

文章编号:2095-6134(2015)05-0588-06

利用灰色关联极限学习机预报日长变化^{*}

雷雨^{1,2,3†}, 蔡宏兵^{1,2}, 赵丹宁^{1,3}

(1 中国科学院国家授时中心, 西安 710600; 2 中国科学院时间频率基准重点实验室, 西安 710600; 3 中国科学院大学, 北京 100049)
(2014 年 11 月 4 日收稿; 2015 年 3 月 12 日收修改稿)

Lei Y, Cai H B, Zhao D N. Prediction of length-of-day variation using grey relational analysis and extreme learning machine[J]. Journal of University of Chinese Academy of Sciences, 2015,32(5):588-593,604.

摘 要 针对日长变化难以用精确模型进行预报的问题,将一种新型人工神经网络——极限学习机(extreme learning machine, ELM)用于日长变化预报中. 首先针对时间序列预测问题中存在的嵌入维数选取和网络结构设计问题,提出一种基于灰色关联分析(grey relational analysis, GRA)的 ELM 算法(GRA-ELM),该算法将灰色关联分析输入节点选取嵌入到 ELM 网络的训练过程中,同时完成嵌入维数和隐层节点规模的确定. 然后根据日长变化数据的特点对其进行预处理,建立一种能够高精度、近实时预报日长变化的 GRA-ELM 预报模型. 最后将 GRA-ELM 模型的预报结果同标准 ELM、反向传播神经网络、广义回归神经网络和地球定向参数预报比较竞赛的结果进行比较. 结果表明,通过本方法得到的日长变化较其他方法在精度上有较大改善.

关键词 日长变化; 预报; 灰色关联分析; 极限学习机; 神经网络

中图分类号:P227. 1 **文献标志码:**A **doi:**10. 7523/j. issn. 2095-6134. 2015. 05. 003

Prediction of length-of-day variation using grey relational analysis and extreme learning machine

LEI Yu^{1,2,3}, CAI Hongbing^{1,2}, ZHAO Danning^{1,3}

(1 National Time Service Center, Chinese Academy of Sciences, Xi'an 710600, China; 2 Key Laboratory of Time and Frequency Primary Standards, Chinese Academy of Sciences, Xi'an 710600, China; 3 University of Chinese Academy of Sciences, Beijing 100049, China)

Abstract Due to the time-varying characteristics of length-of-day (LOD), it is difficult to model LOD variations with a deterministic model. We employ a new type of artificial neural networks (ANN) — extreme learning machine (ELM) to predict LOD variations. In order to solve the problems of embedding dimension selection and network topology design, a training algorithm for ELM based on grey relational analysis (GRA) is first proposed. It optimizes the input and hidden layers simultaneously. Secondly, the values of LOD variation are preprocessed and a GRA-ELM model is then set up to accurately forecast LOD variation in near real-time. Finally, the prediction results are analyzed and compared with those obtained by the back propagation neural networks,

^{*} 中国科学院西部之光联合学者项目(201491)资助

[†] 通信作者, E-mail: leiyu@ntsc. ac. cn

generalization regression neural networks and Earth orientation parameters prediction comparison campaign. The results show that the prediction accuracy of our method is equal to or even better than those of the other prediction methods. The developed method is easy to use.

Key words length-of-day (LOD) variations; prediction; grey relational analysis (GRA); extreme learning machine (ELM); neural networks (NN)

地球自转参数 (Earth rotation parameters, ERP)用以描述地球自转运动,包括极移和日长 (length-of-day, LOD)变化. ERP 是实现地球参考系与天球参考系相互转换的必需参数,在现代空间导航、深空探测以及天文地球动力学研究等领域都有重要应用. 现代空间测地技术如 GNSS、SLR 与 VLBI 等是获取 ERP 的主要手段,但复杂的数据处理过程使得 ERP 的获取存在一定的时间延迟,所以对 EPR 进行高精度预报是一项非常重要的工作^[1].

