

基于SVD-SOA-GRU-LSTM算法的天然气负荷预测

陈 勇, 黄玉桥

浙江理工大学建筑工程学院, 浙江 杭州

收稿日期: 2023年8月30日; 录用日期: 2023年10月12日; 发布日期: 2023年10月24日

摘 要

本文提出一种由海鸥优化算法(SOA)优化门控循环单元(GRU)并结合奇异值分解(SVD)和长短期记忆神经网络(LSTM)的天然气负荷预测算法。采用SOA对GRU的模型参数进行优化, 得到最佳值, 利用SVD对原始数据进行降维和特征提取以提高数据质量, 最后使用LSTM进行残差预测, 结合GRU的预测结果作为最终预测结果, 进一步提高了模型的预测精度, 使用均方根误差(RMSE)和平均绝对百分比误差(MAPE)作为评价标准, 模型的预测结果分别为4766和5.61%。

关键词

天然气负荷, 海鸥优化算法, 门控循环单元, 奇异值分解, 长短期记忆神经网络

Natural Gas Load Forecasting Based on SVD-SOA-GRU-LSTM Algorithm

Yong Chen, Yuqiao Huang

School of Architecture and Engineering, Zhejiang Sci-Tech University, Hangzhou Zhejiang

Received: Aug. 30th, 2023; accepted: Oct. 12th, 2023; published: Oct. 24th, 2023

Abstract

This paper proposes a natural gas load forecasting algorithm that combines the Seagull Optimization Algorithm (SOA) to optimize the Gated Recurrent Unit (GRU), and incorporates Singular Value Decomposition (SVD) and Long Short-Term Memory (LSTM). The SOA is used to optimize the model parameters of GRU and obtain the optimal values. SVD is employed to reduce dimensionality and extract features from the original data, enhancing data quality. Finally, LSTM is utilized for residual prediction, combining the prediction results of GRU as the final forecast. This approach

further improves the prediction accuracy of the model. The evaluation criteria are Root Mean Square Error (RMSE) and Mean Absolute Percentage Error (MAPE). The model achieves an RMSE of 4766 and a MAPE of 5.61% in the prediction results.

Keywords

Natural Gas Load, Seagull Optimization Algorithm, Gated Recurrent Unit, Singular Value Decomposition, Long Short Term Memory Neural Network

Copyright © 2023 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

天然气与传统的煤炭和石油相比具有较低的碳排放和污染物释放而被广泛使用中[1]。当前天然气供需矛盾逐步加剧, 天然气市场的稳定发展面临巨大挑战。部分地区用气高月出现供气短缺现象, 商业、工业乃至居民用户面临天然气减供甚至停气问题, 同时提高了天然气管道的修建、维护管理难度。另一方面, 天然气是不可再生能源, 需要精心管理和有效开发。因此, 准确预测天然气负荷成为了一种必要的方式[2]。

在天然气负荷预测研究中, 预测效果一般受到数据质量、地理位置、气候条件、预测范围、预测方法、市场细分和预测来源等等多种因素的影响[3]。在预测方法方面, 有关天然气负荷预测模型的种类较多, 主要可分为统计模型, 机器学习模型, 时间序列模型等及上述方法的组合模型等[4] [5]。GRU 是一种循环神经网络架构, 在处理较短时间序列数据时有较好的表现被广泛应用于负荷预测[6] [7] [8]。LSTM 能够捕捉和利用较远时间步之间的依赖关系, 因此在处理需要长期记忆的任务上表现优秀[9] [10]。SOA [11]作为一种新兴的优化算法, 在全局搜索能力、收敛速度、适应性和鲁棒性等方面都具有一定的优势[12]。在提高数据质量上 SVD 作为一种重要的数学工具, 具有数据降维、去噪能力、特征提取等优点, 对于处理高维数据和提取关键信息非常有效[13]。综上, 本文提出一种基于 SVD-SOA-GRU-LSTM 的预测模型。

2. 模型建立

2.1. SVD

SVD [14] (奇异值分解)是将一个矩阵分解为三个部分的数学技术, 可以通过提取数据的主要特征和结构来降低数据的维度, 并减少数据中的噪声和冗余信息。同时可以将数据表示为较小的奇异值和相关向量的组合, 因此它可以用较少的存储空间表示原始数据, 实现数据的压缩和存储效率的提。第三, 在面对数据中的噪声、缺失值或异常值时具有较好的稳定性。即使数据存在一些扰动或非线性关系, SVD 仍然可以提供较为可靠的数据分解结果。在特征提取方面, SVD 可以从数据中提取出重要的特征信息。通过选择最大的奇异值和相应的奇异向量, 可以捕捉到数据中的主要模式和结构, 有助于理解数据的本质和提取有用的特征。

