

DOI: 10.7667/PSPC160389

基于相空间重构和高斯过程回归的短期负荷预测

顾熹, 廖志伟

(华南理工大学电力学院, 广州 广东 510640)

摘要: 基于负荷时间序列的混沌特性, 提出了一种结合相空间重构(PSR)和高斯过程回归(GPR)的短期负荷预测方法。首先采用 C-C 方法确定时间序列的延迟时间和嵌入维度, 分别建立单变量和多变量的相空间重构模型。然后, 分别运用单一与组合核函数的 GP 模型对负荷样本进行训练, 根据最优超参数对 24 h 的日负荷进行预测。最后将预测结果与支持向量机模型以及多变量 GP 模型进行比较。结果显示, 多变量组合核函数 GP 模型取得了更好的预测结果, 验证了所提出的基于 PSR 和 GPR 的预测方法的可行性。

关键词: 相空间重构; 高斯过程回归; C-C 方法; 短期负荷预测; 组合核函数

Short-term load forecasting based on phase space reconstruction and Gaussian process regression

GU Xi, LIAO Zhiwei

(School of Electric Power, South China University of Technology, Guangzhou 510640, China)

Abstract: According to the chaotic features of load series, a new forecasting method combining phase space reconstruction and Gaussian process regression is proposed. Firstly, two parameters of time series (delay time and delay window) are earned at the same time by means of the C-C method. Secondly, the reconstructed series of the separate load as well as the multi-variable model considering load and other influence factors are established. Then, the load sample is trained by GPR models using both single and composite kernel function and the optimal hyper-parameters are calculated, with which the 24-hour daily loads are predicted. Finally, the forecasting consequence of the single load model is contrasted with SVM model and the multi-variable GP model. Prediction results indicate that the model using multi-variable and composite kernel function achieves better effects and the new method is not only feasible but also satisfies the requirements of the engineering precision.

Key words: phase space reconstruction; Gaussian process regression; C-C method; short-term load forecasting; composite kernel function

0 引言

电力系统短期负荷是一个受多种外在因素(如气象、社会经济、节假日等)影响的多维非线性系统。以往常见的负荷预测方法依赖其中某种或多种因素展开研究, 其分析结果具有一定的局限性, 不可能完全消除所有外在因素对负荷产生的影响。文献[1]研究指出, 短期负荷时间序列含典型的混沌特性。它并非由外部因素引起, 而是根据系统本身某种确定性规则决定的运动过程, 并且具有随机性的运动状态^[2]。因此, 根据混沌理论以及相空间重构方法, 仅从负荷时间序列中就能够提取和恢复系统本身的演化轨迹以及负荷内蕴藏的完整信息, 不需要计及

外在因素与负荷之间的关系, 避免传统方法事先建立负荷预测模型的人为主观性, 从而提高预测结果的可信度。

近些年来, 机器学习(Machine Learning, ML)被广泛应用于复杂非线性系统回归建模中。负荷预测作为典型的监督性学习, ML 方法中的神经网络算(Neural Network, NN)^[3-6]和支持向量机算法(Support Vector Machine, SVM)^[7-12]更是被大量应用于短期负荷预测研究中, 有效解决了小样本、高维度、非线性的问题。但是这些方法都存在一定的缺陷, 如: NN 普遍存在收敛速度慢, 最优结构难以确定, 过拟合以及易陷入局部最优解等问题^[13]; SVM 核函数及其参数以及惩罚项的确定依靠经验值和交叉验证

方法,对预测结果影响很大。

在基于核学习机的方法中,高斯过程(Gaussian Process, GP)同 SVM 一同成为机器学习领域的热门研究方向。GP 以概率分布表示函数的先验模型,构造协方差函数,基于贝叶斯框架进行推理计算。与 NN 和 SVM 相比,GP 的可调参数较少,可以提供预测结果的置信水平,核函数超参数可以自适应确定^[13]。

本文提出了基于相空间重构和高斯过程回归的短期负荷预测方法,首先应用 C-C 方法确定负荷样本的延迟时间和嵌入维数,对负荷样本重构相空间;然后对重构后的负荷序列建立 GP 模型,通过贝叶斯推理确定超参数;最后利用训练好的 GP 模型进行短期负荷预测。为验证本文方法的有效性,将不同核函数组成的 GP 模型的预测精度与 SVM 预测模型(ϵ -SVR, LS-SVM)以及计及温度因素的多变量 GP 模型进行比较。

