

DOI: 10.13382/j.jemi.B2104583

# 基于 LSTM 网络的水分天平零点误差补偿方法\*

毛翊涵 林海军 吴天昊 徐 雄

(湖南师范大学工程与设计学院 长沙 410081)

**摘要:**零点误差是衡量水分天平的重要指标,其直接影响水分天平的称重准确度。提出了一种基于长短期记忆(LSTM)网络的水分天平零点误差补偿方法,分析了水分天平零点误差机理,使用历史零点误差数据建立基于双层 LSTM 长短期记忆网络的零点误差预测模型,采用空载与加载载荷时两种情况分别进行补偿。利用该模型对 200 g/1 mg 的水分天平进行现场补偿验证,结果表明,补偿后的水分天平在空载和加载载荷时,最大示值误差约为 6 mg,远小于补偿前的示值误差,证实了这种方法的有效性。

**关键词:**水分天平;零点误差;长短期记忆网络;误差补偿

**中图分类号:** TP206+.3 **文献标识码:** A **国家标准学科分类代码:** 510.40

## Zero error compensation method for moisture balance based on LSTM network

Mao Yihan Lin Haijun Wu Tianhao Xu Xiong

(College of Engineering and Design, Hunan Normal University, Changsha 410081, China)

**Abstract:** The zero error is an important parameter of the moisture balance, which directly affects the weighting accuracy of measuring the moisture. A method for compensating the zero error of moisture balance based on long-short term memory (LSTM) network was proposed. The mechanism of the zero error of moisture balance was analyzed, and the prediction model of zero error based on the double layer LSTM was established by using historical zero error data. This proposed model was used to compensate the zero error of the moisture balance with some loads and without load respectively, where the measuring range of the moisture balance is 200 g and its resolution is 1 mg. The experimental results show that the maximum error of the compensated moisture balance is about 6 mg, which is much smaller than before. The experiments have verified the effectiveness of this method.

**Keywords:** moisture balance; zero error; long-short term memory network (LSTM); error compensation

## 0 引言

水分天平是测定物质水分含量的仪器设备,质量称重模块是水分天平的关键部分<sup>[1]</sup>,而零点误差是影响质量称重准确性的主要因素,是评价水分天平性能的重要指标。理论上,水分天平空载时输出为零,然而受温度、传感器蠕变与非线性、电源纹波与噪声等因素干扰<sup>[2]</sup>,水分天平输出不为 0,而是在零点附近随机波动,即产生了零点误差<sup>[3]</sup>。同理,当加载载荷时,水分天平受零点误差影响,其输出不会恒定,而是会发生缓慢、无规律的变化,从而影响称量结果的准确性。因此,必须进行零点误差

补偿。

在当前的水分天平工程实践中,工程师们提出了一种“零点跟踪方法”,即首先设置一个误差窗口(一般为  $1e$ ,其中  $e$  为天平的分度值<sup>[4]</sup>),窗口大小为零点误差允许范围,当零点误差小于误差窗口值,系统默认无漂移,水分天平示值为 0。由于水分天平零点误差变化缓慢,这种方法在工程上获得了广泛应用,有效减小了零点误差;但误差窗口设置缺乏理论指导,不能获得最佳的误差窗口,零点误差有待进一步减小。

为了解决这一问题,刘亚坤等<sup>[5]</sup>针对电子分析天平温度漂移问题提出了基于支持向量机的补偿方法,通过采集传感器温度信号,建立了电子分析天平温度漂移误

收稿日期:2021-08-01 Received Date:2021-08-01

\* 基金项目:国家自然科学基金(51775185)、湖南省自然科学基金(2018JJ2261)项目资助

差模型并进行了温度漂移补偿。李菲等<sup>[6]</sup>在分析电子天平震动信号的频谱特性基础上,提出了一种基于梯度变步长最小均方(LMS)自适应滤波器的电子天平抗震动设计方法,有效减小了冲击性干扰对电子天平性能的影响。上述方法为水分天平零点误差补偿提供了借鉴。

实际上,水分天平零点误差为典型的时间序列,因此可以利用差分自回归滑动平均(ARIMA)模型、递归神经网络(RNN)模型等常用的时间序列预测方法完成零点误差补偿。ARIMA 要求时序数据稳定或者差分化后稳定,适合线性时间序列处理<sup>[7]</sup>。水分天平零点误差受各种非线性因素影响,关系复杂,简单的线性模型并不合适。RNN 在处理长期依赖(时间序列上距离较远的节点)时会遇到巨大的困难,因为计算距离较远的节点之间的联系时会涉及雅可比矩阵的多次相乘,这会带来梯度消失或者梯度膨胀的问题,难以建立长时间间隔的状态之间的依赖关系<sup>[8]</sup>,而长短期记忆网络(LSTM)为解决这一问题提供了良好的解决方案。这种 LSTM 网络具有一定的记忆功能,即神经网络输出值不仅与当前时刻的输入有关,而且与上一时刻的输出及单元状态有关,其广泛应用于时间序列预测、语音识别、机器翻译<sup>[9]</sup>等领域。这种 LSTM 网络为水分天平零点误差补偿提供了良好借鉴。

基于此,本文利用零点误差历史数据,建立基于 LSTM 网络的水分天平零点误差补偿模型,根据历史信息预测下一时刻零点误差值,并及时修正误差,达到实时补偿水分天平零点误差的目的。