当前预报 LOD 变化的方法有多种,这些方法可以分为线性模型和非线性模型两类. 线性模型包括最小二乘 (least squares, LS) 外推、自回归 (autoregressive, AR) 模型^[2]、自协方差 (autocovariance, AC)模型^[3]和卡尔曼滤波^[4]等,非线性模型有神经网络 (neural networks, NN)^[5-7]和模糊推理系统^[8]等. 由于 LOD 变化呈现复杂的非线性、非平稳变化特征,难以用确定性的模型描述其变化规律,因此从理论上讲利用非线性模型对其进行预报更为合适^[6-7]. 相关研究表明,用神经网络技术进行 LOD 预报是可行的,且预测效果比较理想^[5-7],然而,传统的前馈神经网络如反向传播神经网络 (back propagation neural networks, BPNN)采用梯度训练算法,导致网络收敛速度慢、易陷入局部极小,另外,还存在网络结构难以确定和泛化能力不强等不足^[6-8].

极限学习机 (extreme learning machine, ELM)是由 Huang 等^[9-10]提出的一种全新的单隐含层前馈神经网络,其网络结构为 1 个输入层、1 个隐含层和 1 个输出层,其中隐含层含有大量的非线性神经元. ELM 在训练初始阶段随机产生偏置与输入权值,并在训练过程中恒定不变,唯一需要求解的参数为网络输出权值,避免了传统前馈神经网络的不足,具有结构简单、学习速度快和泛化能力好等优点,目前在时间序列预测等领域得到了广泛的应用^[11].

Huang 等^[9-10]的研究表明,ELM 的逼近精度

和泛化能力与隐含层节点 (神经元)的数量密切相关,故在设计 ELM 网络时,如何选取最优的网络结构是研究重点. 除网络结构外,当利用 ELM 网络实现时间序列预测时,时间序列嵌入维数也是影响 ELM 网络性能的一个关键因素. 由于 ELM 网络的建立方式与传统时序分析模型存在本质差异,故时间序列嵌入维数不能凭借传统优化准则选定,人为凭借工程经验设定嵌入维数的方式缺乏合理性,也不具推广性.

本文针对 LOD 变化难以用具体表达式描述的特点,利用 ELM 计算速度快、学习精度高和泛化能力强的优点,将其用于 LOD 变化预测中,并针对时间序列预测问题中存在的嵌入维数选取和网络结构设计问题,将灰色关联分析 (grey relational analysis, GRA) 嵌入维数选取嵌入到 ELM 算法中,提出一种基于灰色关联分析的 ELM 训练算法,即在网络训练过程中,同时实现嵌入维数与隐层节点规模的确定,得到学习和泛化性能更好的灰色关联极限学习机 (GRA-ELM) 模型.

1 LOD 变化预报模型的构建

1.1 ELM 原理

给定 N 个训练样本 $(\mathbf{x}_i, \mathbf{y}_i)$, 其中输入向量 $\mathbf{x}_i = [x_{i1}, x_{i2}, \dots, x_{im}]^T \in \mathbb{R}^m$, 输出向量 $\mathbf{y}_i = [y_{i1}, y_{i2}, \dots, y_{in}]^T \in \mathbb{R}^n$, 则具有 h 个隐层节点的单隐层前馈神经网络可以以零误差逼近这 N 个采样点,即使得下式成立:

$$\mathbf{y}_i = \sum_{j=1}^h \beta_j g(\mathbf{w}_j \cdot \mathbf{x}_i + b_j), \quad i = 1, 2, \dots, N$$

式中, $\mathbf{w}_j = [w_{j1}, w_{j2}, \dots, w_{jm}]^T$ 为连接第 j 个隐层节点与输入节点的权值; $\beta_j = [\beta_{j1}, \beta_{j2}, \dots, \beta_{jn}]^T$ 为连接第 j 个隐层节点与输出节点的权值; b_j 为第 j 个隐层节点的偏置; $g(x)$ 为激活函数. 上式可以写成矩阵相乘的形式:

$$\mathbf{Y} = \mathbf{H}\mathbf{\beta}$$
$$\mathbf{H}(\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_h, b_1, b_2, \dots, b_h, \mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N)$$

