

# 基于 Attention-LSTM-Kalman 建模的风洞动态流量软测量

周隽杰, 付东翔

(上海理工大学光电信息与计算机工程学院, 上海 200093)

**摘要:** 针对风洞流量测量中传统静态软测量模型估计精度低、鲁棒性差等问题, 提出了注意力机制 (Attention mechanism, Attention)、长短时记忆神经网络 (Long short-term memory, LSTM) 和卡尔曼滤波 (Kalman filtering, Kalman) 结合的 Attention-LSTM-Kalman 软测量模型: 通过 LSTM 网络建立静态软测量模型, 在此基础上, 提出一种基于注意力机制的改进方案, 考虑到系统的动态特性, 使用卡尔曼滤波动态调整软测量模型输出序列。实验结果表明, 静态预测模型 LSTM 的预测效果优于循环神经网络 (Recurrent neural network, RNN) 和门控循环单元 (Gated recurrent unit, GRU) 等模型; 基于 LSTM、Attention-LSTM 和 Attention-LSTM-Kalman 的 3 种模型的对比预测测量结果表明, 注意力机制能有效提高模型精准度, 引入卡尔曼滤波改善了模型的动态测量特性。该模型方案在风洞系统的流量测量验证了其可行性和有效性。

**关键词:** 深度学习; 长短时记忆神经网络; 注意力机制; 卡尔曼滤波; 软测量技术

**中图分类号:** TP274.2      **文献标志码:** A

## Soft Measurement of Wind Tunnel Dynamic Flow Based on Attention-LSTM-Kalman Modeling

ZHOU Junjie, FU Dongxiang

(School of Optical-Electrical and Computer Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China)

**Abstract:** Aiming at the problems such as low estimation accuracy and poor robustness of traditional static soft measurement model in wind tunnel flow measurement, an Attention-LSTM-Kalman measurement model combing attention mechanism (Attention), long short-term memory (LSTM) and Kalman filtering (Kalman) is proposed: a static soft-measuring model is established through LSTM network. On this basis, an improved scheme based on attention mechanism is proposed. Considering the dynamic characteristics of the system, Kalman filter is used to dynamically adjust the output sequence of the soft-measuring model. Experimental results show that LSTM is better than recurrent neural network (RNN) and gated recurrent unit (GRU) models. The comparison of the prediction results of the three models based on LSTM, Attention-LSTM and Attention-LSTM-Kalman shows that the attention mechanism could effectively improve the accuracy of the model, and the introduction of Kalman filter improves the dynamic measurement characteristics of the model. The feasibility and effectiveness of the

proposed model are verified by the flow measurement in the wind tunnel system.

**Key words:** deep learning; long short-term memory; attention mechanism; Kalman filtering; soft-measuring technology

## 引 言

风洞作为气体流量次级标准装置,主要用于模拟真实环境下的气体流动<sup>[1]</sup>。风洞实验是研究空气动力学中的关键一环,不仅对航空与航天工程的发展起着重要作用,在交通运输、风力发电等方面也有广泛应用。动态流量是风洞实验中的一项重要参考指标,对于评价系统动态特性有重要意义。目前我国有一些流量仪器生产厂家宣称其产品已通过风洞流量标定,实际上他们标定的仅仅是平均流速,再计算出流量,但用固定的平均流速点来测流量精度不高<sup>[2]</sup>。且大部分流量仪都是在固定场所标定,很难考虑到不同环境下其他因素对流量的影响,测得流量的可靠性不强。在空气动力学研究日益发展的环境下,有必要研究高精度标准气体流量测量方法。软测量技术是根据某种最优准则,基于辅助变量和主导变量之间的数学关系构建的软测量模型<sup>[3]</sup>。它采用各种计算方法有机融合,实现待测参数及指标的测量<sup>[4]</sup>。该方法可以顾及更全面的样本数据,这对研究高精度风量动态测量有重要意义。

传统的软测量技术主要方法中,卡尔曼滤波是一种重要的方法,其动态性能好,但在噪声条件下,其状态估计与真实值的误差不易提出,测量精度受限。基于BP神经网络的动态流量测量法<sup>[5]</sup>,在一定程度上提高了在线测量精度,但简单的神经网络模型由于训练过程收敛速度慢<sup>[6]</sup>,容易出现过拟合、稳定性差等问题。