1 相空间重构

1.1 相空间重构理论

最初提出相空间重构的目的在于在高维空间中恢复混沌吸引子^[14]。对于长度为 N 的时间序列 $\{x(t), t=1, 2, \dots, N\}$, 延迟坐标状态空间重构法的基本思想是将一维的时间序列拓展到高维空间中,从而挖掘出原始序列中的完整信息。根据 Takens 的延迟时间嵌入定理,利用两个重构参数(延迟时间 τ 与嵌入维度 m), 可对 $\{x(t)\}$ 进行相空间重构, 即 $\mathbf{X}(t)=[x(t), x(t+\tau), \dots, x(t+(m-1)\tau)]$, $t=1, 2, \dots, M$ (1)

式中: $\mathbf{X}(t)$ 为重构以后的相点; 重构后序列的长度为 $M=N-(m-1)\tau$ 。

1.2 多变量时间序列的相空间重构

由于实际的负荷序列长度有限,且有噪声干扰,单独的负荷时间序列的重构相空间可能无法包含系统的完整信息,不能准确描述系统本身的演化轨迹。因此可以加入温度、节假日等外在因素的时间序列,将负荷时间序列扩展为多变量时间序列。对于 M 维时间序列 $\{y(t)\}$, 时间序列长度为 N , 其中 $y(t)=[y_1(t), y_2(t), \dots, y_M(t)]$, $t=1, 2, \dots, N$ 。

于是多变量时间序列相空间重构的相点为^[15]

$$\mathbf{Y}(t)=[y_1(t), y_1(t-\tau_1), \dots, y_1(t-(m_1-1)\tau_1), y_2(t), y_2(t-\tau_2), \dots, y_2(t-(m_2-1)\tau_2), \dots$$
 (2)

$$y_M(t), y_M(t-\tau_M), \dots, y_M(t-(m_M-1)\tau_M)]$$

式中, $t=\max_{1 \leq i \leq M} (m_i-1)\tau_i+1, \dots, N$, $i=1, 2, \dots, M$, τ_i

和 m_i 分别是第 i 个时间序列的延迟时间和嵌入维数。

1.3 重构参数的选取

相空间重构的关键就是确定延迟时间 τ 和嵌入维度 m , 这两个参数决定着相空间的相似程度以及混沌吸引子的大小。

C-C 方法在统计学方法的基础上对时间延迟 τ_d 和延迟时间窗口 $\tau_w=(m-1)\tau_d$ 同时进行估计。其具有易于操作,计算量小,抗噪声且对小数据组可靠的优点^[16-17]。

对于长度为 N 时间序列 $\{x(t)\}$, 其重构相空间为 $\{\mathbf{X}_i\} (i=1, 2, \dots, M)$, $M=N-(m-1)\tau$, 其中时间延迟为 t , 重构维数为 m , 定义关联积分为

$$C(m, N, r, t) = \frac{2}{M(M-1)} \sum_{1 \leq i < j \leq M} \theta(r - d_{ij}), r > 0 \quad (3)$$

其中: d_{ij} 为向量之间的欧式距离, $d_{ij} = \|\mathbf{X}_i - \mathbf{X}_j\|$;

Heaviside 函数 $\theta(x) = \begin{cases} 0 & x < 0 \\ 1 & x \geq 0 \end{cases}$, r 为时间序列的半径。

将时间序列 $\{x(t)\}$ 划分成 t 个互不重叠的子序列, 即

$$\begin{aligned} \mathbf{x}_1 &= \{x(1), x(t+1), \dots, x(N-t+1)\} \\ \mathbf{x}_2 &= \{x(2), x(t+2), \dots, x(N-t+2)\} \\ &\dots \\ \mathbf{x}_t &= \{x(t), x(2t), \dots, x(N)\} \end{aligned} \quad (4)$$

定义子序列的检验统计量为

$$S(m, N, r, t) = \frac{1}{t} \sum_{s=1}^t \left[C_s \left(m, \frac{N}{t}, r, t \right) - C_s^m \left(1, \frac{N}{t}, r, t \right) \right] \quad (5)$$

令 $N \rightarrow \infty$, 有

$$S(m, r, t) = \frac{1}{t} \sum_{s=1}^t \left[C_s(m, r, t) - C_s^m(1, r, t) \right], m=2, 3, \dots \quad (6)$$

根据 BDS 统计结论, C-C 方法主要通过计算以下 3 个统计量的值。

$$\bar{S}(t) = \frac{1}{16} \sum_{m=2}^5 \sum_{j=1}^4 S(m, r_j, t) \quad (7)$$

$$\Delta \bar{S}(t) = \frac{1}{4} \sum_{m=2}^5 \Delta S(m, t) \quad (8)$$

$$S_{\text{cor}}(t) = \Delta \bar{S}(t) + |\bar{S}(t)| \quad (9)$$

式中, 取 $r_j = \frac{j\sigma}{2}$, σ 为时间序列的标准差, 利用式 (6) 估算 $S(m, r, t)$ 的值。

$$\Delta S(m, t) = \max \{S(m, r_j, t)\} - \min \{S(m, r_j, t)\} \quad (10)$$

计算完毕, 则最优 τ_a 取 $\Delta \bar{S}(t) \sim t$ 第一个局部极小点, 最优 τ_w 取 $S_{\text{cor}}(t) \sim t$ 的全局最小点。