$$= \begin{bmatrix} g(\mathbf{w}_1 \cdot \mathbf{x}_1 + b_1) \cdots g(\mathbf{w}_h \cdot \mathbf{x}_1 + b_h) \\ \vdots \\ g(\mathbf{w}_1 \cdot \mathbf{x}_N + b_1) \cdots g(\mathbf{w}_h \cdot \mathbf{x}_N + b_h) \end{bmatrix}_{N \times h}$$
$$\boldsymbol{\beta} = \begin{bmatrix} \boldsymbol{\beta}_1^T \\ \boldsymbol{\beta}_2^T \\ \vdots \\ \boldsymbol{\beta}_h^T \end{bmatrix}_{h \times n}, \mathbf{Y} = \begin{bmatrix} \mathbf{y}_1^T \\ \mathbf{y}_2^T \\ \vdots \\ \mathbf{y}_N^T \end{bmatrix}_{N \times n}$$

其中 \mathbf{H} 为隐层输出矩阵。

ELM 训练步骤如下:①随机给定输入层权值 \mathbf{w}_j 和偏置 $b_j, j = 1, 2, \cdots, h$; ②计算隐层输出矩阵 \mathbf{H} ; ③计算输出层权值 $\boldsymbol{\beta} = \mathbf{H}^+ \mathbf{Y}$, 其中 \mathbf{H}^+ 为矩阵 \mathbf{H} 的 Moore-Penrose 广义逆。

1.2 GRA-ELM 模型的建立

1) 数据预处理. 首先根据国际地球自转与参考系服务组织 (International Earth Rotation and Reference Service, IERS) 协议给出的经验模型移除 LOD 变化序列中周期为 5 d ~ 18.6 a 的固体潮项^[12], 然后采用下述线性模型确定 LOD 变化的半年项、周年项以及长期趋势项:

$$f_{\text{LODR}}(t) = a_0 + a_1 t + \sum_{i=1}^2 [c_{i,1} \cos(\omega_i t) + c_{i,2} \sin(\omega_i t)],$$

式中, LODR 表示移除固体潮项后的 LOD 变化序列; ω_1 和 ω_2 分别表示周年项和半年项的角频率, 本文取 $\omega_1 = 2\pi/365.24$ 、 $\omega_2 = 2\pi/182.62$; a 、 b 、 $c_{i,1}$ 和 $c_{i,2}$ 为未知参数, 可以通过最小二乘拟合获得。

经过上述数据处理后的剩余项代表 LOD 变化的残差序列, 该残差序列包含各种非线性成分, 包括海洋半日、周日潮项和不规律的短周期振荡成分, 本文采用 ELM 网络对剩余残差序列进行建模和预报, 然后将线性模型的预测值和 ELM 模型的预测值叠加便可获得 LODR 的预测值, 再恢复固体潮项即可得到 LOD 变化预测值。

2) 基于 GRA 的 ELM 训练算法过程. 2 个变量之间的相关程度可以用灰色关联度来衡量, 但传统的灰色关联度模型随分辨系数取值的不同, 会得到不同的关联度. 所以这里引入一种新型灰色关联度模型^[13]来计算关联度, 该模型消除了分辨系数取值对关联度计算的影响, 可以如实地反映 2 个变量的相关程度, 该模型可以表示为

$$\sigma(t) = x(t)/y(t), \bar{\sigma} = \frac{1}{L} \sum_{t=1}^L \sigma(t),$$

$$l(t) = \frac{1}{1 + |\sigma(t) - \bar{\sigma}|}, r = \frac{1}{L} \sum_{t=1}^L l(t),$$

关联度越大, 代表变量之间的相关程度越高, 即变量 x 包含关于变量 y 的信息量越大. 所以可将 GRA 嵌入维数选取与 ELM 网络融合, 在网络的学习过程中确定输入节点与隐层节点的规模. 设 LOD 变化的残差序列为 $\{\xi(t), t = 1, 2, \cdots, L\}$, 按照下述方式构造训练样本:

$$\{\xi(t-m), \xi(t-m+1), \cdots, \xi(t-1)\} \rightarrow \{\xi(t)\}, t = m+1, m+2, \cdots, L,$$