## 1 基于 LSTM 网络的水分天平零点误差补偿

### 1.1 水分天平工作原理及零点误差来源

质量称重为水分天平工作的关键部分,水分天平的质量称重部分由应变式称重传感器构成<sup>[10]</sup>。在实际应变式称重传感器设计电路中通常使 4 个应变计阻值相同,即  $R_1 = R_2 = R_3 = R_4 = R$ ,无荷载作用时,电桥平衡,输出电压  $U_L$  为 0。有荷载作用时,应变计产生形变,  $R_1$ 、 $R_4$  被拉伸,阻值增加  $R_1 \rightarrow R_1 + \Delta R_1$ 、 $R_4 \rightarrow R_4 + \Delta R_4$ ;  $R_2$ 、 $R_3$  被压缩,阻值减小  $R_2 \rightarrow R_2 - \Delta R_2$ 、 $R_3 \rightarrow R_3 - \Delta R_3$ ,此时电桥失衡。设每个应变计有相同的形变量  $\Delta R$ ,则输出电压  $U_L$  为:

$$U_L = \frac{\Delta R}{R} U \quad (1)$$

式中:  $U$  为称重传感器激励电压源。由式(1)可知,称重输出  $U_L$  与应变计形变  $\Delta R$ 、供电电压  $U$  分别成线性关系。但当电源电压波动时,会产生时变的波动电压  $\Delta U(n)$ ,经过计算可获得电压波动产生的非线性时变误差  $\Delta_U(n)$  为:

$$\Delta_U(n) = \frac{\frac{\Delta R}{R} U - \frac{\Delta R}{R} (U + \Delta U(n))}{\frac{\Delta R}{R} U} = -\frac{\Delta U(n)}{U} \quad (2)$$

另外,由温度引起的应变计的阻值误差也是称重传感器非线性误差的主要来源<sup>[11]</sup>。设温度发生变化时,每个应变计有相同的阻值偏差量  $\Delta R_T(n)$ ,有应变计阻值  $R_1, R_4 \rightarrow R + \Delta R + \Delta R_T(n)$ ,  $R_2, R_3 \rightarrow R - \Delta R + \Delta R_T(n)$ ,经计算可获得温度变化引起的非线性时变误差为:

$$\Delta_T(n) = \frac{\frac{\Delta R}{R} U - \frac{\Delta R}{R + \Delta R_T(n)} U}{\frac{\Delta R}{R} U} = 1 - \frac{R}{R + \Delta R_T(n)} \quad (3)$$

此外,传感器自重及加载方向斜偏产生的横向荷载力都会使应变计变形,从而产生误差。另一方面,称重电路的器件噪声、辐射噪声及传导噪声等其他电磁干扰<sup>[12]</sup>,均构成了称重系统的随机干扰噪声,它们直接影响水分天平零点的准确性。

### 1.2 水分天平零点误差补偿原理

图 1 所示为基于 LSTM 网络的水分天平零点误差补偿算法原理框图。系统首先将采集获得的称重初始值进行滑窗均值滤波得到  $X$ ,即  $X = [x_t, x_{t-1}, \dots, x_{t-n+1}]^T$ ;  $X_{nl}$  表示分解  $X$  后得到的部分信号,如式(5)所示;  $H$  表示空载时以  $X$  为输入的 LSTM 模型预测输出序列;  $H_{nl}$  表示加载时以  $X_{nl}$  为输入的 LSTM 模型预测输出序列;  $H_c$  表示  $H_{nl}$  与  $X$  信号重构后的输出;  $Y$  表示水分天平误差补偿后的称重结果输出。

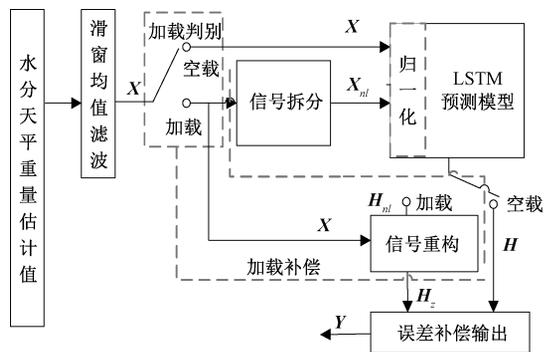


图 1 基于 LSTM 的水分天平零点误差补偿方法原理

Fig. 1 Zero error compensation method of moisture balance based on long-short term memory network

根据水分天平是否加载,将零点误差补偿分为空载时零点误差补偿和加载时零点误差补偿。

#### 1) 空载时零点误差补偿原理

空载时,将水分天平称重初始值滑窗均值滤波后的  $X$  作为 LSTM 预测模型输入,获得预测输出序列  $H$ ,用于零点跟踪<sup>[13]</sup>,并根据预测输出及时修正天平输出,得到

误差补偿输出  $\mathbf{Y}$ , 此时  $\mathbf{Y}$  趋近于 0。

### 2) 加载时零点误差补偿原理

水分天平加载时, 由于传感器蠕变、电路噪声等因素影响, 零点误差趋势将发生改变, 此时空载时建立的 LSTM 预测模型无法满足加载后零点误差的变化趋势, 且加载后零点误差数据无法直接测得, 需构建加载时的零点误差补偿模型<sup>[14]</sup>。实验发现, 当加载被测物体时, 经过一段时间或  $N$  个采样数据后, 水分天平的示值将会保持稳定, 此时天平示值为仪器输出信号与零点误差之差。