2 高斯过程

2.1 高斯过程回归理论

高斯过程将有限维的高斯分布应用到无限维的泛函空间, 将 $f(\mathbf{x})$ 的取值作为随机变量, 同时将 $f(\mathbf{x})$ 的先验分布作为高斯分布。对于训练数据集 $\mathbf{D} = \{\mathbf{x}^{(n)}, y_n\}_{n=1}^N$, $\mathbf{x}^{(i)} \in \mathbf{R}^d$, $y_n \in \mathbf{R}$ 。在训练数据集 \mathbf{D} 中, $f(\mathbf{x}^{(1)}), f(\mathbf{x}^{(2)}), \dots, f(\mathbf{x}^{(N)})$ 构成随机变量的集合, 并且具有联合高斯分布, 其全部统计特征由均值函数 $m(\mathbf{x})$ 和协方差函数 $k(\mathbf{x}, \mathbf{x}')$ 组成^[18-20], 表示为

$$f(\mathbf{x}) \sim GP(m(\mathbf{x}), k(\mathbf{x}, \mathbf{x}')) \quad (11)$$

考虑一个一般的回归过程, 利用高斯过程进行建模, 假设观察目标值 y 含有噪声, 则

$$y = f(\mathbf{x}) + \varepsilon \quad (12)$$

式中, ε 服从均值为 0、方差为 σ^2 的正态分布, 且独立于 $f(\mathbf{x})$ 的噪声, 记作 $\varepsilon \sim N(0, \sigma^2)$ 。若 $f(\mathbf{x})$ 满足高斯分布, 则 y 也满足高斯分布, 其有限观测输出值的联合分布集合可以构成一个高斯过程, 即

$$f(\mathbf{x}) \sim GP(m(\mathbf{x}), k(\mathbf{x}, \mathbf{x}') + \sigma_n^2 \delta_{ij}) \quad (13)$$

式中: $m(\mathbf{x})$ 为均值函数; δ_{ij} 为狄拉克函数, 当 $i=j$ 时, $\delta_{ij} = 1$, 将协方差函数以矩阵形式表达, 即为

$$\mathbf{C}(\mathbf{X}, \mathbf{X}) = E(\mathbf{y}\mathbf{y}^T) = \mathbf{K}(\mathbf{X}, \mathbf{X}) + \sigma_n^2 \mathbf{I} \quad (14)$$

式中: $\mathbf{C}(\mathbf{X}, \mathbf{X})$ 为 N 阶的协方差矩阵; σ_n 为噪声; $\mathbf{K}(\mathbf{X}, \mathbf{X})$ 为 N 阶的核矩阵, 称为格拉姆矩阵, 矩阵中的元素为 $\mathbf{K}_{ij} = k(\mathbf{x}^{(i)}, \mathbf{x}^{(j)})$; \mathbf{I} 为 N 阶的单位矩阵。

在贝叶斯框架下, 可通过高斯过程先验过程计算出后验分布的函数预测输出。给定测试数据集 $\mathbf{D}_1 = \{\mathbf{x}^{(n)}, y_n\}_{n=N+1}^{N+N_s}$, $\mathbf{X}_* \in \mathbf{R}^{d \times N_s}$ 为测试集的输入数据矩阵, $\mathbf{f}_* \in \mathbf{R}^{N_s}$ 为相应函数输出 $f(\mathbf{x}_*)$ 构成的测试集的输出, 于是训练集的输出与测试集的输出构成了联合高斯分布, 即

$$\begin{bmatrix} \mathbf{y} \\ \mathbf{f}_* \end{bmatrix} \sim N \left(0, \begin{bmatrix} \mathbf{K}(\mathbf{X}, \mathbf{X}) + \sigma_n^2 \mathbf{I} & \mathbf{K}(\mathbf{X}, \mathbf{X}_*) \\ \mathbf{K}(\mathbf{X}_*, \mathbf{X}) & \mathbf{K}(\mathbf{X}_*, \mathbf{X}_*) \end{bmatrix} \right) \quad (15)$$