其中 m 称为输入维数或嵌入维数, 则基于 GRA 的 ELM 算法的具体步骤为

①划分样本集. 将原始训练样本划分为训练集和测试集。

②初始化 ELM. 设置激活函数类型、随机给定输入层权值和偏置以及初始化隐层节点规模。

③选取备选输入变量. 设置较大的嵌入维数 m , 然后计算每一维输入变量与输出变量之间的关联度 $r_i, i = 1, 2, \cdots, m$, 选择满足 $r_i > \alpha$ 的输入变量, 按照关联度从小到大对其进行排序, 并组成备选变量集合 F , 其中 α 为预先设定的常数, 一般取 $\alpha = 0.85$ 。

④选取输入节点. 选择备选变量集合 F 中的最后一个变量作为输入节点, 并将该变量从 F 中删掉, 构成新的备选变量集合 F 。

⑤训练 ELM 网络。

⑥判断是否满足训练终止准则. 以测试集上的测试均方根误差 (root mean squares error, RMSE) 作为统计量, 若测试 RMSE 小于预先设定的阈值, 则终止训练, 此时网络即为最优网络, 否则转至步骤⑦。

⑦计算变量贡献度. 计算当前新增变量的贡献度, 贡献度由变量增加前后网络测试 RMSE 的变化量来衡量. 如果 RMSE 的变化量小于阈值 η , 则认为新增变量在网络中是无意义的, 停止增加变量, 转至步骤⑧, 否则应当继续增加变量, 转至步骤④, 本文取 $\eta = 0.01 \text{ ms}$ 。

⑧增加隐层节点. 因为算法采用增长模式逐步添加隐层节点, 故初始节点个数一般可以取较小的值. 算法每次增加隐层节点时, 可以以固定步长增加若干节点. 隐层节点增加之后转至步骤⑤。

3) 基于 GRA-ELM 模型的残差项预报过程. 设网络最终确定的输入向量为 $\{\xi(t-M), \xi(t-$

$M + 1), \cdots, \xi(t - 1)\}, t = M + 1, M + 2, \cdots, L$, 其中 M 为算法最终确定的嵌入维数, $M \leq m$. 在预报阶段,令输入向量为 $\{\xi(L - M + 1), \xi(L - M + 2), \cdots, \xi(L)\}$, 则网络输出值为对应输入向量一步后的下一状态点,即一步预测值 $\hat{\xi}(L + 1)$, 然后令 $\xi(L + 1) = \hat{\xi}(L + 1)$, 获得新时间序列 $\{\xi(L - M + 2), \xi(L - M + 3), \cdots, \xi(L + 1)\}$ 作为下一时刻网络的输入向量,依次类推,即可实现残差项的多步预测.

2 模型验证与比较

2.1 精度评定标准

本文采用的精度评定标准有平均绝对误差 (mean absolute error, MAE) 和 RMSE,其计算公式分别为

$$MAE_i = \frac{1}{n} \sum_{j=1}^n |P_j^i - O_j^i|,$$

$$RMSE_i = \sqrt{\frac{1}{n} \sum_{j=1}^n (P_j^i - O_j^i)^2},$$

式中, O_j 和 P_j 分别表示 j 点的观测值和预测值; i 为预测跨度; n 为预测期数.

2.2 与 ELM、BPNN 以及 GRNN 模型的比较

实验中使用的 LOD 变化数据来源于 IERS 公布的采样间隔为 1 d 的 EOP05 C04 序列. 首先将 1990-01-01 至 1999-12-31 的 LOD 变化残差序列作为训练样本对 GRA-ELM 模型进行训练,然后用 GRA-ELM 模型对 2000—2001 年的残差序列进行 1 ~ 360 d 跨度的预报,并同常规 ELM、BPNN^[5]、广义回归神经网络 (general regression neural network, GRNN)^[6] 和改进 BPNN^[6] 的预报结果进行比较,预测时段和精度评定标准与文献 [5-6] 中的一样,对比结果见表 1,精度评定标准均为 RMSE,其中 ELM 模型的嵌入维数和隐含层节点分别设定为 5 和 100, GRA-ELM 和 ELM 模型均选取 Sigmoid 函数作为激活函数,其表达式为

$$g(x) = 1/(1 + e^{-x}).$$

从表 1 可以看出,ELM 用于 LOD 变化预报效果是比较理想的,与其他几种方法类似,其预测精度随着预测跨度增大而降低. 为使对比结果更加直观,图 1 绘出各种模型不同跨度的预测 RMSE. 结合表 1 和图 1 可发现,对于 1 ~ 10 d 的超短期