对于一个 $m \times n$ 的实数矩阵 A , 它的奇异值分解可以表示为以下公式:

$$A = U \Sigma V^T \quad (1)$$

其中 A 是一个 m 行 n 列的元素均为实数的矩阵, U 是一个 m 行 m 列的行向量和列向量两两垂直的矩阵, 它的列向量被称为左奇异向量, 这些向量对应于 A 矩阵的行空间, Σ 是一个 m 行 n 列的除主对角线歪其余元素均是 0 的矩阵, 它的对角线上的每一个元素都被称为 A 的奇异值, 记为 $\sigma_i (i=1, \dots, r)$ 。它们是非负实数且按照从大到小的顺序排列。奇异值表示了 A 在每个特征空间方向上的重要性或能量分布。 V 是一个 n 行 n 列的行向量和列向量两两垂直的矩阵, 它的列向量被称为右奇异向量, 这些向量对应于 A 矩阵的列空间。

由公式(1)分别左乘和右乘 A^T 可得公式(2) (3)如下:

$$A^T A = V \Sigma^T U^T U \Sigma V^T = V \Sigma^2 V^T \quad (2)$$

$$A A^T = U \Sigma V^T V \Sigma U^T = U \Sigma^2 U^T \quad (3)$$

由公式(2) (3)可以看出, $A^T A$ 和 $A A^T$ 的特征向量分别组成了 V 和 U 的列向量, 而特征值则对应于 Σ 乘以其转置矩阵的对角线上的元素, 这个关系提供了一种计算 $A A^T$ 特征向量和特征值的方法。

2.2. SOA

在 2019 年, Gaurav Dhiman 等人通过观察海鸥的迁徙与捕食行为提出了一种新的算法以寻求最优解, 命名为 SOA。SOA 利用模拟海鸥觅食行为的策略, 在搜索空间中进行全局搜索, 能够避免陷入局部最优解, 并寻找到更好的全局最优解, 采用并行计算的方式, 可以同时搜索多个候选解, 提高了搜索的效率。同时, SOA 还使用了启发式规则来指导搜索过程, 进一步加速了算法的收敛速度。SOA 的运行过程和参数设置相对简单, 易于理解和解释。它通过模拟海鸥觅食的行为来进行优化搜索, 使得搜索过程更加直观可见, 同时对问题的初始解的依赖较小, 对初始解的质量和范围要求相对较低, 具有较好的鲁棒性。这使得 SOA 在处理复杂问题和实际应用中更加可靠。算法基本步骤如下:

- 1) 初始化参数
- 2) 初始化种群位置
- 3) 计算适应度值并保存全局最优位置
- 4) 迁徙、全局搜索, 需要计算不与相邻海鸥碰撞的新位置 $C_s(t)$, 最佳位置方向 $M_s(t)$ 和新位置 $D_s(t)$ 。

$$C_s(t) = A \times P_s(t) \quad (4)$$

$$A = f_c - t \times \frac{f_c}{\max_{\text{iteration}}} \quad (5)$$

$$M_s(t) = B \times (P_{\text{best}}(t) - P_s(t)) \quad (6)$$

$$B = 2 \times A^2 \times r \quad (7)$$

$$D_s(t) = |C_s(t) + M_s(t)| \quad (8)$$

其中 A 是指代海鸥在模拟搜索空间中的运动动作, f_c 是用来控制变量 A 变化频率的函数, 从 2 线性递减到最小值 0, $\max_{\text{iteration}}$ 是指代最大迭代次数的符号, $P_{\text{best}}(t)$ 是指海鸥当前的最佳位置, $P_s(t)$ 是指海鸥当前的位置, B 为平衡全局与局部搜索能力的随机数; r 为 [0, 1] 内的随机数。