随着深度学习的不断发展,其特点是可以从原始特征中获得更有效的多尺度特征,收敛速度更快,鲁棒性更好<sup>[7]</sup>。近年来涌现出深度网络模型有循环神经网络(Recurrent neural network, RNN)、门控循环单元(Gated recurrent unit, GRU)网络、长短时记忆神经(Long short-term memory, LSTM)网络等,其中,LSTM网络因其对时间序列的强大学习能力,已成功应用于软测量领域。Ke等<sup>[8]</sup>提出基于长短期记忆单元的软测量建模方法,有效地实现了工业过程中的动态测量。Yan等<sup>[9]</sup>提出了一种基于Attention-LSTM模型的河流流量预测模型,通过Attention学习数据间的非线性关系,加强序列间的相关性,并有效提升预测精度。上述LSTM模型方法只用作静态预测模型,其较长的训练、参数整定耗时,无法有效应用于动态瞬时流量测量。虽然离线训练的静态模型无需在线学习,但在动态性提取上有缺陷,导致估计精度低、鲁棒性差等问题<sup>[10]</sup>。另外,LSTM模型存在当时时间序列过长,序列中两个间隔时间步很远的样本之间相关特性不易发现等问题,考虑引入注意力机制。

本文基于LSTM建立静态软测量模型,加入注意力机制,并结合Kalman滤波,提出一种基于Attention-LSTM-Kalman的动态测量模型。根据实验风洞环境特点,测量与气体流量相关的变量数据,对特征值进行归一化处理作为软测量模型的输入变量,并建立基于注意力机制的LSTM预测模型,为了更好地适应系统的动态特性,加入Kalman对输出进行动态调整。最后通过风洞测量实验验证该模型在动态测量中的可行性和有效性。

## 1 风洞流量软测量模型

本文为有效实现风洞流量动态测量,采用长短时记忆网络LSTM作为预测模型,采集过去一段时间内的相关变量(压力、压差、温度和风速)作为输入,对时间序列中的流量进行预测,作为基本时间序列,此外引入注意力机制来更好地适应序列样本的相关性。图1为本实验搭建的Attention-LSTM建模

过程。通过学习、训练和验证得到更精准的静态预测模型。

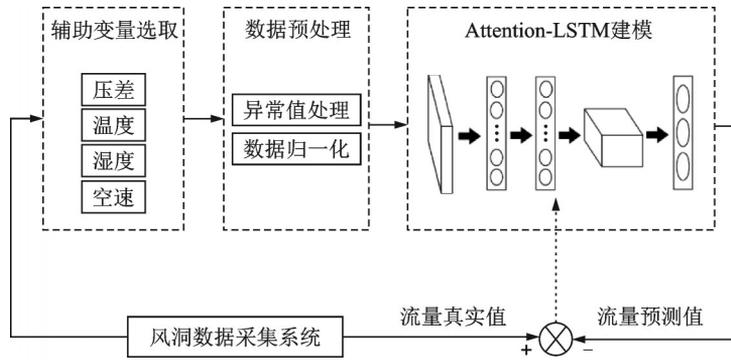


图1 Attention-LSTM 建模过程

Fig.1 Modeling process of Attention-LSTM

### 1.1 LSTM 神经网络

通过应用 LSTM,不仅可以建立顺序数据的短期关系,而且可以建立长期依赖关系<sup>[11]</sup>。LSTM 网络结构<sup>[12]</sup>如图 2 所示,其引入了门控的思想,以保护和控制单元的状态,使网络能在多个时间步上继续学习。

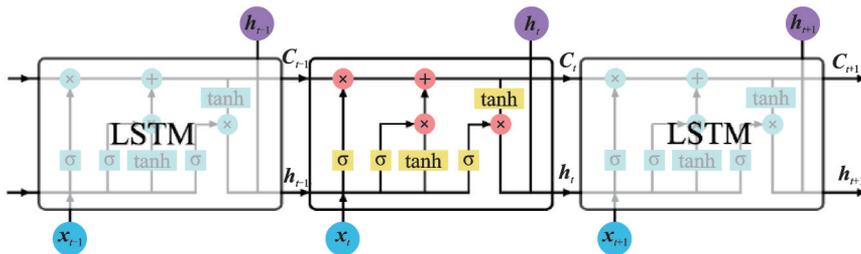


图2 LSTM网络结构

Fig.2 Structure of LSTM network

(1)遗忘门确定哪些信息从 LSTM 单元状态中被丢弃,其输出表示为

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \tag{1}$$

式中:σ为 sigmoid 函数;  $W_f$ 和  $b_f$ 为 LSTM 单元参数。

(2)输入门确定将哪些信息存储在 LSTM 单元中。输入门中, sigmoid 层决定需要更新的信息; tanh 层创建新的候选向量  $C_t$  并添加到细胞状态,通过与旧状态  $C_{t-1}$  的计算实现更新

