

DOI: 10.13382/j.jemi.B2306190

基于 Kalman-LSTM 模型的悬浮质含沙量测量^{*}

邓罗晟 车国霖 金建辉

(昆明理工大学信息工程与自动化学院 昆明 650500)

摘 要:针对电容法测量河流含沙量过程中易受环境因素影响而导致测量结果不准确的问题,提出基于卡尔曼滤波和长短期记忆神经网络(Kalman-LSTM)的融合模型。先采用卡尔曼滤波器进行滤波处理,减小传感器测量的随机误差;再通过 LSTM 神经网络模型对含沙量信息和环境量信息进行多传感器数据融合,减小环境因素对电容法测量含沙量的影响;最后建立了电容法测量含沙量的 Kalman-LSTM 融合模型。为了验证 Kalman-LSTM 融合模型的融合效果,与 BP 模型、RBF 模型和 LSTM 模型对比,比较各模型的均方根误差、最大绝对误差、平均绝对误差和平均相对误差。实验结果表明,Kalman-LSTM 融合模型的平均相对误差为 2.54%,均方根误差为 2.47 kg/m³,该融合模型能有效降低环境因素对含沙量测量的影响,提高电容法测量含沙量的准确性。

关键词: 电容法;含沙量;Kalman 滤波;LSTM;多传感器数据融合

中图分类号: TN98;TV149 **文献标识码:** A **国家标准学科分类代码:** 510.40

Measurement of suspended sediment concentration based on Kalman-LSTM modle

Deng Luosheng Che Guolin Jin Jianhui

(School of Information Engineering and Automation, Kunming University of Science and Technology, Kunming 650500, China)

Abstract: In order to solve the problem of inaccurate measurement results due to environmental factors while measuring the sediment concentration of rivers with the capacitance method, a fusion model based on Kalman filtering and LSTM (Kalman-LSTM) is proposed. Firstly, the Kalman filtering is used for filtering to reduce the random error of sensor measurement. Then, the LSTM was used to integrate multi-sensor data of sediment content information and environmental content information, to reduce the influence of environmental factors on sediment content measurement by the capacitance method. Finally, a Kalman-LSTM fusion model for measuring sediment concentration by capacitance method was developed. To verify the fusion effect of the Kalman-LSTM fusion model, the root mean square error, maximum absolute error, average absolute error, and average relative error of each model are compared with the BP model, the RBF model, and the LSTM model. The experimental results show that the average relative error of the Kalman-LSTM fusion model is 2.54% and the root mean square error is 2.47 kg/m³. The fusion model can effectively reduce the influence of environmental factors on sediment concentration measurement and improve the accuracy of sediment concentration measurement by the capacitance method.

Keywords: capacitance sensor; suspended sediment concentration; Kalman filtering; LSTM; multi-sensor data fusion

0 引 言

我国河流众多,水土流失严重,水土流失会导致土地退化,毁坏耕地;削弱生态系统的调节功能,对生态安全

和饮水安全构成严重威胁。径流泥沙是衡量土壤侵蚀的重要参数之一,可为土壤侵蚀动力过程的模拟与研究、土壤侵蚀预报模型的建立等提供基础资料,为水土流失的监测、防治等提供科学依据^[1]。

目前常见的河流含沙量测量方法^[2-3]可分为直接测

量方法和间接测量方法。直接测量方法包括:烘干称重法和置换法,间接测量方法包括:光学法、声学法、振动法、同位素法、电容法等。烘干称重法是最直接、最原始的方法,也是应用最广泛的测量含沙量的方法,其设备简单、方法易行、精度较高,其结果常被作为评价其他方法的标准。但测量周期长,过程繁琐,无法实现对泥沙含量的实时在线测量。为了克服传统方法的缺点^[4],曾为军等^[5]提出了一种基于计时法和光照法的径流量与含沙量测量方法,验证了光照法测量含沙量的可行性;Huang 等^[6]研制了盐度测量仪和光纤含沙量测量仪,研究了盐度与含沙量之间的相互影响,提高了盐度与含沙量同步测量的精度。超声反射法利用超声波在水体传播时遇到沙产生反射波和衰减来测量水中含沙量^[7],Moore 等^[8-9]利用超声波反向散射信号的幅度对悬浮含沙量进行估值,Fleri 等^[10]利用 ADCP 来估算入海口处含沙量,王仲明等^[11]利用超声成像技术获得泥沙图像,通过建立成像灰度值和含沙量的关系来测量泥沙含量。Zhang 等^[12]利用 X 射线来测量水中含沙量,李德贵等^[13]研制了一种同位素测沙仪利用 γ 射线穿过含沙水流时的衰减情况进行含沙量测量。