- 5) 海鸥攻击猎物, 在局部的搜索, 模拟在空中进行螺旋运动, 代入到数学公式中为:

$$x = r \cos \theta \quad (9)$$

$$y = r \sin \theta \quad (10)$$

$$z = r\theta \quad (11)$$

$$r = u \times e^{\theta v} \quad (12)$$

其中, r 是指螺旋运动的半径, 这个值会逐渐减小, θ 是一个在 $[0, 2\pi]$ 内的随机变化的角度值; u 、 v 是两个确定螺旋运动形状的参数。海鸥攻击猎物后的新位置 $P_S(t)$

$$P_S(t) = D_S(t) \times x \times y \times z + P_{best}(t) \quad (13)$$

6) 判断计算值是否达到了终止条件, 若未达到条件则返回步骤 3。

流程图如图 1 所示。

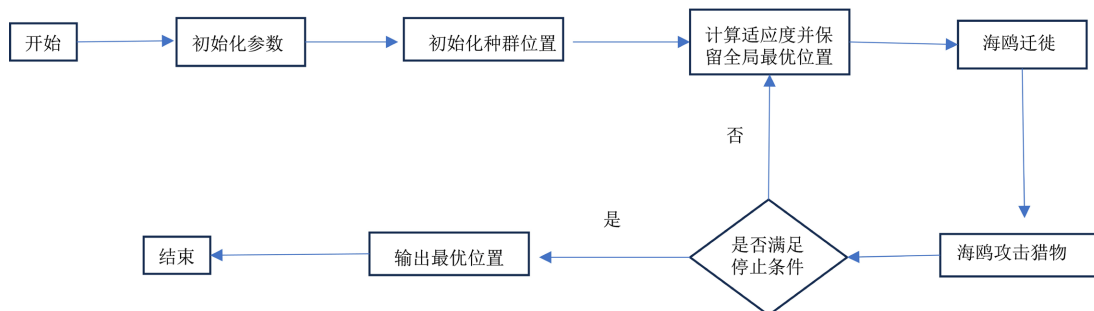


Figure 1. Process diagram of SOA

图 1. SOA 流程示意图

2.3. GRU

GRU 网络是对传统神经网络进行了优化改进, 与传统神经网络相比, GRU 引入了重置门和更新门结构[15], 通过使用更新门和重置门来控制内存单元的更新, 从而有效地调整信息的流动。这使得 GRU 能够更好地处理长期依赖关系, 并避免梯度消失或爆炸等问题。通过更新门和重置门, GRU 可以选择性地更新和遗忘过去的信息, 从而更好地捕捉和存储重要的时间序列模式。同时, 相比与 LSTM 模型拥有 3 个门控, GRU 模型仅仅使用了 2 个门控(更新门和重置门), 这导致 GRU 在训练和推断时需要更少的计算资源, 同时允许用户根据具体任务和数据的特点进行不同的变体和调整。通过调整门控机制的权重和阈值, 可以对 GRU 模型进行灵活的改进和优化。它的数学模型见公式 14~17。

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t]) \quad (14)$$

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t]) \quad (15)$$

$$\tilde{h}_t = \tanh(W \cdot [r_t \odot h_{t-1}, x_t]) \quad (16)$$

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t \quad (17)$$

其中, r_t 是指代重置门函数, h_{t-1} 是指上一个时间步的隐藏状态, x_t 是当前时间步的输入, 将 h_{t-1} 和 x_t 进行堆叠得到一个新的向量, W_r 是重置门的权重矩阵, σ 是 Sigmoid 函数, 它们构成了重置门。重置门决定了过去隐藏状态 h_{t-1} 对当前时间步的影响程度。 z_t 是指更新门函数, W_z 是更新门的权重矩阵, 过去隐藏状态 h_{t-1} 和当前输入 x_t 对当前时间步有一定的影响, 而 z_t 就是确定其影响的指标; \tilde{h}_t 是候选隐藏状态, \odot 表示逐元素乘法, W 是候选隐藏状态的权重矩阵; h_t 更新后的隐藏状态, 与 h_{t-1} 和 \tilde{h}_t 的关系如公式 17 是所示, 在这之中更新门 z_t 是确定两者之间的权重的重要指标。GRU 模型单元示意图如图 2。