于是, GPR 模型的表达式写作:

$$\mathbf{f}_* | \mathbf{X}, \mathbf{y}, \mathbf{X}_* \sim N(m_*, \text{cov}(\mathbf{f}_*)) \quad (16)$$

$$m_* = E(\mathbf{f}_* | \mathbf{X}, \mathbf{y}, \mathbf{X}_*) = \mathbf{K}(\mathbf{X}, \mathbf{X}_*) (\mathbf{K}(\mathbf{X}, \mathbf{X}) + \sigma_n^2 \mathbf{I})^{-1} \mathbf{y} \quad (17)$$

$$\text{cov}(\mathbf{f}_*) = \mathbf{K}(\mathbf{X}_*, \mathbf{X}_*) -$$

$$\mathbf{K}(\mathbf{X}_*, \mathbf{X}) (\mathbf{K}(\mathbf{X}, \mathbf{X}) + \sigma_n^2 \mathbf{I})^{-1} \mathbf{K}(\mathbf{X}, \mathbf{X}_*) \quad (18)$$

式中, m_* 即为 GP 模型给出的预测期望值, 协方差输出向量给出了该预测的置信水平, 这是相对于其他机器学习算法(如 SVM)的显著优点。

2.2 核函数的选择及超参数的自适应

注意到, GP 过程模型的性质完全由给定的协方差核函数 $k(\mathbf{x}^i, \mathbf{x}^j)$ 决定, 核函数的选择对 GP 模型的建立至关重要。根据 RKHS 性质, 核函数都必须是半正定函数。本文选取以下 3 种协方差函数^[21]。

1) 平方指数协方差函数(SE)

$$k_{\text{SE}} = \sigma_f^2 \exp\left(-\frac{1}{2} r_d^2\right) \quad (19)$$

2) 有理二次协方差函数(RQ)

$$k_{\text{RQ}} = \sigma_f^2 \left[1 + \frac{1}{2\alpha} r_d^2\right]^{-\alpha} \quad (20)$$

3) Matern 协方差函数

$$k_M = \sigma_f^2 \left[1 + \sqrt{3} r_d \exp(-\sqrt{3} r_d)\right] \quad (21)$$

式中: $r_d = \sqrt{(\mathbf{x}^i - \mathbf{x}^j)^T \Lambda^{-2} (\mathbf{x}^i - \mathbf{x}^j)}$, $\Lambda = \text{diag}(\boldsymbol{\lambda})$, $\boldsymbol{\lambda}$ 是关联性测度超参数向量, $\boldsymbol{\lambda} \in \mathbf{R}^d$, 对输入具有自动相关确定特性(ARD), 当 $\boldsymbol{\lambda}$ 各项取值相同时, 式(19)为高斯径向基(RBF)核函数; σ_f^2 为信号方差, 表征函数的局部相关性; α 为形状参数, 用于控制协方差的衰减率。

GP 对训练数据集的训练过程即为超参数的学习过程, 基于证据最大化的贝叶斯框架, 超参数可通过高斯模型的对数似然函数极大化得到, 即

$$\ln p(\mathbf{y} | \mathbf{X}, \boldsymbol{\theta}) = -\frac{1}{2} \mathbf{y}^T \mathbf{C}^{-1} \mathbf{y} - \frac{1}{2} \ln |\mathbf{C}| - \frac{N}{2} \ln 2\pi \quad (22)$$

对超参数向量初始化, 使用共轭梯度优化方法求解式(22), 搜索最优超参数, 需要对式(22)求取对超参数矢量 $\boldsymbol{\theta}$ 的偏导数, 即

$$\frac{\partial}{\partial \theta_i} \ln p(\mathbf{y} | \mathbf{X}, \boldsymbol{\theta}) = -\frac{1}{2} \mathbf{y}^T \mathbf{C}^{-1} \frac{\partial \mathbf{C}}{\partial \theta_i} \mathbf{C}^{-1} \mathbf{y} - \frac{1}{2} \text{tr} \left(\mathbf{C}^{-1} \frac{\partial \mathbf{C}}{\partial \theta_i} \right) \quad (23)$$

式中: tr 表示矩阵的迹; 在对数空间中构建超参数向量, 可取为 $\boldsymbol{\theta} = [\ln \lambda_1, \dots, \ln \lambda_d, \ln \sigma_f^2, \ln \alpha]$ 。

3 算例分析

3.1 样本设计

本文选取某地区电网 1 月 1 日—2 月 19 日 50 天, 每个小时一个负荷点, 共计 1200 个点作为单变量负荷序列的训练集, 将 2 月 20 日至 2 月 26 日一周的日负荷作为测试集, 如图 1 所示。

在重构相空间之前, 需要对样本负荷数据进行预处理, 修正异常数据并且对数据作归一化处理。

应用 C-C 方法对样本数据进行参数估计, 绘制 $\Delta\bar{S}(t) \sim t$ 和 $S_{\text{cor}}(t) \sim t$ 的曲线, 如图 2 所示。