烘干称重法测量周期长,过程繁琐;光学法受介质颜色和粒径影响大,测量范围窄,成本高;声学法成本价格昂贵,测量范围小;振动法受水速影响较大,在水速过低时会堵振动管;同位素法由于放射源辐射问题无法推广使用。电容测沙构造简单,造价成本低,使用安全且响应速度快,但电容法测量含沙量的过程中容易受环境影响而导致测量结果不准确,因此如何减小环境因素对电容法测量值的干扰是研究电容法测沙的关键性问题。针对以上问题,Liu 等^[14-15]采用 BP 网络的非线性拟合能力和 IGA-RBF 模型的全局逼近能力来消除温度对电容传感器测量含沙量的影响,以提高测量准确性。但以上方法未考虑到含沙量 and 环境信息的历史数据对当前数据的影响,忽略了历史测量数据与当前数据的相关性。因此,本文采用的 LSTM 网络加强序列数据间的相关性,有效提升测量精度,实现了含沙量的动态实时测量。

卡尔曼滤波是线性随机动态系统的最优递推数据处理算法,在对监测数据的噪声剔除方面具有良好的效果。长短期记忆网络是一种改进的递归神经网络,适用于序列数据的实时处理。为了加强序列数据间的相关性,利用含沙量 and 环境因素的历史数据,跟踪测量系统的动态特性,提出了基于卡尔曼滤波和长短期记忆网络 (Kalman-LSTM) 的融合模型,首先采用卡尔曼滤波器对多传感器输出值进行滤波,减小测量的随机误差;然后将电容、温度和电导率等测量信息与含沙量进行长短期记忆网络多源数据融合处理,进一步消除环境因素对含沙量测量的影响,提高含沙量测量准确性。

1 系统设计

泥沙和水这两种物质具有不同的介电常数,利用不同浓度的泥沙与水的混合物引起介电常数变化的物理特性,通过电容传感器将浑水的含沙量变化转化为电容量变化,从而达到测量浑水含沙量的目的^[16]。本实验中采取平行式极板电容传感器,其结构示意图如图 1 所示。其极板间电容为:

$$C = \frac{\epsilon S}{d} \tag{1}$$

式中: C 为极板间电容值, ϵ 为极板间介质的介电常数, S 为极板的相对面积, d 为极板间距。当浑水含沙量发生变化时,其介电常数也会发生变化,进而导致极板间电容量的变化。因此,可以通过测量极板电容量来测量浑水的含沙量。




图 1 平行式极板电容传感器结构

Fig. 1 Structure diagram of a parallel pole plate capacitive sensor

本实验采用 FDC2214 芯片作为电容测量芯片,该芯片采用抗电磁干扰架构,加强了在高噪声环境下的稳定性,28 位的高分辨率和最高可达 4.08 ksp/s 的采样频率提高了测量精度与采样速度。为了研究环境因素对电容传感器测量值的影响,还加入了温度传感器、电导率测试仪、加热装置等辅助设备,系统硬件搭建示意图如图 2 所示。




图 2 系统硬件结构

Fig. 2 Structure diagram of system hardware

实验容器为 150 mm×50 mm×110 mm 的水槽,电容板由两块 150 mm×100 mm×1 mm 的紫铜板构成,分别置于水槽两侧。使用 FDC2214 芯片采集两极板的电容值,STM32F103 作为系统控制单元,温度传感器采集水体温度,电导率检测仪采集水体的电导率,加热装置调节水体的温度。

2 研究方法

2.1 数据预处理

在传感器采集电容值、温度和电导率数据的过程中,由于采样频率较高,采样点较多,随着测量时间推移,采样数据越来越庞大,不可避免的存在异常数据。数据异常值产生的原因一般有 3 个方面:1) 设备原因,测量设备在运行过程中有元件损坏,测量结果将出现异常值;2) 人为原因,在测量过程中由于人为操作失误等产生异常值;3) 环境原因,由于测量环境中存在的电磁干扰造成测量结果的数据失真产生异常值。数据异常值一般明显偏离它所属样本的其余观测值,极大地降低了观测数据的准确性,因此在进行数据分析研究前,需要进行异常值的识别和剔除。

结合测量数据庞大的特点,利用拉依达准则来识别测量数据的异常值。判断方法如下:

$$x_i = \begin{cases} \text{正常值}, & |x_i - \bar{x}| \leq 3\sigma \\ \text{异常值}, & |x_i - \bar{x}| > 3\sigma \end{cases} \quad (2)$$