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \tag{2}$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \tag{3}$$

$$C_t = f_t \circ C_{t-1} + i_t \circ \tilde{C}_t \tag{4}$$

式中“ $\circ$ ”表示两个向量乘积。

(3)通过输出门根据更新 LSTM 单元的状态确定输出信息。输出门中, sigmoid 层决定当前单元状态的输出; tanh 层对细胞状态进行处理,得到一个  $[-1, 1]$  之间的值,再乘以 sigmoid 输出,求得输出

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \tag{5}$$

$$h_t = o_t * \tanh(C_t) \quad (6)$$

$\tilde{C}_t$ 和 $h_t$ 在每个时间步都被转移到下一个单元,然后重复进行上述过程。

本文建立的LSTM网络通过学习预测值和流量样本间的差异来学习权值和偏差,这种训练方式可以更全面地学习数据间的非线性关系。

## 1.2 注意力机制

由于多维辅助变量对输出的影响程度不一,可能对预测结果产生影响。对此本文用注意力机制<sup>[13]</sup>为不同时间步的输入分配权重来改善流量预测效果。主要原理是:保存时间序列输入经LSTM网络产生的中间结果,将该结果与输出值联系起来,从而使模型学习如何选择性地关注数据,并为这些数据分配更合理的权重<sup>[14]</sup>。该网络结构如图3所示。

在 $t$ 时刻得到LSTM隐藏状态为: $[h_{t,1}, h_{t,2}, \dots, h_{t,i}, \dots, h_{t,T}]^T$ 。

计算 $t$ 时刻隐层状态 $h_t$ 对输出的注意力权重 $\alpha_{t,i}$ ,本文采用点乘形式计算

$$e_{t,i} = S_{t-1}^T \cdot h_{t,i} \quad (7)$$

$$\alpha_{t,i} = \frac{\exp(e_{t,i})}{\sum_{k=1}^T \exp(e_{t,k})} \quad (8)$$

本文将注意力机制加入LSTM神经网络,用于计算网络各隐层状态的权重,并建立Attention-LSTM软测量模型实现风洞流量预测。

## 1.3 构建Attention-LSTM网络模型

基于Attention-LSTM的网络层结构如图4所示,主要有4部分组成。

输入层:输入为辅助变量时间序列和流量值。

设 $T$ 为时间步平滑窗口数,则在 $t$ 时刻输入序列为

$$x = [x_{t-T+1}, x_{t-T+2}, \dots, x_{t-T+i}, \dots, x_t]^T \quad (9)$$

$$x_t = [\text{pressure}_t, \text{airspeed}_t, \text{temp}_t, \text{humidity}_t] \quad (10)$$

式中: $\text{pressure}_t$ ,  $\text{airspeed}_t$ ,  $\text{temp}_t$ ,  $\text{humidity}_t$ 分别为 $t$ 时刻的压差、空速值、温度、湿度。

LSTM层:利用LSTM层对输入序列 $X$ 进行学习,记在 $t$ 时刻LSTM的隐层状态为 $h_t$

$$h_t = [h_{t,1}, h_{t,2}, \dots, h_{t,i}, \dots, h_{t,T}] \quad i \in [1, T] \quad (11)$$

$$h_{t,i} = \text{LSTM}(x_{t,i}, h_{t-1,i}) \quad i \in [1, T] \quad (12)$$

Attention层:Attention层的输入为上一层的输出 $h_t$ ,通过式(7,8)求得注意力权值 $\alpha_{t,i}$ ,记 $t$ 时刻该层的输出为 $S_t$