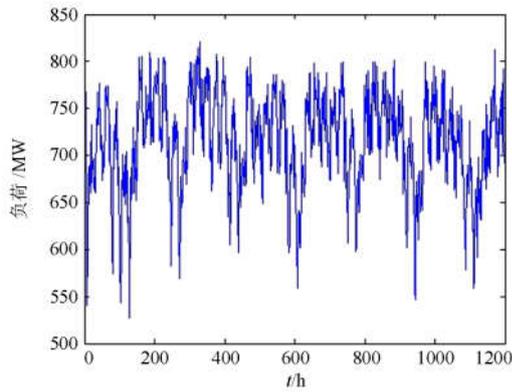


图 1 原始负荷序列

Fig. 1 Sample load time series

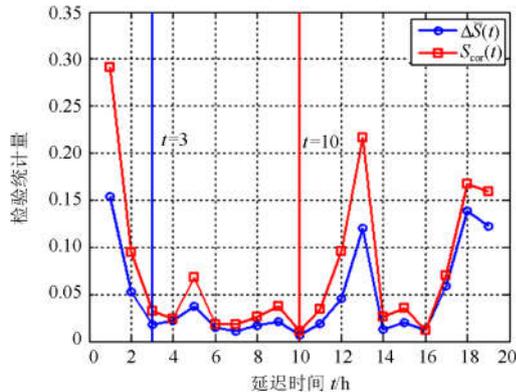


图 2 C-C 方法计算时间延迟和嵌入维度

Fig. 2 Delay time and embedding dimension calculated by C-C method

根据图 2 可以判断: 最优时间延迟取 $\Delta\bar{S}(t) \sim t$ 曲线的首个局部极小值点, 即 $\tau_d=3$ h; 最优窗口时间延迟取 $S_{\text{cor}}(t) \sim t$ 曲线的全局最小值, 即 $\tau_w=10$ h。由此可以确定延迟时间 $\tau=3$ h, 嵌入维度 $m=5$ 。然后对样本总数为 $N=1224$ 的历史负荷时间序列重构

相空间, 构成 $M = N - (m-1)\tau = 1212$ 个相点, 其中取前 1187 个相点作为训练集, 后 24 个相点作为测试集, 用于验证预测结果的准确性。

本文采用局域法对重构后的时间序列作单步预测, 在相空间中计算各点到中心点 $Y(M)$ 的欧式距离, 找出距离 $Y(M)$ 最邻近的 k 个相点作为参考向量集 $\hat{Y}(M) = \{Y_{M_1}, Y_{M_2}, \dots, Y_{M_k}\}$, 每一步预测前均需重新选择参考集, 则训练集的输入输出可表示为

$$x_{M_{i+1}} = f(Y_{M_i}) = f(x_{M_i}, x_{M_{i-1}}, \dots, x_{M_{i-(m-1)\tau}) \quad (24)$$

式中, $i=1, 2, \dots, k$ 。

高斯过程的核函数考虑采用式(19)~式(21)的三种单一核函数及其两两组合构成的组合核函数。

3.2 评价指标

为了衡量本文提出的高斯过程回归模型的预测精度, 本文采用平均相对误差 E_{mape} 和最大相对误差 E_{mre} 两个指标对结果进行评价。

$$E_{\text{mape}} = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_*(i) - y(i)}{y(i)} \right| \times 100\% \quad (25)$$

$$E_{\text{mre}} = \max \left(\left| \frac{y_*(i) - y(i)}{y(i)} \right| \right) \quad (26)$$

式中: N 为测试样本数; $y_*(i)$ 为测试样本预测值; $y(i)$ 为测试样本的真实值。

3.3 单变量模型预测结果分析

本文分别采用 6 种核函数对单负荷变量 GP 模型 2 月 20 日 24 小时的日负荷进行预测, 超参数初始值从均值为 0, 标准差为 1 的正态分布中随机选取。同时应用 ε -SVR 和 LS-SVM 模型对样本数据进行训练, 采用 RBF 核函数, 并且应用粒子群算法对核参数 σ^2 和惩罚因子 C 进行寻优。6 种核函数模型以及两种 SVM 模型的 24 小时的仿真误差结果见表 1。

从表 1 的结果可以得到, 组合核函数的预测精度要优于单一核函数的 GP 模型, 测试结果的 E_{mape} 均小于 2%, E_{mre} 也不超过 5%。其中 SE+RQ 的平均相对误差仅为 1.71%, 最大相对误差为 3.28%, 取得了较为精确的结果。结果表明, 单一核函数模型对于复杂非线性系统的各维度输入特性难以充分地表述。同时除了单一 Matern 核函数模型, 其他 5 种核函数 GP 模型均要优于 ε -SVR 和 LS-SVM 的预测结果。SE+RQ 组合核函数最终计算得到的最优超参数取值如表 2 所示。