式中: $\bar{x}$ 指测量数据的平均值, σ 指测量数据的标准差。

将识别出的异常值剔除后会造成部分数据的缺失,为保证数据的完整性和稳定性,需补齐缺失数据。利用线性插值法原理计算得到新的估算值来对数据的异常值进行修正补充,以保证数据的完整性。

2.2 卡尔曼滤波

卡尔曼滤波是一种最优化的自回归的数据处理算法,可以依据上一时刻的状态估计值和当前时刻的观测值,对当前的状态值进行滤波估计得到最优估计值。本文用它来解决传感器测量过程中的估计问题,减小传感器测量的随机误差。一个离散的线性状态方程和观测方程如下:

$$\mathbf{x}(k) = \mathbf{A}\mathbf{x}(k-1) + \mathbf{w}(k-1) \quad (3)$$

$$\mathbf{y}(k-1) = \mathbf{H}\mathbf{x}(k-1) + \mathbf{v}(k-1) \quad (4)$$

式中: $\mathbf{x}(k)$ 为状态向量, $\mathbf{y}(k)$ 为观测向量; $\mathbf{A}$ 为状态矩阵, $\mathbf{H}$ 为观测矩阵; $\mathbf{w}(k)$ 为系统噪声, $\mathbf{v}(k)$ 为观测噪声。 $\mathbf{w}(k)$ 和 $\mathbf{v}(k)$ 为互不相关的零均值白噪声序列。

本文采用的卡尔曼滤波计算步骤如下:

1) 预测部分:

$$\hat{\mathbf{x}}(k/k-1) = \mathbf{A}\mathbf{x}(k-1/k-1) \quad (5)$$

$$\mathbf{P}(k/k-1) = \mathbf{A}\mathbf{P}(k-1/k-1)\mathbf{A}^T + \mathbf{Q}(k) \quad (6)$$

式中: $\hat{\mathbf{x}}(k/k-1)$ 为 k 时刻的先验估计值, $\mathbf{x}(k-1/k-1)$ 为 $k-1$ 时刻的状态估计值, $\mathbf{P}(k/k-1)$ 为 k 时刻的预测协方差矩阵, $\mathbf{P}(k-1/k-1)$ 为 $k-1$ 时刻的误差协方差矩阵, $\mathbf{Q}(k)$ 为 k 时刻的系统噪声的协方差矩阵。

2) 更新部分:

$$\mathbf{K}(k) = \mathbf{P}(k/k-1)\mathbf{H}^T[\mathbf{H}\mathbf{P}(k/k-1)\mathbf{H}^T + \mathbf{R}(k)]^{-1} \quad (7)$$

$$\hat{\mathbf{x}}(k) = \hat{\mathbf{x}}(k/k-1) + \mathbf{K}(k)[\mathbf{y}(k) - \mathbf{H}\hat{\mathbf{x}}(k/k-1)] \quad (8)$$

$$\mathbf{P}(k/k) = [\mathbf{I} - \mathbf{K}(k)\mathbf{H}]\mathbf{P}(k/k-1) \quad (9)$$

式中: $\mathbf{K}(k)$ 为 k 时刻的卡尔曼增益, $\mathbf{R}(k)$ 为 k 时刻的观测噪声的协方差矩阵, $\hat{\mathbf{x}}(k)$ 为 k 时刻的状态估计值, $\mathbf{P}(k/k)$ 为 k 时刻的误差协方差矩阵。

将更新后的状态估计 $\hat{\mathbf{x}}(k)$ 和误差协方差矩阵 $\mathbf{P}(k/k)$ 再代入 $k+1$ 时刻进行卡尔曼滤波估计,以此递推计算实现整个序列的滤波。

2.3 长短期记忆网络

长短期记忆网络(long short-term memory, LSTM)能够有效解决传统循环神经网络(recurrent neural network, RNN)的长期依赖和梯度爆炸、消失问题。在 LSTM 元胞内部,存在的门限结构主要包含输入门、遗忘门和输出门^[17],它们相互协调配合,控制着信息流入和流出细胞状态的能力。LSTM 神经网络结构如图 3 所示。




图3 LSTM 神经网络结构

Fig. 3 Structure diagram of LSTM neural network

h_{t-1} 是上一时刻的含沙量输出, x_t 是当前时刻的电容值、温度和电导率组成的输入, h_t 是当前时刻的含沙量输出。遗忘门 f_t 决定上一时刻细胞状态 C_{t-1} 被遗忘的程度,取值范围在 0~1 之间,其中 1 表示“完全保留上个状态”,0 表示“完全遗忘上个状态”。输入门 i_t 和中间细胞状态 $\tilde{C}_t$ 共同决定当前时刻输入信息如何更新到细胞状态中, C_t 表示当前时刻更新后的细胞状态。输出门限 o_t