$$S_t = \sum_{i=1}^T \alpha_{t,i} h_{t,i} \quad (13)$$

输出层:选用激活函数为sigmoid的全连接层,输出 $t+1$ 时刻的流量预测值 $y$

$$y = \text{sigmoid}(wS_t + b) \quad (14)$$

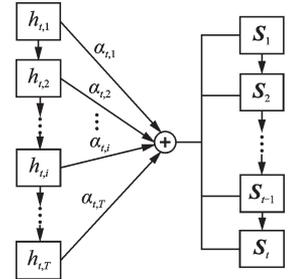


图3 注意力机制工作步骤  
Fig.3 Work steps of attention mechanism

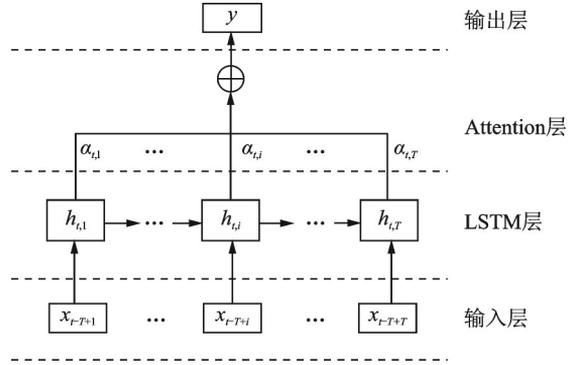


图4 基于Attention-LSTM神经网络层级结构  
Fig.4 Hierarchy of Attention-LSTM network

## 2 卡尔曼滤波

考虑到被测系统的动态特性,且辅助变量的采集过程中产生的噪声和错误,上述建立的软测量模型本着“错进错出”的原理必然会对测量结果产生一定影响。针对该问题,提出在模型后使用卡尔曼滤波来消除影响。它运用递归算法来解决离散数据的滤波问题,并且不需要所有的先前数据<sup>[15]</sup>。具体方法如下:

(1)通过静态软测量法分析当前时刻的流量真值,由流量方程为

$$Q_k = SV_k \quad (15)$$

式中: $Q_k$ 为 $k$ 时刻的流量数据; $S$ 为截面积,这里取风洞洞口处截面; $V_k$ 为 $k$ 时刻该截面上的空速。

(2)由于 $k$ 时刻下该流量真值与软测量模型的预测值都被认为是不可信的,故依据卡尔曼原理对系统建模得到最优估计值。记 $Q_j(k)$ 为连续的静态软测量信号, $Q_d(k)$ 为网络软测量模型软测量信号。选取 $Q_d(k)$ 作为 Kalman 的测量信号,得到该系统的状态方程和测量方程分别为

$$Q_d(k) = AQ_d(k-1) + BU(k) + W(k) \quad (16)$$

$$Z(k) = HQ_j(k) + V(k) \quad (17)$$

式中: $A$ 和 $B$ 为系统参数; $Q_d(k)$ 和 $Q_d(k-1)$ 分别为 $k$ 时刻和 $k-1$ 时刻网络软测量模型得到的流量值; $Q_j(k)$ 为 $k$ 时刻分析的流量真值; $U(k)$ 和 $Z(k)$ 分别为 $k$ 时刻的控制量和观测值; $W(k)$ 和 $V(k)$ 分别表示过程和测量噪声; $H$ 为测量系统的参数。

(3)经网络模型预测,Kalman 的输入输出都是一维流量数据,故取 $A=1, H=1, B=0$ 。假设过程 $W(k)$ 和测量噪声 $V(k)$ 不随系统状态变化,为高斯白噪声,记其协方差分别为 $R, Q$ 。采用 $k-1$ 时刻网络模型的流量输出作为 $k$ 时刻的先验估计值并预测误差协方差 $P$ ,则有