表 1 单变量模型预测结果分析
Table 1 Error analysis of single variable model

误差	GP						SVM	
	k_{SE}	k_{RQ}	k_M	$k_{SE+k_{RQ}}$	k_{SE+k_M}	k_{RQ+k_M}	ϵ -SVR	LS-SVM
$E_{\text{mapc}}(\%)$	1.92	2.06	2.25	1.71	1.83	1.77	2.41	2.10
$E_{\text{mre}}(\%)$	4.54	4.80	5.11	3.28	4.12	3.86	5.66	4.88

表 2 SE+RQ 组合核函数的最优超参数
Table 2 Optimal hyper-parameters obtained by combinatorial kernel function (SE+RQ)

核函数	λ_1	λ_2	λ_3	λ_4	λ_5	σ_r	α
$k_{SE+k_{RQ}}$	k_{SE}	0.2595	1.9204	0.1234	0.1209	0.1485	0.0511
	k_{RQ}	4.4801	1.1928	2.0844	1.9348	1.2935	0.4831

3.4 多变量模型预测模型及结果分析

由于实际的负荷序列长度有限, 且存在噪声, 单独的负荷时间序列的重构相空间可能无法包含系统的完整信息, 不能准确描述系统本身的演化轨迹。本文将温度时间序列加入到样本负荷数据中, 将单一负荷时间序列扩展为双变量时间序列 $\{y(t)\}$, $y(t)=(y_{1,t}, y_{2,t})$, $t=1,2,3,\dots,N$ 。其中, N 为序列长度, $y_{1,t}$ 为负荷序列, $y_{2,t}$ 为温度序列。已求得负荷样本序列的延迟时间和嵌入维数分别为 $\tau_1=3$ 和 $m_1=5$ 。同样采用 C-C 方法判断, 温度样本时间序列的重构参数分别为 $\tau_2=2$ 和 $m_2=4$ 。

因此, 多变量模型重构后的相点可表示为

$$Y(t)=[y_1(t), y_1(t-\tau_1), \dots, y_1(t-(m_1-1)\tau_1), y_2(t), y_2(t-\tau_2), \dots, y_2(t-(m_2-1)\tau_2)] \quad (27)$$

式中, $t = \max_{1 \leq i \leq 2} (m_i - 1)\tau_i + 1, \dots, N$, 系统嵌入维数 $m=m_1+m_2=9$ 。

对重构后的时间序列作单步预测, 核函数选取效果最好的 SE+RQ 的组合核函数, 多变量时间序列相点的欧式距离计算表达式为

$$d = \|Y_p - Y_q\| = \sqrt{\sum_{i=1}^2 \sum_{j=1}^{m_i} (y_i(p - (j-1)\tau_i) - y_i(q - (j-1)\tau_i))^2} \quad (28)$$

采用多变量 GP 模型的预测结果如表 3 所示, 并与单变量模型的结果比较, 其 E_{mapc} 为 1.69%, 而 E_{mre} 则是 3.14%, 略优于单变量模型的预测精度, 可以说明多变量模型可以弥补单变量模型信息不完整的缺陷。为了进一步验证本方法的有效性, 采用上述多变量模型对 2 月 20 日至 2 月 26 日一周的负荷进行预测。其中 22 日和 23 日为双休日, 从图中可以看到负荷有明显的下降。一周 168 个点的预测结果如图 3 所示。一周七天的日平均相对误差分别为 1.72%, 1.73%, 2.21%, 2.10%, 1.82%, 1.98%,

2.04%, 一周最大误差为 5.29%, 基本满足精度要求, 且对于节假日这类特殊情况的拟合程度也较高, 88% 的点的相对误差控制在 3% 以内, 证明了本文方法的有效性。

表 3 2 月 20 日 24 点负荷预测结果

Table 3 Prediction results of 24th load in February 20th

单变量模		多变量模		单变量模		多变量模	
时间	型误差	型误差	时间	型误差	型误差	时间	型误差
	(%)	(%)		(%)	(%)		(%)
00:00	-1.01	-0.47	12:00	-0.42	-0.94		
01:00	3.28	1.84	13:00	-0.98	-0.19		
02:00	1.48	0.89	14:00	1.13	-1.23		
03:00	-1.99	-1.41	15:00	1.32	2.00		
04:00	2.19	2.93	16:00	2.95	3.14		
05:00	-2.16	-2.58	17:00	-2.93	2.79		
06:00	-1.10	-0.27	18:00	-1.99	-1.34		
07:00	-1.33	-0.39	19:00	1.25	1.95		
08:00	1.19	0.64	20:00	2.07	2.95		
09:00	-1.31	-2.12	21:00	1.21	1.43		
10:00	-1.63	-2.28	22:00	1.86	2.46		
11:00	1.13	1.93	23:00	3.06	2.15		