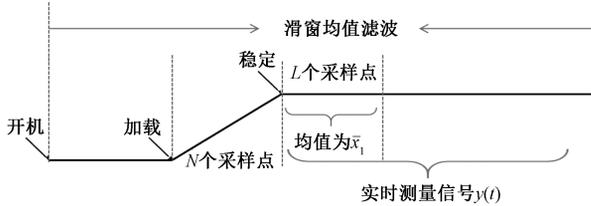


图 2 零点误差数据处理示意图

Fig. 2 Schematic diagram of zero error data processing

图 2<sup>[15]</sup> 所示为水分天平零点误差数据处理示意图。通过分解基本稳定后的水分天平称重信号, 可以获得被测载荷加载初始阶段的信号均值  $\bar{x}_1$  与零点误差序列  $\mathbf{X}_{nl}$ 。这里,  $\bar{x}_1$  由计算图 2 中初始  $L$  个采样点的均值获得, 观测值向量  $\mathbf{Y}_T$  由实时测量信号  $y(t)$  组成, 即  $\mathbf{Y}_T = [y_{(t+L+1)}, y_{(t+L+2)}, \dots, y_{(t+L+n)}]$ , 零点误差序列  $\mathbf{X}_{nl}$  为观测值向量  $\mathbf{Y}_T$  与被测载荷加载初始阶段的信号均值  $\bar{x}_1$  之差, 即:

$$\bar{x}_1 = \frac{1}{L} \sum_{t=1}^L y(t) \quad (4)$$

$$\mathbf{X}_{nl} = \mathbf{Y}_T - \bar{x}_1 * \text{ones}(1, N) \quad (5)$$

式中:  $\text{ones}(1, N) = [1, 1, \dots, N]$ ;  $y_{(t+L+1)}$  为水分天平加载后的第  $N+L$  个实时测量信号值 (图 2)。参考图 1, 系统将误差序列  $\mathbf{X}_{nl}$  输入至 LSTM 预测模型, 获得预测输出序列  $\mathbf{H}_{nl}$ , 其中  $\mathbf{H}_{nl} = [\tilde{y}_t, \tilde{y}_{t-1}, \dots, \tilde{y}_{(t-n)}]$ , 再将  $\mathbf{H}_{nl}$  与称重初始值进行滑动均值滤波后的输出值  $\mathbf{X}$  进行信号重构, 即:

$$\mathbf{H}_z = \mathbf{X} - \mathbf{H}_{nl} \quad (6)$$

此时, 误差补偿输出  $\mathbf{Y} = \mathbf{H}_z$ , 即完成了加载时水分天平零点误差补偿。

### 3) 水分天平载荷加载判决

由于水分天平存在零点漂移, 使用格拉布斯准则 (Grubbs)<sup>[16]</sup> 判断水分天平是否加载, 以防止出现加载误判问题。设零点误差测量值  $x_i$  对应的残差为  $v_i$ , 则当满足式 (7) 时, 测量值  $x_i$  被认为是较大误差数据, 此时系统判定水分天平有加载。

$$|v_i| = |x_i - \bar{x}| > g(n, \alpha) \times \sigma(x) \quad (7)$$

式中:  $\bar{x}$  为水分天平  $n$  次称重结果平均值;  $\sigma(x)$  为测量数据组的标准差;  $\alpha$  为显著性水平。即采用格拉布斯方法判

定异常数据出现误判的几率, 临界值  $g(n, \alpha)$  可查表获得。

### 1.3 水分天平零点误差 LSTM 预测模型

水分天平零点误差是典型的时间序列, 利用历史数据, 可以对零点误差进行趋势预测。LSTM 网络通过引入门控机制改进普通循环神经网络的隐藏单元结构<sup>[17]</sup>, 选择性地加入新信息和遗忘信息, 有效解决了梯度消失等问题, 非常合适时间序列预测<sup>[18]</sup>。图 3 所示为零点误差 LSTM 预测模型。

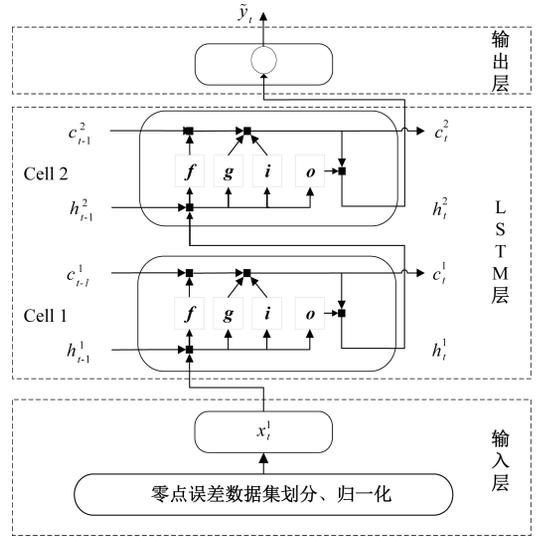


图 3 水分天平零点误差补偿的 LSTM 预测模型结构

Fig. 3 LSTM model's structure of compensating the zero error of moisture balance

如图 3 所示, 系统建立了一个由时间序列输入层、LSTM 层以及输出层组成的单输入单输出神经网络预测模型, 其中, 输出层由全连接神经网络构成。  $\mathbf{X} = [x_t^1, x_{t-1}^1, \dots, x_{(t-n)}^1]$  为模型的输入向量,  $\mathbf{X}$  代表  $t$  时刻前  $n$  个输入零点误差特征向量。将第  $t$  时刻的零点误差作为标签, 该模型在  $t$  时刻的输入为  $x_t^1$ , 输出为零点误差预测值  $\tilde{y}_t$ 。图 3 中, LSTM 层由两个细胞组成, 分别为 Cell 1 和 Cell 2。其中,  $h_{t-1}^1, h_{t-1}^2, c_{t-1}^1, c_{t-1}^2$  为 Cell 1 和 Cell 2 上一时刻隐藏状态和单元状态。由于 LSTM 预测模型为典型的自回归模型<sup>[19]</sup>, 因此将  $h_t^1$  作为 Cell 2 的输入。图 3 中, 变量关系如下:

$$i_t = \sigma(\mathbf{W}_i x_t + \mathbf{U}_i h_{t-1} + b_i) \quad (8)$$

$$f_t = \sigma(\mathbf{W}_f x_t + \mathbf{U}_f h_{t-1} + b_f) \quad (9)$$

$$\tilde{c}_t = \tanh(\mathbf{W}_c x_t + \mathbf{U}_c h_{t-1} + b_c) \quad (10)$$

$$o_t = \sigma(\mathbf{W}_o x_t + \mathbf{U}_o h_{t-1} + b_o) \quad (11)$$

$$c_t = f_t \cdot c_{t-1} + i_t \cdot \tilde{c}_t \quad (12)$$

$$h_t = o_t \cdot \tanh(c_t) \quad (13)$$

式中: 激活函数  $\sigma$  为 sigmoid 函数;  $h_{t-1}$  为上一时刻的隐藏层输出反馈;  $\mathbf{W}_i, \mathbf{W}_f, \mathbf{W}_o$  为连接输入  $x_t$  与细胞输入门、

遗忘门、输出门的权值矩阵;  $U_i$ 、 $U_f$ 、 $U_o$  为连接上一时刻输出与本细胞单元中输入门、遗忘门、输出门的权值矩阵;  $b_i$ 、 $b_f$ 、 $b_o$  为偏置值。

1) 利用上一时刻的外部状态  $h_{i-1}^1$  和当前时刻的输入  $x_i^1$ , 计算 Cell 1 内当前时刻 3 个门  $i_i^1$ 、 $f_i^1$  和  $O_i^1$  的向量及候选状态值  $\tilde{c}_i^1$ , 再更新记忆单元  $c_i^1$  并输出信息给隐藏层的外部状态  $h_i^1$ 。

2) 利用  $t$  时刻 Cell1 的外部状态  $h_i^1$  作为当前时刻 Cell 2 的输入, 重复式(8)~(13), 计算 Cell 2 内  $t$  时刻 3 个门  $i_i^2$ 、 $f_i^2$  和  $O_i^2$  的向量及候选状态值  $\tilde{c}_i^2$ , 再更新记忆单元  $c_i^2$  并输出信息给隐藏层的外部状态  $h_i^2$ 。

3) 利用全连接层将多维数组转换成一维, 此时零点误差预测值为:

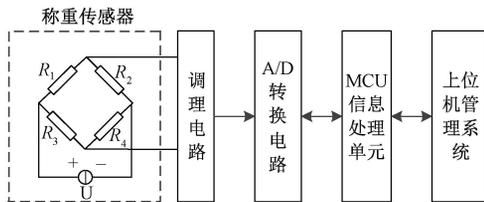
$$\tilde{y}_i = W_d h_i^2 + b_d \quad (14)$$

式中:  $W_d$ 、 $b_d$  为全连接层的权值矩阵与偏置值。

## 2 水分天平零点误差补偿实验与分析

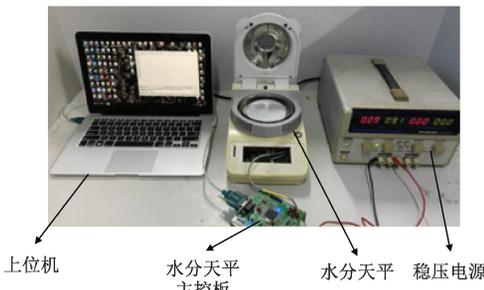
### 2.1 实验平台

根据水分天平零点误差补偿问题, 本文设计了以微处理器 STM32F407 为信息处理单元的水分天平及实验平台, 如图 4 所示。



(a) 水分天平称重模块框图

(a) Block diagram of moisture balance



(b) 实验平台

(b) Experimental platform

图 4 水分天平称重模块框图及实验平台

Fig. 4 Block diagram and experimental platform of moisture balance

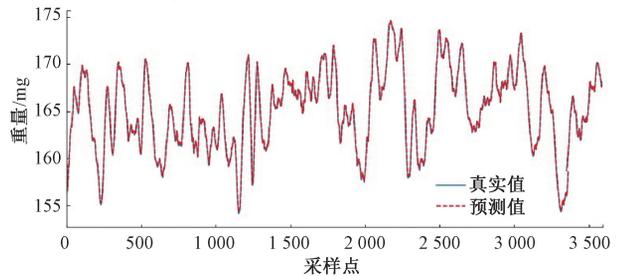
图 4(a) 为水分天平称重模型系统框图, 由应变式称重传感器、信号调理电路、模数转换电路(A/D)、微处理器模块、数据通信模块、电源电路等组成。称重传感器将

荷载重量转换成对应比例的模拟电信号, 经信号调理电路处理、A/D 模块转换成数字信号, 经信息处理单元处理后获得称重结果。图 4(b) 为项目组设计的水分天平及实验平台。该水分天平的质量称重范围为 200 g, 称重分辨率为 1 mg。