$$Q_d(k|k-1) = Q_d(k-1|k-1) + W(k-1) \quad (18)$$

$$P(k|k-1) = P(k-1|k-1) + Q \quad (19)$$

式中: $P(k|k-1)$ 为先验估计的协方差, $P(k-1|k-1)$ 为 $k-1$ 状态下的协方差。

(4)得到状态预测结果后,结合 $k$ 时刻的网络模型流量输出 $Z(k)$ ,对先验估计值修正。得到当前时刻的最优估计值 $Q_d(k|k)$ 为

$$Q_d(k|k) = Kg(k)(Z(k) - Q_d(k|k-1)) \quad (20)$$

式中 $Kg(k)$ 为 $k$ 时刻的卡尔曼增益,可表示为

$$Kg(k) = P(k|k-1)/(P(k|k-1) + R) \quad (21)$$

(5)至此已经得到了 $k$ 时刻的最优估计值 $X(k|k)$ 。为了 Kalman 能一直递归到系统状态结束,还需更新协方差 $P(k|k)$

$$P(k|k) = (1 - Kg(k))P(k|k-1) \quad (22)$$

按照上述 Kalman 算法流程实现对 Attention-LSTM 软测量模型输出的动态校正,综合输出当前时刻流量的最优估计值。

## 3 实验分析

### 3.1 实验数据

根据式(15)可知,理想状态下的气体流量 $Q$ 与流速 $v$ 正相关,而根据伯努利方程

$$p + \frac{1}{2}\rho v^2 + \rho gh = C \quad (23)$$

可知,流速  $v$  与高度  $h$ , 压强  $p$ , 流体密度  $\rho$  有关。故本实验选取风洞出口截面处的压差、空速、温度和湿度作为预测流量的辅助变量, 并使用标准流量计观测流量数据作为验证集。

本文使用的数据来自实验室风洞数据采集系统, 共 2 000 组实验数据, 时间间隔为 10 s。为了模型训练和验证测试, 选取前 70% 的观察数据集作训练集来训练估计样本模型的性能, 后 30% 为测试集。由于输入和输出间量纲不同, 在分析训练模型前, 需做归一化<sup>[16]</sup>处理

$$\bar{x}_m^{(t)} = \frac{x_m^{(t)} - x_m^{\min}}{x_m^{\max} - x_m^{\min}} \quad (24)$$

式中:  $x_m^{(t)}$  为  $t$  时刻第  $m$  个流量相关变量的数据;  $\bar{x}_m^{(t)}$  为数据归一化后序列。

### 3.2 实验结果

网络的输出值反归一化<sup>[17]</sup>后, 转化为原始数据对应的输出。LSM 模型的流量预测结果如图 5 所示。以原始四维变量为输入建立 Attention-LSTM-Kalman 网络模型, 其流量预测结果如图 6 所示。

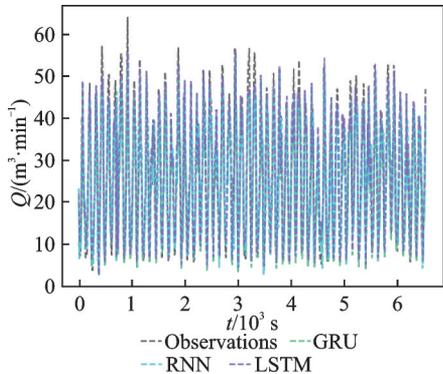


图5 流量真实值、GRU、RNN 以及 LSTM 模型预测值随时间序列的变化

Fig.5 Change of real value, GRU, RNN and LSTM model predicted value with time series

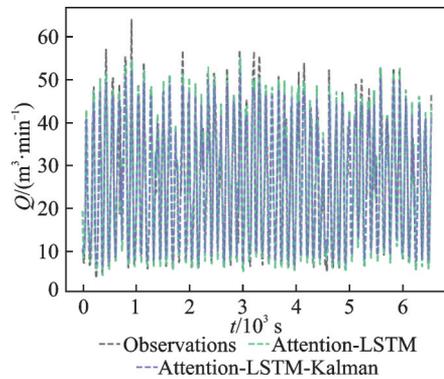


图6 流量真实值、Attention-LSTM 以及 Attention-LSTM-Kalman 模型预测值随时间序列的变化

Fig.6 Change of real value, Attention-LSTM and Attention-LSTM-Kalman model predicted value with time series

模型预测的均方根误差(Root mean squared error, RMSE)和平均绝对误差(Mean absolute error, MAE)评价如图 7、8 所示。静态预测模型 Attention-LSTM 预测值的 RMSE 和 MAE 均低于 GRU、RNN 和 LSTM 模型, 证明在本实验中基于注意力机制的 LSTM 较其他两种时间序列模型取得了更准确的预测值。而本文提出的 Attention-LSTM-Kalman 模型的 RMSE 和 MAE 均低于 Attention-LSTM 模型, 经 Kalman 动态调整后, 模型的准确度明显提升, 表明本模型有更准确的预测能力。

模型预测的确定系数  $R$ -squared 评价如图 9 所示。静态预测模型 Attention-LSTM 预测值的  $R$ -squared 比 GRU、RNN 和 LSTM 模型更接近于 1, 证明在本实验中, 基于注意力机制的 LSTM 模型的拟合度优于其他两种预测模型。而本文提出的