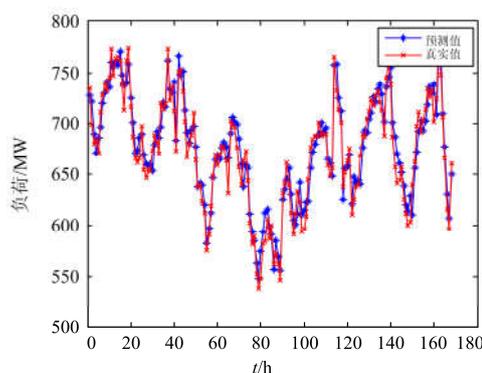


图 3 2 月 20~26 日的预测结果

Fig. 3 Prediction results from February 20th to 26th

由于实际的温度时间序列或者是节假日时间序列大多是一天一个点地记录, 因此, 多变量模型更适合应用于日最高负荷的预测工作。

4 结论

1) 基于负荷序列的混沌特性, 应用重构相空间理论, 还原非线性系统本身的演化轨迹与负荷中蕴含的完整信息, 不需要计及气象、经济等外在因素, 简化了数据需求, 节省了预测成本。

2) 高斯过程回归模型具有可调参数少, 超参数自适应, 易实现, 能够给出预测结果置信水平的优点。研究表明, 采用组合核函数的 GP 模型预测和泛化能力要高于单一核函数模型。与基于 RBF 的 ϵ -SVR 和 LS-SVM 模型相比, 组合核函数的 GP 模型的预测精度更高。

3) 由于长度有限和存在噪声的原因, 单一负荷序列相空间重构无法还原系统的完整信息。本文构造的双变量混沌序列模型, 预测结果平均相对误差仅为 1.71%, 优于单变量模型, 完全满足工程需求。

4) GPR 使用共轭梯度法求取最优超参数计算量较大且依赖于初值, 容易陷入局部最优; 预测模型仅局限于高斯白噪声的假设情况, 无法适用于观察值在几个数量级之间变化的情况。因此, 如何配合其他智能优化算法搜索超参数, 减小计算量并实现全局最优以及如何突破高斯噪声假设的局限性, 是需要进一步研究的内容。

参考文献

[1] O'NEILL-CARRILO E, HEYDT G T, KOSTELICH E J. Chaotic phenomena in power system: detection and application[J]. *Electric Machines and Power Systems*, 1999, 27(1): 79-91.

[2] ABARBANEL H D. Analysis of observed chaotic data[M]. New York: Springer-Verlag, 1996: 10-21.

[3] 何耀耀, 许启发, 杨善林, 等. 基于 RBF 神经网络分位数回归的电力负荷概率密度预测方法[J]. *中国电机工程学报*, 2013, 33(1): 93-98.
HE Yaoyao, XU Qifa, YANG Shanlin, et al. A power load probability density forecasting method based on RBF neural network quantile regression[J]. *Proceedings of the CSEE*, 2013, 33(1): 93-98.

[4] 葛少云, 贾鸥莎, 刘洪. 基于遗传灰色神经网络模型的实时电价条件下短期电力负荷预测[J]. *电网技术*, 2012, 36(1): 224-229.
GE Shaoyun, JIA Ousha, LIU Hong. A gray neural network model improved by genetic algorithm for short-

term load forecasting in price-sensitive environment[J]. *Power System Technology*, 2012, 36(1): 224-229.

[5] 杨胡萍, 王承飞, 朱开成, 等. 基于相空间重构和 Chebyshev 正交基神经网络的短期负荷预测[J]. *电力系统保护与控制*, 2012, 40(24): 95-99.
YANG Huping, WANG Chengfei, ZHU Kaicheng, et al. Short-term load forecasting based on phase space reconstruction and Chebyshev orthogonal basis neural network[J]. *Power System Protection and Control*, 2012, 40(24): 95-99.

[6] 李龙, 魏靖, 黎灿兵, 等. 基于人工神经网络的负荷模型预测[J]. *电工技术学报*, 2015, 30(8): 225-230.
LI Long, WEI Jing, LI Canbing, et al. Prediction of load model based on artificial neural network[J]. *Transactions of China Electrotechnical Society*, 2015, 30(8): 225-230.

[7] 王宁, 谢敏, 邓佳梁, 等. 基于支持向量机回归组合模型的中长期降温负荷预测[J]. *电力系统保护与控制*, 2016, 44(3): 92-97.
WANG Ning, XIE Min, DENG Jialiang, et al. Mid-long term temperature-lowering load forecasting based on combination of support vector machine and multiple regression[J]. *Power System Protection and Control*, 2016, 44(3): 92-97.