表 1 不同模型预报均方根误差统计表

Table 1 Statistics of the prediction RMSE among different models ms

预报跨度/d	GRA-ELM	ELM	BPNN	改进 BPNN	GRNN
1	0.027	0.027	0.019	0.027	0.037
2	0.057	0.058	0.049	0.073	0.074
3	0.078	0.079	0.074	0.093	0.097
4	0.096	0.097	0.097	0.110	0.117
5	0.110	0.112	0.121	0.131	0.134
6	0.121	0.125	0.142	0.148	0.151
7	0.131	0.137	0.159	0.162	0.164
8	0.142	0.150	0.174	0.170	0.174
9	0.151	0.160	0.184	0.176	0.179
10	0.157	0.169	0.193	0.185	0.187
15	0.178	0.200	0.246	0.221	0.204
20	0.192	0.220	0.251	0.217	0.210
25	0.198	0.232	0.249	0.215	0.211
30	0.201	0.240	0.245	0.219	0.217
60	0.222	0.266	0.292	0.219	0.222
90	0.242	0.281	0.306	0.231	0.226
120	0.238	0.265	0.314	0.229	0.226
150	0.212	0.234	0.330	0.237	0.233
180	0.217	0.246	0.361	0.234	0.234
210	0.229	0.265	0.397	0.241	0.236
240	0.232	0.267	0.377	0.236	0.236
270	0.228	0.264	0.386	0.231	0.240
300	0.227	0.266	0.402	0.249	0.247
330	0.224	0.273	0.372	0.262	0.254
360	0.232	0.279	0.347	0.245	0.250

预报, GRA-ELM 和 ELM 模型的预报精度大体相当,且高于其他几种神经网络模型;从第 10 天开始, GRA-ELM 模型的预测精度和预测稳定性均优于 ELM 模型,这说明通过 GRA 能有效改善在 LOD 变化预报过程中 ELM 模型参数选定对预测结果的影响,可以获得外推能力更好的 ELM 模型. 同时对于 1 ~ 360 d 的长期预测, GRA-ELM 模型的预测精度也要高于其他神经网络模型. 另外,在建模过程中发现, GRA-ELM 和 ELM 两种模型的计算复杂度远低于其他几种模型,以预报 1 d 的 LOD 变化值为例,采用 BPNN 和 GRNN 算法进行预测分别消耗 10 h 和 1 h 左右的时间^[6],而应用 GRA-ELM 和 ELM 方法则分别只耗时 10 min 和 4 min 左右,大大提高了预测效率,这对于 ERP 的实时快速预报有着非常重要的实际意义.





图 1 不同模型预报均方根误差对比图

Fig. 1 Comparison of the prediction RMSEs by using different models

2.3 与 EOP PCC 结果的比较

为了客观地衡量各种方法的 ERP 预报性能, 维也纳理工大学大地测量与地球物理研究所从 2005-10-01 至 2008-02-28 开展了全球性的地球定向参数预测比较竞赛 (Earth orientation parameters prediction comparison campaign, EOP PCC)^[14], 该竞赛明确定义了预测时段、参考序列以及精度评定标准, 可以较为客观地衡量模型的预测效果. 因此, 为进一步探讨 GRA-ELM 模型的预报性能, 选取 1990-01-01 至 2005-09-30 的 LOD 变化序列作为建模数据, 预报 2005-10-01 至 2008-02-28 间 1~500 d 跨度的 LOD 变化值, 计算预测结果的 MAE, 并同 EOP PCC 的结果进行比较, 比较结果绘于图 2.