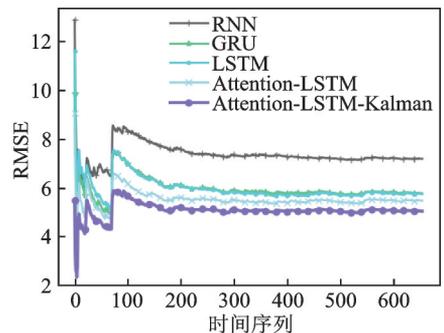


图7 RMSE 值随时间序列的变化

Fig.7 Change of RMSE with time series

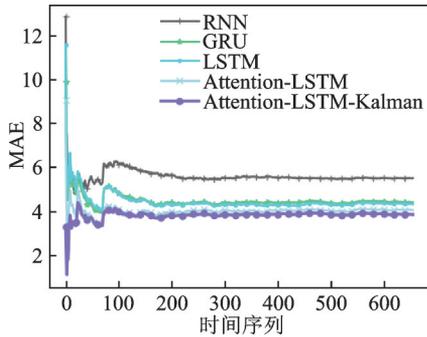


图8 MAE值随时间序列的变化

Fig.8 Change of MAE with time series

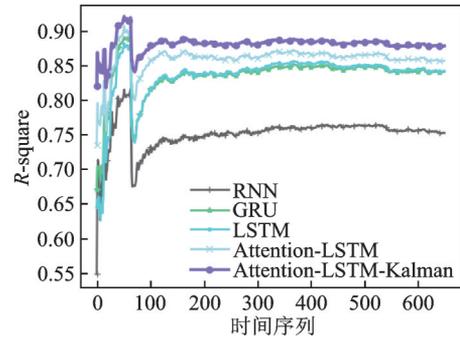


图9 R-square值随时间序列的变化

Fig.9 Change of R-square with time series

Attention-LSTM-Kalman模型的  $R$ -squared 高于 Attention-LSTM, 静态预测模型经 Kalman 动态调整后,  $R$ -squared 的值显著上升。这表明 LSTM-Kalman 模型在预测方面具有更好的解释能力, Attention-LSTM-Kalman 模型更好地拟合了数据。各网络模型预测评价如表 1 所示。

表 1 各网络模型预测结果对比

Table 1 Prediction results comparison of various network models

| 网络模型                  | RMSE | MAE  | $R$ -square |
|-----------------------|------|------|-------------|
| RNN                   | 7.19 | 5.50 | 0.75        |
| GRU                   | 5.77 | 4.40 | 0.84        |
| LSTM                  | 5.55 | 4.14 | 0.85        |
| Attention-LSTM        | 5.47 | 4.05 | 0.86        |
| Attention-LSTM-Kalman | 5.04 | 3.85 | 0.88        |

#### 4 结束语

针对传统神经网络静态预测模型在动态流量测试中估计精度低, 适应性差, 不适用于动态测量场景的问题。本文提出一种动静结合的软测量方法, 在静态预测模型后追加 Kalman 滤波进行动态校正, 使软测量模型能够取得更高的精度和拟合度, 为了使序列间获得更好的相关性, 本文也引用了注意力机制加以实现。实验结果表明, Attention-LSTM-Kalman 模型的动态测量值比 RNN、LSTM 等传统预测模型的结果更加平滑且拟合效果更好, 实现了流量动态测量, 本文的模型方法对流量测量、标定等方面有参考意义。

#### 参考文献:

- [1] 恽起麟. 风洞实验[M]. 北京: 国防工业出版社, 2000.
- [2] 张绍武, 关祥东, 朱涛, 等. 高超声速风洞进气道流量系数测量精度影响因素研究[J]. 推进技术, 2013, 34(4): 470-476.  
ZHANG Shaowu, GUAN Xiangdong, ZHU Tao, et al. Investigation on factors affecting the measurement accuracy for inlet flow coefficient in hypersonic wind tunnel[J]. Journal of Propulsion Technology, 2013, 34(4): 470-476.
- [3] 唐翊翔, 于合龙, 陈桂芬. 基于比色法的温度场测量[J]. 长春师范大学学报, 2014, 33(6): 25-27.  
TANG Hongxiang, YU Helong, CHEN Guifen. Temperature field measurement based on colorimetric method[J]. Journal of Changchun Normal University, 2014, 33(6): 25-27.
- [4] 李海青, 黄志尧. 软测量技术原理及应用[M]. 北京: 化学工业出版社, 2000.