### 2.2 LSTM 预测模型训练与参数调试

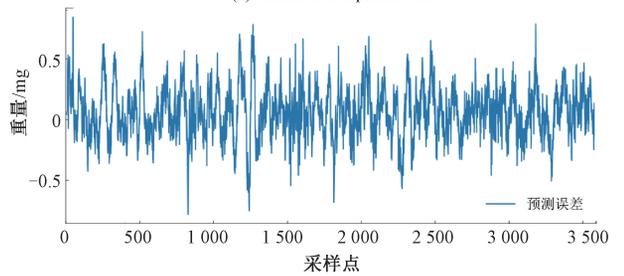
采集 18 000 个空载时水分天平的输出信号, 采用滑动窗口均值滤波, 得到预处理后的信息  $X$ ,  $X = (x_1, x_2, \dots, x_n)$ 。取前 80% 的数据作为训练样本, 剩下的 20% 作为测试样本。在 Jupyter Notebook 环境下, 搭建基于 Keras 的 LSTM 神经网络预测模型。为评估模型预测性能, 采用均方误差(MSE)、均方根误差(RMSE)和平均绝对误差(MAE)作为衡量预测性能的指标。将  $X$  作为 LSTM 预测模型的输入特征向量, 逐步训练并及时调整记忆单元各参数矩阵。最后, 将训练好的模型放入测试集进行测试, 对比预测值与实际值, 分析预测效果。为了更好地处理零点误差数据在小范围内发生的随机波动, 设置双层 LSTM 网络。使用 Dense 全连接层对 LSTM 层的输出进行线性整合, 选用 Adam 优化器, 经反复试验, 以 MSE、MAPE、RMSE 为评价指标, 通过大量实验发现, 当模型参数批量大小 batch\_size 为 256、迭代次数 epochs 为 100、学习率为 0.05、固定步长  $S=1$ 、两层 LSTM 的隐藏单元数均为 100 时, LSTM 预测模型效果最佳。将这些调优后的 LSTM 模型参数保存在 MCU 中, 为在线补偿准备。

图 5 所示为基于 LSTM 模型的水分天平零点预测效果。由图 5 可以看出, LSTM 模型能较好地预测零点误差, 预测误差小。



(a) 预测结果

(a) Result of the prediction



(b) 预测误差

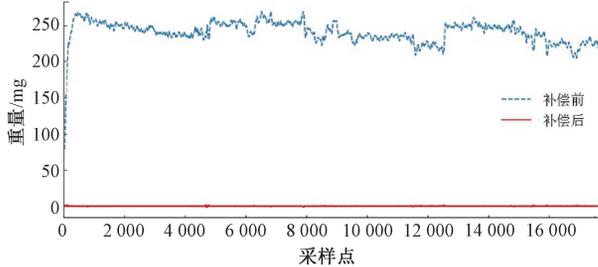
(b) Bias of the prediction

图 5 基于 LSTM 模型的水分天平零点误差预测结果

Fig. 5 Zero error of moisture balance with LSTM

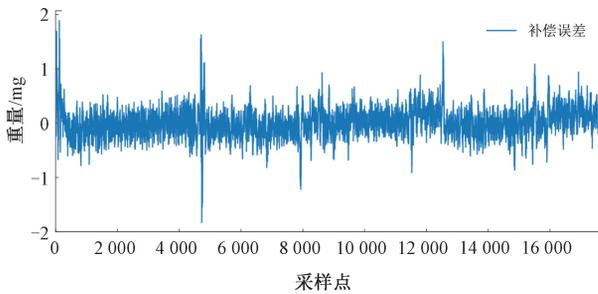
### 2.3 算法验证

利用调优训练后的 LSTM 预测模型对水分天平空载零点误差进行补偿仿真。采集水分天平空载时输出的 18 000 个初始零点值,预处理后将其输入 LSTM 预测模型,并进行零点误差补偿,补偿结果如图 6 所示。



(a) 空载时零点误差补偿前后对比

(a) Comparison before and after zero point error compensation without load

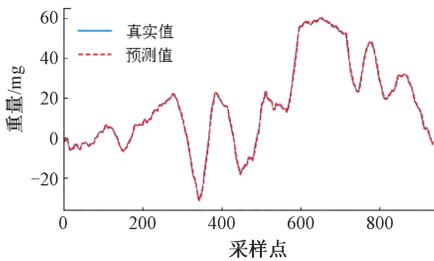


(b) 补偿后误差

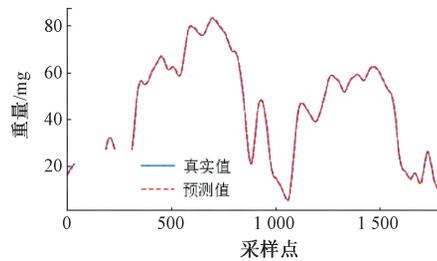
(b) Bias after compensation

图 6 空载时水分天平零点误差补偿结果及误差

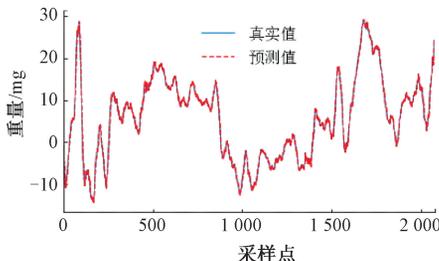
Fig. 6 Zero error of moisture balance with compensation and without compensation