参与 EOP PCC 的研究小组名单详见文献 [14], 其中预报精度较高的几个研究小组是 Gross R 小组 (卡尔曼滤波联合大气角动量方法)、Kalarus M 小组 (LS + AR 模型) 和 Kosek W 小组 (小波和 AC 模型的组合). 从图 2 中可以发现, 对于 1~10 d 的超短期预报, GRA-ELM 模型的预测精度仅次于排在第一位的 Gross R 小组和排在第二位的 Kalarus M 小组的精度; 对于 1~30 d 的短期预报, GRA-ELM 模型的预测效果稍逊于排在第一位的 Gross R 小组的效果, 优于排在第二位的 Kalarus M 小组; 对于 1~500 d 的长期预报, GRA-ELM 模型的预测精度则高于其他小组的预测精度.



(a) 超短期(1~10 d)

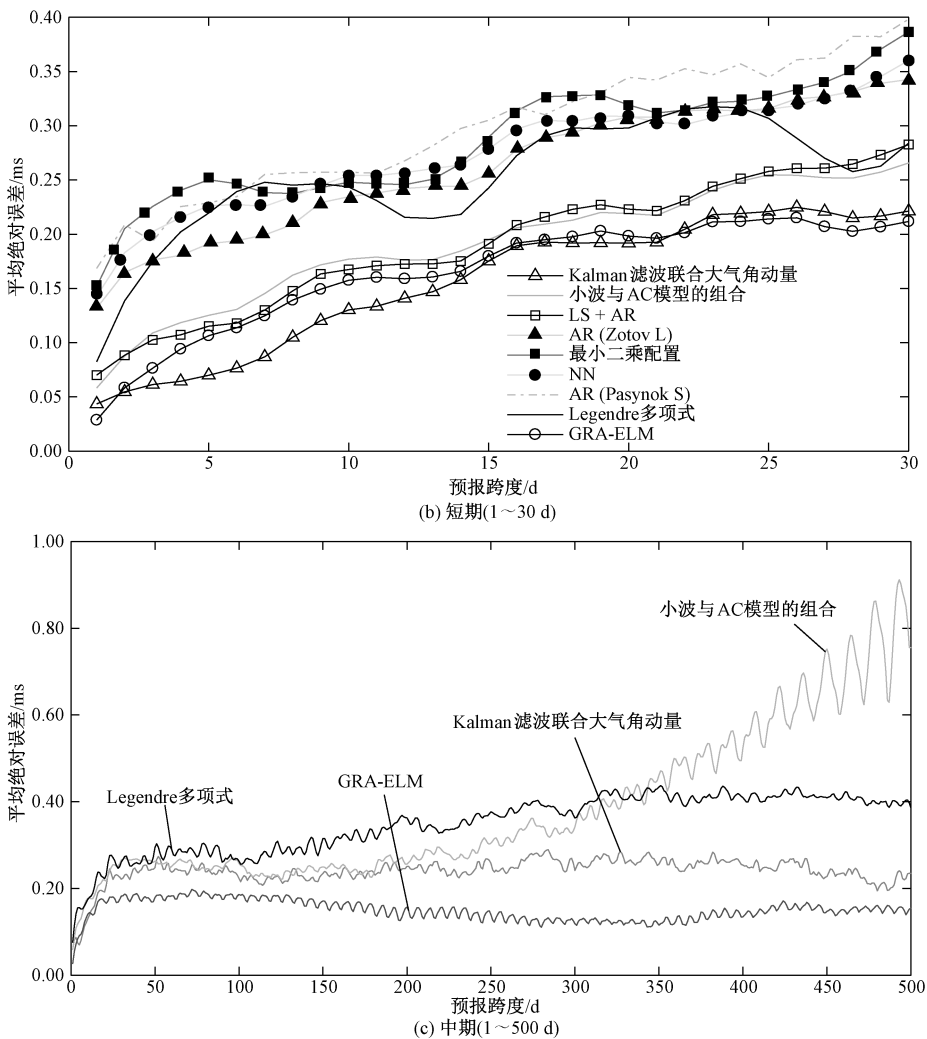


图 2 GRA-ELM 和 EOP PCC 预报 MAE 结果对比图
Fig. 2 Comparison of MAE between GRA-ELM and EOP PCC prediction