- [5] 王伟吉, 纪静迪, 黄卫庆, 等. 基于软测量技术的蒸汽流量测量[J]. 中南大学学报(自然科学版), 2013, 44(S1): 248-254.  
WANG Weiji, JI Jingdi, HUANG Weiqing, et al. Steam flow evaluation based on soft-sensing technique[J]. Journal of Central South University(Science and Technology), 2013, 44(S1): 248-254.
- [6] WANG Yanhong. Listed company financial risk prediction based on BP neural work[C]//Proceedings of International Conference on Measuring Technology & Mechatronics Automation. [S.l.]: IEEE, 2015.
- [7] WANG Xuyu, GAO Lingjun, MAO Shiwen, et al. CSI-based fingerprinting for indoor localization: A deep learning approach [J]. IEEE Transactions on Vehicular Technology, 2016, 66(1): 763-776.
- [8] KE Wensi, HUANG Dexian, YANG Fan, et al. Soft sensor development and applications based on LSTM in deep neural networks[C]//Proceedings of 2017 IEEE Symposium Series on Computational Intelligence (SSCI). Honolulu, HI, USA: IEEE, 2017: 1-6.
- [9] YAN Le, CHEN Changwei, HANG Tingting, et al. A stream prediction model based on attention-LSTM[J]. Earth Science Informatics, 2021, 14(2): 723-733.
- [10] 罗健旭, 邵惠鹤. 应用多神经网络建立动态软测量模型[J]. 化工学报, 2003, 54(12): 1770-1773.  
LUO Jianxu, SHAO Huihe. Developing dynamic soft sensors using multiple neural networks[J]. CIESC Journal, 2003, 54(12): 1770-1773.
- [11] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.
- [12] MESSINA R, LOURADO J. Segmentation-free handwritten Chinese text recognition with LSTM-RNN[C]//Proceedings of 2015 13th International Conference on Document Analysis and Recognition (ICDAR). Tunis, Tunisia: [IEEE], 2015: 171-175.
- [13] BAHDANAU D, CHO K, BENGIO Y, et al. Neural machine translation by jointly learning to Align and Translate[C]//Proceedings of 2015 3rd International Conference on Learning Representations (ICLR). San Diego, CA, USA: [s.n.], 2015.
- [14] 龚飘怡, 罗云峰, 方哲梅, 等. 基于 Attention-BiLSTM-LSTM 神经网络的短期电力负荷预测方法[J]. 计算机应用, 2021, 41(S1): 81-86.  
GONG Piaoyi, LUO Yunfeng, FANG Zhemei, et al. Short-term power load forecasting method based on Attention-BiLSTM-LSTM neural network[J]. Journal of Computer Applications, 2021, 41(S1): 81-86.
- [15] 谢亚晋, 徐之海, 冯毕君, 等. 基于最小生成树与改进卡尔曼滤波器的实时电子稳像方法[J]. 光子学报, 2018, 47(1): 59-68.  
XIE Yajin, XU Zhihai, FENG Bijun, et al. Real-time video stabilization based on minimal spanning tree and modified Kalman filter[J]. Acta Photonica Sinica, 2018, 47(1): 59-68.
- [16] BOUKTIF S, FIAZ A, OUNI A, et al. Optimal deep learning lstm model for electric load forecasting using feature selection and genetic algorithm: Comparison with machine learning approaches[J]. Energies, 2018, 11(7): 1627-1636.
- [17] 孙剑, 蒙西, 乔俊飞. 基于 MIV-RBF 神经网络的主蒸汽流量软测量[J/OL]. 控制工程. [2022-03-28]. DOI:10.14107/j.cnki.kzgc.CPCC2020-204.  
SUN Jian, MENG Xi, QIAO Junfei. Soft sensor model of main steam flow based on mean impact vaule and rbf neural network [J/OL]. Control Engineering of China. [2022-03-28]. DOI:10.14107/j.cnki.kzgc.CPCC2020-204.

#### 作者简介:



周隽杰(1995-), 男, 硕士研究生, 研究方向: 软测量技术、嵌入式系统、工业自动化等, E-mail: jack950523@163.com.。



付东翔(1971-), 通信作者, 男, 副教授, 研究方向: 工业自动化、光电检测技术等, E-mail: fudx@usst.edu.cn.。

(编辑: 夏道家)