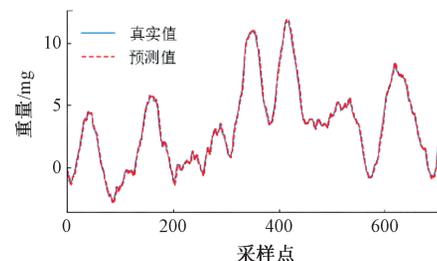
(a) 加载5 g砝码



(b) 加载50 g砝码



(c) 加载100 g砝码



(d) 加载200 g砝码

图 7 加载 5、50、100、200 g 砝码时  $X_{nl}$  真实值与预测值

Fig. 7 Comparison between real and predicted values of  $X_{nl}$  with 5, 50, 100 and 200 g weights, respectively

由图 6(a)、(b)可知,补偿前的水分天平具有较大的零点误差(由约为 250 mg 的偏置值和幅值约为 50 mg 的随机误差组成),补偿后,水分天平的绝大多数零点误差小于 2.0 mg,远小于补偿前的零点误差。

利用 LSTM 预测模型对加载不同载荷时的零点误差进行补偿。分别选取 10、50、100、200 g M1 级标准砝码加载,水分天平开机预热后,将标准砝码放置水分天平称托盘上,一段时间后拿开,模拟载荷加载与卸载。重复上述加载实验,直至这些标准砝码全部完成称量。根据式(5)将  $X_{nl}$  作为 LSTM 预测模型的输入,水分天平在加载 5、50、100、200 g 时  $X_{nl}$  的真实值与预测值如图 7 所示。由图 7 可以发现,无论加载载荷重量是多少,水分天平示值无规律飘动,即称重结果受到了零点误差的影响;利用 LSTM 预测模型,能够很好地完成水分天平零点误差预测。经基于 LSTM 预测模型的零点误差补偿后,如图 7 所示,水分天平称重示值稳定,随机波动现象大大减小(图 8),零点误差大大减少(图 9),说明零点误差得到了有效补偿。

### 2.4 零点误差补偿方法现场测试

以图 4 的水分天平为实验对象,将训练好的 LSTM 预测模型参数保存在微处理器 STM32F407 中。水分天平加载判决时,设置测量窗口大小为 15,置信度为 95%,即取  $n=15, \alpha=0.05$ 。此时查阅格拉布斯临界值参照表得到临界值参数  $g(n, \alpha) = 2.41$ ,将  $g(n, \alpha) = 2.41$  代入式(7),判断水分天平是否加载。

