 44(3): 29-33.
- HU Yang, CHANG Xianrong. Short term load forecasting based on improved EMD-PSVM[J]. Shaanxi Electric Power, 2016, 44(3): 29-33.
- [20] 谷云东, 张素杰, 冯君淑. 大用户电力负荷的多模型模糊综合预测[J]. 电工技术学报, 2015, 31(23): 110-115.
- GU Yundong, ZHANG Sujie, FENG Junshu. Multi model fuzzy comprehensive prediction of power load for large users[J]. Transactions of China Electrotechnical Society, 2015, 31(23): 110-115.
- [21] 王惠中, 刘轲, 周佳. 基于综合气象指数和日期类型的电力系统负荷预测[J]. 电网与清洁能源, 2015, 31(9): 67-71.
- WANG Huizhong, LIU Ke, ZHOU Jia. Power system load forecasting based on integrated weather index and date type[J]. Power System and Clean Energy, 2015, 31(9): 67-71.
- [22] HE Jinghan, LIU Lin, LI Wenli, et al. Development and research on integrated protection system based on redundant information analysis[J]. Protection and Control of Modern Power Systems, 2016, 1: 13pp.
- DOI 10.1186/s41601-016-0024-y
- [23] TAN L Z, OUYANG A J, PENG X Y, et al. A fast and stable forecasting model to forecast power load[J]. International Journal of Pattern Recognition and Artificial Intelligence, 2015, 29(3).

收稿日期: 2016-12-29; 修回日期: 2017-05-10

作者简介:

杨慧霞(1977—), 女, 硕士研究生, 高级工程师, 从事继电保护与自动化设备行业的技术标准研究工作; E-mail: 13598953605@163.com

邓迎君(1975—), 男, 硕士研究生, 高级工程师, 从事继电保护与自动化设备行业的软件测试研究工作;

刘志斌(1989—), 男, 通信作者, 硕士研究生, 主要研究方向为电力无线传感器网络的监测和数据分析、算法研究。E-mail: liuzhibin.1989@163.com

(编辑 姜新丽)