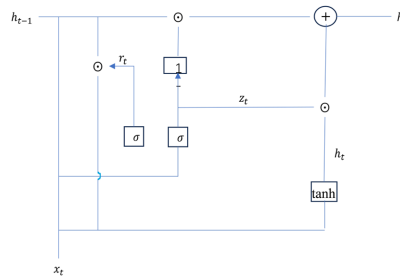


Figure 2. GRU model cell
图 2. GRU 模型单元

2.4. LSTM

LSTM 是 Hochreiter [16]在 1997 年提出的一种神经网络。LSTM 通过使用门控机制，特别是遗忘门和输入门，可以有效地解决传统循环神经网络(RNN)中由于梯度消失或爆炸引起的长期依赖问题。这使得 LSTM 能够更好地捕捉和处理时间序列中的长期依赖关系，因此可以更好地建模残差序列中的时间相关性。这对于预测残差中的复杂模式和趋势非常有益。也可以根据不同的时间尺度自动适应序列数据的长期和短期依赖关系。这使得 LSTM 在处理各种时间序列数据，如语音、文本、音乐等方面具有较好的表现。通过细胞状态(cell state)的维护和调整，LSTM 可以有选择性地记住和遗忘信息，从而更好地捕捉序列数据中的重要模式。

其数学模型公式如下：

$$f_t = \sigma(W_f X_t + U_f h_{t-1} + b_f) \tag{18}$$

$$i_t = \sigma(W_i X_t + U_i h_{t-1} + b_i) \tag{19}$$

$$\tilde{C}_t = \tanh(W_c X_t + U_c h_{t-1} + b_c) \tag{20}$$

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t \tag{21}$$

$$o_t = \sigma(W_o X_t + U_o h_{t-1} + b_o) \tag{22}$$

$$h_t = \tanh(C_t) \odot o_t \tag{23}$$

其中， f_t 为遗忘门， i_t 为输入门， W 和 U 为矩阵，用来确定输入向量和隐藏状态的权重， X_t 是一个向量，用来确定当前时刻的输入值，而符号 h_{t-1} 是指上一个时刻的隐藏状态，符号 b 是指代一个偏置向量， σ 表示为sigmoid函数， \tanh 则是代表着双曲正切函数， C_t 是用来表示当前时刻的细胞状态， \odot 是逐元素相乘， o_t 是输出门的输出， h_t 表示隐藏层的状态。其结构示意图如图3。

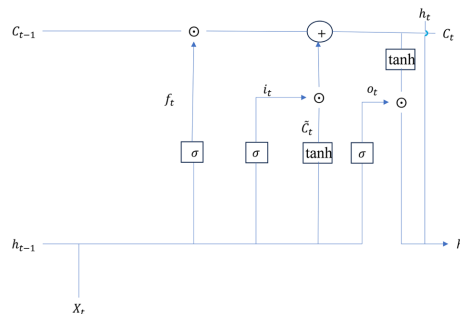


Figure 3. LSTM model cell
图 3. LSTM 模型单元

2.5. 评价标准及整体流程

在预测结果评估方面, 本文采用均方根误差和平均绝对百分比误差来表示模型的预测精度, 其计算公式如下所示:

$$\text{RMSE} = \sqrt{\frac{\sum_{t=1}^n (\tilde{y}_t - y_t)^2}{n}} \quad (24)$$

$$\text{MAPE} = \frac{\sum_{t=1}^n \left| \frac{\tilde{y}_t - y_t}{y_t} \right|}{n} \times 100\% \quad (25)$$

流程图如图 4, 各个部分具体流程见上文:

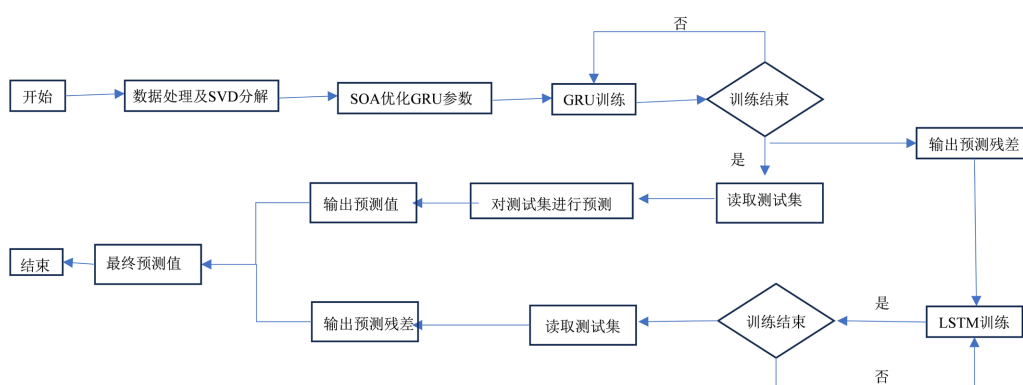


Figure 4. Predictive process diagram

图 4. 预测流程图

3. 实例分析

3.1. 数据处理

为验证模型的有效性, 本文采集了丽水市某县的 2020 年 1 月 1 日至 2023 年 6 月 30 日的天然气负荷数据及对应日的各项天气参数如最高、最低温度、相对湿度、干湿球温度等。考虑到工业用气占比超过 80%, 额外加入对应日前 3 天的负荷数据作为输入参数。对与所有的输入参数, 本文使用斯皮尔曼秩次相关性分析法[17]确定其与天然气负荷的相关性, 进行取舍后使用 Matlab 软件中自带的工具包的 mapminmax 函数对原始数据进行归一化处理, 并将数据分为训练集和测试集, 两者比例为 7:3。具体相关性如表 1。

Table 1. Correlation coefficients of each parameter

表 1. 各参数相关系数

输入参数	秩相关系数
最高温度	-0.216463732
最低温度	0.152897958
空气质量指数	0.113332097
干球温度	-0.089734497
露点温度	0.051215616
湿球温度	-0.275471776
相对湿度	-0.023415666

Continued

平均风速	0.060704405
前一天天然气用量	0.858498275
前两天天然气用量	0.762720876
前三天天然气用量	0.683449317

确定输入参数后利用 SVD 对数据进行降维和特征提取, 具体结果如图 5, 图 6。




Figure 5. Singular value line plot
图 5. 奇异值折线图





Figure 6. Residuals for different k values
图 6. 不同 k 值的残差

由图 5 可得当 $k=4$ 之后不再涵盖原矩阵更多特征, 图 6 表达了不同 k 值时重构矩阵与原矩阵的误差, 可以看到, 当 $k=4$ 时误差最小, 因此本文选定 $k=4$ 。


3.2. 模型预测

在 Matlab 上对原始数据分别用 GRU、SVD-GRU、SVD-SOA-GRU 和 SVD-SOA-GRU-LSTM 这 4 个模型进行预测, 其结果如图 7 所示, RMSE 和 MAPE 如表 2 所示。由图表可得, 4 个模型预测结果都整体负荷原始数据规律, 其中 GRU 模型因没有对原始数据进行降维、降噪和特征提取等, 总体误差最大, MAPE 为 15.23%。对比各模型同样可以看出, SOA 优化预测模型的参数及加入 LSTM 对残差的分解预测可以在一定程度上提高预测精度, 对各模型的 MAPE 分别整体提高 1.68%和 3.28%。最后, SVD-SOA-GRU-LSTM


模型的精度最高, MAPE 为 5.61%, 不仅在整体上更接近原始数据, 在波峰波谷时误差也较小, 跳出了“局部最优”, 证明其平稳性和准确性, 为用户的天然气供应提供保障, 为天然气资源的优化调度以及天然气管网的设计提供有效参考信息。




a) 各模型预测结果对比图



b) 前 50 天预测结果对比图



c) 100 到 150 天预测结果对比图



d) 250 到 300 天预测结果对比图

Figure 7. Predicted results of each model

图 7. 各模型预测结果

Table 2. Errors of each model

表 2. 各模型误差

模型	GRU	SVD-GRU	SVD-SOA-GRU	SVD-SOA-GRU-LSTM
RMSE	14665	12358	8985	4766
MAPE	15.23%	13.55%	10.27%	5.61%

4. 结论

本文就提高预测数据质量和改进预测方法 2 个方向对天然气负荷预测进行了优化改进。实例分析证明, 通过 SVD 对数据进行降维和特征提取能有效提高 GRU 的预测精度。SOA 寻优对于 GRU 模型参数的优化、LSTM 对残差的预测也提高了预测模型的精度。基于上述研究提出的 SVD-SOA-GRU-LSTM 模型最终预测结果于实际的天然气负荷更为接近且效果稳定, 为用户用气供应及天然气资源调度提供更佳精确的依据。