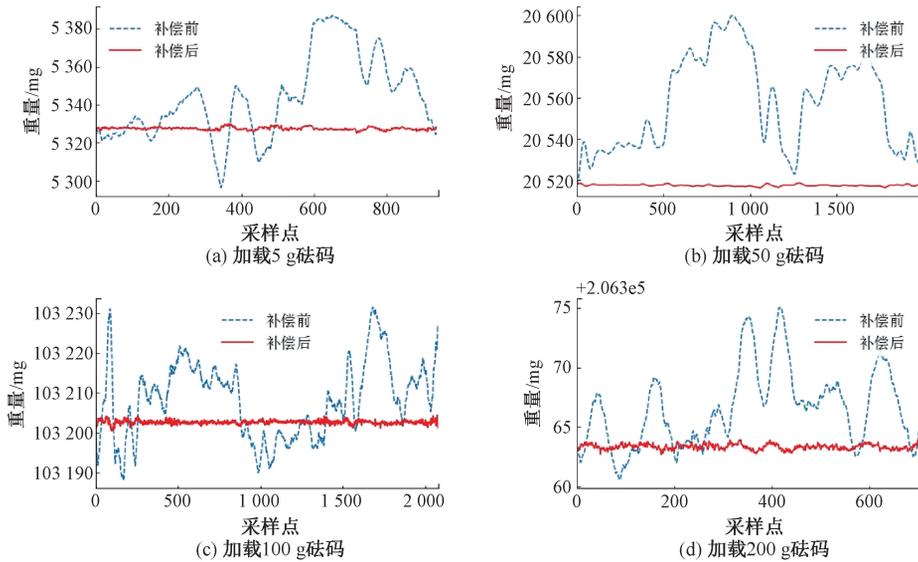


图 8 加载 5、50、100、200 g 砝码时补偿前与补偿后的水分天平称重结果

Fig. 8 Weighing results of moisture balance with 5, 50, 100 and 200 g weights

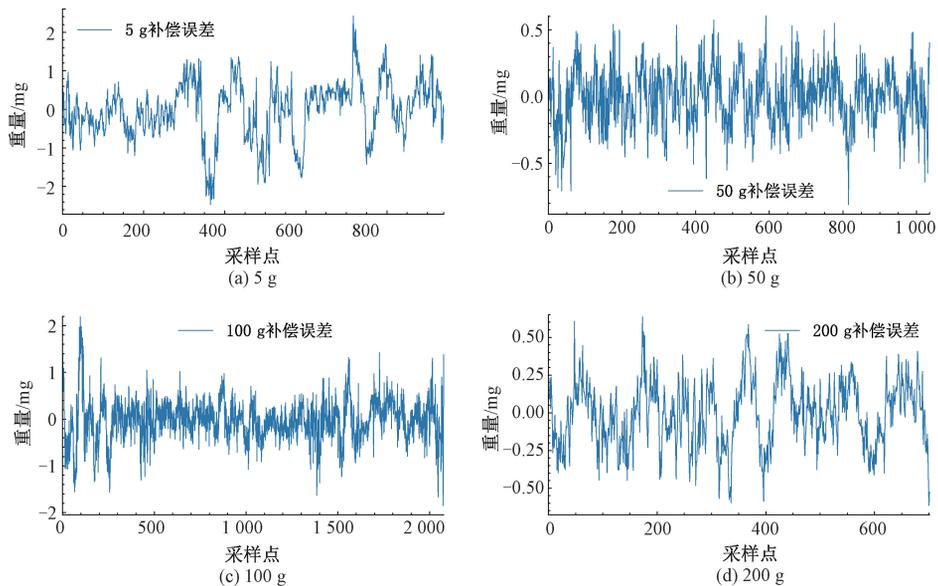


图 9 加载 5、50、100、200 g 砝码补偿后的零点误差值

Fig. 9 Zero error of the moisture balance with 5, 50, 100 and 200 g weights

1) 零点误差补偿测试

分别加载 5、50、100、200 g M1 级标准砝码,采用本文设计的基于 LSTM 模型零点误差补偿方法,记录空载与分别加载 5、50、100、200 g 时水分天平示值,利用线性插值法<sup>[20]</sup>进行水分天平非线性校正,校正后水分天平示值如表 1 所示。

由表 1 可知,非线性校正后的水分天平称重最大示值误差约为 6 mg,远小于补偿前的误差,证实了基于 LSTM 模型的水分天平零点误差补偿方法的有效性。

表 1 水分天平零点误差补偿结果

Table 1 Compensation results of zero error of moisture balance with LSTM

加载重量/g	补偿前示值/g	非线性校正后示值/g	示值误差/g
0	0.001 8	0.000 0	0.000 0
5	5.286 2	5.000 0	0.000 0
50	51.647	49.993 8	-0.006 2
100	103.164	100.001 6	0.001 6
200	206.180	200.000 0	0.000 0

2) 长时间加载时零点补偿测试

的称重显示值,并求出上述时间段内补偿前、后示值的标准偏差与均值,如表 2、3 所示。

为了测试长时间加载时水分天平零点漂移情况,分别记录水分天平加载稳定后的第 1、10、15、10、15 min 内

表 2 加载 5、50 g 水分天平称重示值标准偏差与均值

Table 2 Sample standard deviation and mean value with 5 and 50 g loads

测试时间	5 g				50 g			
	标准偏差/mg		均值/g		标准偏差/mg		均值/g	
	补偿前	补偿后	补偿前	补偿后	补偿前	补偿后	补偿前	补偿后
1 s	1.413 6	0.020 5	5.174 7	5.000 0	1.213 7	0.067 5	51.545 9	49.993 8
10 s	2.326 2	0.011 1	5.174 9	4.999 9	1.658 4	0.065 3	51.647 2	49.993 8
1 min	4.615 0	0.060 2	5.170 8	4.999 7	2.839 3	0.109 4	51.647 1	49.993 7
5 min	4.896 3	0.051 8	5.173 3	4.999 5	4.309 2	0.179 2	51.647 1	49.993 7
10 min	8.216 1	0.038 4	5.179 8	4.999 6	23.949 5	0.448 8	51.646 9	49.993 5
15 min	9.482 5	0.033 4	5.184 4	4.999 6	66.383 3	1.013 9	51.646 7	49.993 5

表 3 加载 100、200 g 水分天平称重示值标准偏差与均值

Table 3 Sample standard deviation and mean value with 100 and 200 g loads

测试时间	100 g				200 g			
	标准偏差/mg		均值/g		标准偏差/mg		均值/g	
	补偿前	补偿后	补偿前	补偿后	补偿前	补偿后	补偿前	补偿后
1 s	1.905 4	0.099 0	103.174 6	100.001 7	4.818 9	0.298 6	206.289 6	200.000 0
10 s	8.690 2	0.195 3	103.182 3	100.001 9	5.384 0	0.309 6	206.288 8	199.999 9
1 min	9.631 5	0.209 2	103.194 0	100.001 8	3.686 8	0.284 9	206.287 3	199.999 9
5 min	18.620 6	0.259 5	103.223 8	100.001 5	7.086 2	0.307 5	206.297 1	200.000 3
10 min	22.7.82	0.311 3	103.241 1	100.001 5	11.208 9	0.302 7	206.306 2	200.000 3
15 min	25.045 3	0.321 5	103.252 1	100.001 5	11.222 4	0.284 7	206.309 8	200.000 3

由表 2、3 可知,零点误差补偿后,在 15 min 之内,当加载 5、50、100、200 g M1 级标准砝码时,水分天平称重示值的变化均降低到 0.4 mg 以内,且各时间段内称重示值标准偏差大大减小,稳定在 1.1 mg 以内,零点漂移得到明显抑制。

3 结 论

为补偿水分天平零点误差,提出了基于 LSTM 模型的零点误差补偿方法,利用历史零点误差数据建立 LSTM 预测模型,补偿方法分为空载时补偿与加载时补偿两个部分。空载补偿时,以当前时刻空载信号作为 LSTM 预测模型输入,输出获得下一时刻零点误差预测值;加载补偿时,分解加载信号,并将分解后的信号作为 LSTM 预测模型输入,获得预测输出。实验结果表明,采用基于 LSTM 模型的零点误差补偿方法补偿后的水分天平,零点误差小、补偿效果好。

参考文献

[ 1 ] 高文龙. 一种快速水分测定的测定仪天平[ P ]: 中国,202020959254. 7, 2020-08-21.  
GAO W L, A measuring instrument balance for quick moisture determination [ P ]: China, 202020959254. 7,