[8] 陈超, 黄国勇, 范玉刚, 等. 基于离散 Fréchet 距离和 LS-SVM 的短期负荷预测[J]. *电力系统保护与控制*, 2014, 42(5): 142-147.
CHEN Chao, HUANG Guoyong, FAN Yugang, et al. Short-term load forecasting based on discrete Fréchet distance and LS-SVM[J]. *Power System Protection and Control*, 2014, 42(5): 142-147.

[9] 李霄, 王昕, 郑益慧, 等. 基于改进最小二乘支持向量机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.

[10] 王新, 孟玲玲. 基于 EEMD-LSSVM 的超短期负荷预测[J]. *电力系统保护与控制*, 2015, 43(1): 61-66.
WANG Xin, MENG Lingling. Ultra-short-term load forecasting based on EEMD-LSSVM[J]. *Power System Protection and Control*, 2015, 43(1): 61-66.

[11] 王东, 史晓霞, 尹交英. 不同核函数的支持向量机用于空调负荷预测的对比研究[J]. *电工技术学报*, 2015, 30(增刊 1): 531-535.
WANG Dong, SHI Xiaoxia, YIN Jiaoying. Prediction on

- hourly load of air conditioning by RBF support vector machine[J]. Transactions of China Electrotechnical Society, 2015, 30(S1): 531-535.
- [12] 刘念, 张清鑫, 刘海涛. 基于核函数极限学习机的微电网短期负荷预测方法[J]. 电工技术学报, 2015, 30(8): 218-224.
- LIU Nian, ZHANG Qingxin, LIU Haitao. Online short-term load forecasting based on ELM with kernel algorithm in micro-grid environment[J]. Transactions of China Electrotechnical Society, 2015, 30(8): 218-224.
- [13] 孙斌, 姚海涛, 刘婷. 基于高斯过程回归的短期风速预测[J]. 中国电机工程学报, 2012, 32(29): 104-109.
- SUN Bin, YAO Haitao, LIU Ting. Short-term wind forecasting based on Gaussian process regression model[J]. Proceedings of the CSEE, 2012, 32(29): 104-109.
- [14] 吕金虎, 陆军安, 陈士华. 混沌时间序列分析及应用[M]. 武汉: 武汉大学出版社, 2002: 57-80.
- [15] 雷绍兰, 孙才新, 周淦, 等. 电力短期负荷的多变量时间序列线性回归预测方法研究[J]. 中国电机工程学报, 2006, 26(2): 25-29.
- LEI Shaolan, SUN Caixin, ZHOU Quan, et al. The research of local linear model of short-term electrical load on multivariate time series[J]. Proceedings of the CSEE, 2006, 26(2): 25-29.
- [16] 陆振波, 蔡志明, 姜可宇. 基于改进的C-C方法的相空间重构参数选择[J]. 系统仿真学报, 2007, 19(11): 2527-2529.
- LU Zhenbo, CAI Zhiming, JIANG Keyu. Determination of embedding parameters for phase space reconstruction based on improved C-C method[M]. Journal of System Simulation, 2007, 19(11): 2527-2529.
- [17] KIM H S, EYKHOLT R, SALAS J D. Nonlinear dynamics, delay times and embedding windows[J]. Physica D (S0167-2789), 1999, 127: 48-60.
- [18] 李军, 张友鹏. 基于高斯过程的混沌时间序列单步与多步预测[J]. 物理学报, 2011, 60(7): 143-152.
- LI Jun, ZHANG Youpeng. Single-step and multiple-step prediction of chaotic time series using Gaussian process model[J]. Acta Physica Sinica, 2011, 60(7): 143-152.
- [19] RASMUSSEN C E, WILLIAMS C K I. Gaussian processes for machine learning[M]. Massachusetts: the MIT Press, 2006: 7-31.
- [20] SEEGER M. Gaussian process for machine learning[J]. International Journal of Neural System, 2004, 14(2): 69-106.
- [21] 徐冲, 刘保国, 刘开云, 等. 基于组合核函数的高斯过程边坡角智能设计[J]. 岩土力学, 2010, 31(3): 821-826.
- XU Chong, LIU Baoguo, LIU Kaiyun, et al. Slope angle intelligent design based on Gaussian process with combinatorial kernel function[J]. Rock and Soil Mechanics, 2010, 31(3): 821-826.

收稿日期: 2016-03-22; 修回日期: 2016-05-16

作者简介:

顾 焱(1990-), 男, 硕士研究生, 主要研究方向为电力系统优化与控制; E-mail: guxi661250@gmail.com

廖志伟(1973-), 男, 通信作者, 副教授, 主要研究方向为电力系统故障诊断、分析以及电力系统智能控制。E-mail: epliao@scut.edu.cn

(编辑 魏小丽)