3 结论

本文提出一种基于灰色关联分析的 ELM 训练算法,该算法将灰色关联分析嵌入维数选取嵌入到 ELM 网络的训练学习过程之中,以网络的学习性能作为衡量输入变量与输出变量相关程度的指标,并以增量模式确定隐层节点规模,同时完成了嵌入维数和隐层节点规模的优化选取.所提算法不必对嵌入维数和隐层节点数进行专门的主观选择,从而可以避免预报的人为主观性,提高网络的普适性、预报精度以及可信度.与标准 ELM 算法相比,所提算法具有更好的泛化能力和预报稳定性.

通过与 BPNN、GRNN 和 EOP PCC 的比较实验,验证了所提算法能够以较高的精度和相对稳定的性能来预报 LOD 变化值,同时所提算法简单

易用且实时性较高.因此,可以考虑作为一种新型的 LOD 变化预报方法使用.

本文在对 LOD 变化进行预报时是仅仅利用 LOD 变化的历史数据建立模型进行预报的,而未考虑大气和海洋对 LOD 变化的激发作用.综合考虑大气和海洋激发源对 LOD 变化进行联合预报,是我们下一步的研究重点.

参考文献

[1] Gambis D, Luzum B. Earth rotation monitoring, UT1 determination and prediction [J]. Metrologia, 2011, 48 (4): 165-170.
[2] Tomasz N, Kosek W. Prediction of UT1-UTC, LOD and AAM χ_3 by combination of least-squares and multivariate stochastic methods [J]. Journal of Geodesy, 2008, 82 (2): 83-92.




Fig. S3 Top and side views of $\text{Pd}_4\text{O}_x@ \text{CeO}_2(111)$, and $\text{Pd}_4\text{O}_x@ \text{CeO}_2(100)$

(上接第 593 页)

[3] Kosek W, McCarthy D D, Luzum B J. Possible improvement of Earth orientation forecast using autocovariance prediction procedures [J]. Journal of Geodesy, 1998, 72 (4) : 189-199.

[4] Gross R S, Eubanks T M, Steppe J A, et al. A Kalman filter-based approach to combining independent Earth-orientation series [J]. Journal of Geodesy, 1998, 72(4) : 215-235.

[5] Schuh H, Ulrich M, Egger D, et al. Prediction of Earth orientation parameters by artificial neural networks [J]. Journal of Geodesy, 2002, 76(5) : 247-258.

[6] 张晓红, 王琪洁, 朱建军, 等. 广义回归神经网络在日长变化预报中的应用 [J]. 天文学报, 2011, 52 (4) : 322-331.

[7] Wang Q J, Du Y N, Liu J. Introducing atmospheric angular momentum into prediction of length of day change by generalized regression neural network model [J]. Journal of Central South University, 2014, 21 : 1 396-1 401.

[8] Akyilmaz O, Kutterer H. Prediction of Earth rotation parameters by fuzzy inference systems [J]. Journal of Geodesy, 2004, 78(1/2) : 82-93.

[9] Huang G B, Zhu Q Y, Siew C K. Extreme learning machine: theory and applications [J]. Neurocomputing, 2006, 70(1-3) : 489-501.

[10] Huang G B, Zhu H M, Ding X J, et al. Extreme learning machine for regression and multiclass classification [J]. Iee Transactions on Systems, Man, and Cybernetics-Part B: Cybernetics, 2012, 42(2) : 513-529.

[11] Sun Z L, Choi T M. Sales forecasting using extreme learning machine with applications in fashion retailing [J]. Decision Support Systems, 2008, 46(1) : 411-419.

[12] Gerard P, Brain L. IERS Conventions (2010) [S]. Germany: Verlag des Bundesamts für Kartographie und Geodasie, 2011 : 123-131.

[13] 崔杰. 一种新的灰色相似关联度及其应用 [J]. 统计与决策, 2008, 20 : 14-16.

[14] Kalarus M, Schuh H, Kosek W, et al. Achievements of the Earth orientation parameters prediction comparison campaign [J]. Journal of Geodesy, 2010, 84(10) : 587-596.