2020-08-21.  
[ 2 ] SUN Y C, SONG Q L, ZHANG X F, et al. Simulating the properties of electric and thermal drift of the bridge offset of pressure sensors[ J]. Journal of Electron Devise, 2000, 267(11): 1468-1470.  
[ 3 ] 叶红霞. 220 g/0.1 mg 智能电子分析天平软件设计[ D ]. 长沙; 湖南大学, 2012.  
YE H X. Software design of 220g/0.1mg intelligent electronic analytical balance [ D ]. Changsha: Hunan University, 2012.  
[ 4 ] 黄强. 基于 DLS 的智能电子分析天平研究[ D ]. 长沙; 湖南大学, 2017.  
HUANG Q, Research on the intelligent electronic analytical balance based on DLS[ D ]. Changsha: Hunan University, 2017.  
[ 5 ] 刘亚坤, 黄强, 李建闽, 等. 基于 SVM 的电子分析天平温度漂移补偿方法[ J ]. 计量学报, 2018, 39(06): 826-831.  
LIU Y K, HUANG Q, LI J M, et al. Temperature drift compensation method for electronic analytical balance based on support vector machine[ J ]. Acta Metrologica Sinica, 2018, 39(06): 826-831.  
[ 6 ] 李菲, 滕召胜, 黄强, 等. 基于梯度变步长 LMS 的电

- 子天平抗震设计[J]. 仪器仪表学报, 2016, 37(12): 2813-2820.
- LI F, TENG ZH SH, HUANG Q, et al. Shock resistant design for electronic balance based on gradient variable step size LMS algorithm[J]. Chinese Journal of Scientific Instrument, 2016, 37(12): 2813-2820.
- [7] 陈安民, 张春元, 张泽林. 基于长短期记忆网络的无人机认知无线电频谱预测[J]. 国外电子测量技术, 2021, 40(1): 37-43.
- CHEN AN M, ZHANG CH Y, ZHANG Z L. UAV cognitive radio spectrum prediction based on long short-term memory network [J]. Foreign Electronic Measurement Technology, 2021, 40(1): 37-43.
- [8] 魏昱洲, 许西宁. 基于 LSTM 长短期记忆网络的超短期风速预测[J]. 电子测量与仪器学报, 2019, 33(2): 64-71.
- WEI Y ZH, XU X N, Ultra-short-term wind speed prediction model using LSTM networks [J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(2): 64-71.
- [9] 崔粟晋, 王雪. 基于长短时记忆太阳能无线传感节点能量预测[J]. 仪器仪表学报, 2018, 39(11): 147-154.
- CUI S J, WANG X. Solar wireless sensor node energy prediction based on long-short term memory[J]. Chinese Journal of Scientific Instrument, 2018, 39(11): 147-154.
- [10] SUN B, TENG Z, HU Q. A novel LMS-based SANC for conveyor belt-type checkweigher [J]. IEEE Transactions on Instrumentation and Measurement, 2020, 65(3): 1-10.
- [11] 林海军, 王震宇, 林亚平, 等. 基于导数约束的称重传感器非线性误差补偿方法[J]. 传感技术学报, 2013, 26(11): 1537-1542.
- LIN H J, WANG ZH Y, LIN Y P, et al. Method for Compensation of Load Cell's Nonlinear Error based on derivatives constraints [J]. Chinese Journal of Sensors and Actuators, 2013, 26(11): 1537-1542.
- [12] LEE S G, MOON Y S, SON W H, et al. Silicon strain gauge load cell for weighting disdrometer [J]. Journal of Sensor Science and Technology, 2013, 22(5): 321-326.
- [13] YU J B. Adaptive hidden Markov model-based on QMF analysis [J]. Journal of Detection & Control, 2017, 29(4): 83-89.
- [14] CHATTERJEE K, MAHATO S N, CHATTOPADHYAY S. Weighing system by load cell response rectification method [J]. International Journal on Measurement Technologies & Instrumentation Engineering, 2012, 2(3): 34-44.
- [15] CHEN Z W, ZHANG Z, DONG F. A hybrid finite element modeling: Artificial neural network approach for predicting solder joint fatigue life in wafer-level chip scale packages [J]. Journal of Electronic Packaging, 2021, 143(1): 256-264.
- [16] GRUBBS FRANK E. Sample criteria for testing outlying observations [J]. The Annals of Mathematical Statistics, 1950, 21(1): 27-58.
- [17] ISLAM T, SAHA H. Study of long-term drift of a porous silicon humidity sensor and its compensation using ANN technique [J]. Sensors and Actuators, 2006, 133(1): 472-479.
- [18] IAN G, YOSHUA B, AARON C, et al. Deep learning [M]. London: The MIT Press, 2016.
- [19] CHENG M, XU Q, LV J M, et al. MS-LSTM: A multi-scale LSTM model for BGP anomaly detection [C]. IEEE International Conference on Network Protocols, 2016: 1-6.
- [20] 林海军, 王震宇, 林亚平, 等. 基于导数约束的称重传感器非线性误差补偿方法 [J]. 传感技术学报, 2013, 26(11): 1537-1542.
- LIN H J, WANG ZH Y, LIN Y P, et al. Method for compensation of load cell's nonlinear error based on derivatives constraints [J]. Chinese Journal of Sensors and Actuators, 2013, 26(11): 1537-1542.

## 作者简介



毛翊涵, 2019 年于湖南师范大学学院获得学士学位, 现为湖南师范大学硕士研究生, 主要研究方向为智能检测与机器学习。

E-mail: 727155554@qq.com

**Mao Yihan** received her B. Sc. degree from Hunan Normal University in 2019. Now she is a M. Sc. candidate at Hunan Normal University. Her main research interests include intelligent detection and machine learning.