参考文献

- [1] 王震, 孔盈皓, 李伟. “碳中和”背景下中国天然气产业发展综述[J]. 天然气工业, 2021, 41(8): 194-202.
- [2] 刘定智, 张元涛, 梁严, 等. 基于“全国一张网”的天然气管输优化模型构建及应用[J]. 油气与新能源, 2021, 33(4): 64-70.
- [3] Ahmad, T., Chen, H.X., Zhang, D.D. and Zhang, H.C. (2020) Smart Energy Forecasting Strategy with Four Machine Learning Models for Climate Sensitive and Non-Climate Sensitive Conditions. *Energy*, **198**, Article 117283. <https://doi.org/10.1016/j.energy.2020.117283>
- [4] Liu, C., Wu, W.Z., Xie, W.L., Zhang, T. and Zhang, J. (2021) Forecasting Natural Gas Consumption of China by Using a Novel Fractional Grey Model with Time Power Term. *Energy Reports*, **7**, 788-797. <https://doi.org/10.1016/j.egyr.2021.01.082>
- [5] Wei, N., Yin, L.H., Li, C., Li, C.J., Chan, C. and Zeng, F.H. (2021) Forecasting the Daily Natural Gas Consumption with an Accurate White-Box Model. *Energy*, **232**, Article 121036. <https://doi.org/10.1016/j.energy.2021.121036>
- [6] 门嘉铖, 樊玉光, 高琳, 等. EMD-Attention-GRU 天然气管网流量组合预测模型[J/OL]. 油气储运: 1-12. <http://kns.cnki.net/kcms/detail/13.1093.TE.20230815.1638.002.html>, 2023-08-26.
- [7] 张应辉. 基于 Attention-GRU 模型的城市燃气用气负荷预测[J]. 油气储运, 2022, 41(11): 1349-1354.
- [8] Xue, G., Song, J., Kong, X., et al. (2019) Prediction of Natural Gas Consumption for City-Level DHS Based on Atten-

- tion GRU: A Case Study for a Northern Chinese City. *IEEE Access*, **7**, 130685-130699. <https://doi.org/10.1109/ACCESS.2019.2940210>
- [9] 那幸仪, 贾俊铖, 赵晓筠, 等. 基于小波变换和 LSTM 模型的城市天然气负荷预测[J]. 计算机应用与软件, 2021, 38(12): 61-66.
- [10] Laib, O., Khadir, M.T. and Mihaylova, L. (2019) Toward Efficient Energy Systems Based on Natural Gas Consumption Prediction with LSTM Recurrent Neural Networks. *Energy*, **177**, 530-542. <https://doi.org/10.1016/j.energy.2019.04.075>
- [11] Dhiman, G. and Kumar, V. (2019) Seagull Optimization Algorithm: Theory and Its Applications for Large-Scale Industrial Engineering Problems. *Knowledge-Based Systems*, **165**, 169-196. <https://doi.org/10.1016/j.knosys.2018.11.024>
- [12] 赵伟, 陈培红, 曹阳. 基于 ACSOA-BP 神经网络的瓦斯含量预测模型[J]. 煤矿安全, 2022, 53(1): 174-180. <https://doi.org/10.13347/j.cnki.mkaq.2022.01.028>
- [13] Biglieri, E. and Yao, K. (1989) Some Properties of Singular Value Decomposition and Their Applications to Digital Signal Processing. *Signal Processing*, **18**, 277-289. [https://doi.org/10.1016/0165-1684\(89\)90039-X](https://doi.org/10.1016/0165-1684(89)90039-X)
- [14] Tang, T. and Yuan, H.M. (2021) The Capacity Prediction of Li-Ion Batteries Based on a New Feature Extraction Technique and an Improved Extreme Learning Machine Algorithm. *Journal of Power Sources*, **514**, Article 230572. <https://doi.org/10.1016/j.jpowsour.2021.230572>
- [15] 余本功, 张培行. 基于双通道特征融合的 WPOS-GRU 专利分类方法[J]. 计算机应用研究, 2020, 37(3): 655-658.
- [16] Hochreiter, S. and Schmidhuber, J. (1997) Long Short-Term Memory. *Neural Computation*, **9**, 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- [17] Wu, Y., Liu, H., Li, B., *et al.* (2021) Individual Thermal Comfort Prediction Using Classification Tree Model Based on Physiological Parameters and Thermal History in Winter. *Building Simulation*, **14**, 1651-1665. <https://doi.org/10.1007/s12273-020-0750-y>