决定当前时刻细胞状态需要输出的部分, h_t 表示当前时刻的最终输出。LSTM 神经网络计算过程如下:

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

（10）

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

（11）

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

（12）

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

（13）

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

（14）

$$h_t = o_t * \text{Tanh}(C_t)$$

（15）

式中: $W_f, b_f, W_i, b_i, W_c, b_c, W_o, b_o$ 分别为遗忘门、输入门、中间输出和输出门的权重矩阵和偏置, $\sigma(\cdot)$ 为 Sigmoid 激活函数, $\text{Tanh}(\cdot)$ 为 Tanh 激活函数, $*$ 为哈达玛乘积。




图 4 Kalman-LSTM 融合模型

Fig. 4 Fusion model of Kalman-LSTM

3 结果分析

实验土样为采自学校校园的沙壤土,实验水样为民用自来水,将土样和水配制成含沙量(土壤质量/浑水体积×100%)为 0, 20, 40, 60, 80, …, 280, 300 kg/m³ 共 16 组浑水混合物。实验时将不同含沙量的浑水分别加热到 5℃、10℃、20℃、30℃ 一共 4 种温度条件下,将电容传感器、温度传感器和电导率测试仪探头浸入悬浮液中,测量电容值、水温和电导率。本实验共采集了 12 800 组实验数据。

3.1 电容值、电导率和温度与含沙量分析

从实验数据中可以得到电容传感器测量极板电容值与含沙量的关系如图 5 所示,实验表明在相同温度条件下,随着含沙量的增加,电容传感器测量极板电容值减小,电容值与含沙量具有较好的线性关系;在相同含沙量条件下,随着温度升高,电容传感器测量极板电容值增加。电导率与含沙量的关系如图 6 所示,实验表明在相同温度条件下,随着含沙量的增加,浑水电导率增加,电导率与含沙量具有较好的线性关系;对于相同含沙量条件下,随着温度升高,电导率增加。

3.2 异常值识别与修正效果分析

实验选取传感器在某段时间内采集到含有异常值的

2.4 Kalman-LSTM 融合模型

Kalman-LSTM 融合模型由 Kalman 滤波器和 LSTM 神经网络模型组成,如图 4 所示。电容传感器、温度传感器和电导率测试仪采集被测水体的电容数据、水温数据和电导率数据,将采集数据通过拉依达准则和线性插值法进行数据预处理,达到识别并修正异常值的目的,然后将修正后的数据送入 Kalman 滤波器中进行最优估计,减小测量误差。最后将得到的电容估计值、温度估计值和电导率估计值作为 LSTM 神经网络的输入,含沙量作为 LSTM 神经网络的输出,对 LSTM 神经网络训练后,网络可以根据输入的电容值、温度和电导率做出含沙量的预测,实现通过电容值测量含沙量的目的。




图 5 电容与含沙量的关系

Fig. 5 Diagram of relationship between capacitance and sediment concentration

100 个电容数据作为样本对象,采用拉依达准则和线性插值法对样本进行异常值识别与修正。异常值的数据识别与修正对比图如图 7 所示,图 7(a)中序号 23 和 76~80 的样本为异常值。实验结果表明,拉依达准则算法能够成功识别数据中的异常值,并采用线性插值法将异常值修正到正常范围内。数据预处理去除了含有粗大误差的异常值,增加了样本数据的可靠性,提高了实验样本的可信度。






图6 电导率与含沙量的关系

Fig. 6 Diagram of relationship between electrical conductivity and sediment concentration



(a) 异常值修正前

(a) Before the outlier correction



(b) 异常值修正后

(b) After the outlier correction

图7 异常值数据修正前后对比

Fig. 7 Comparison of before and after correction of outliers

3.3 卡尔曼滤波效果分析

经过预处理后的传感器输出数据送入 Kalman 滤波器进行最优估计,其卡尔曼滤波效果图如图 8 所示。图中只截取了实验数据中的 200 个滤波数据,从图 8 中可以看出,由于测量过程种存在随机误差,电容传感器输出值在真值附近呈周期性变化,具有明显的波动现象。经过 Kalman 滤波器滤波后,电容传感器输出值的 Kalman

估计值的波动明显减小,提高了电容传感器输出数据的稳定性与准确性,实验结果表明滤波效果较好。




图8 卡尔曼滤波效果图

Fig. 8 Effect of Kalman filtering

3.4 对比实验

1) 评价指标

本实验使用最大绝对误差 (MaxAE)、平均绝对误差 (MAE)、平均相对误差 (MRE) 和均方根误差 (RMSE) 作为模型的评价指标,来量化模型预测准确性^[18-19],式 (16)~(19) 为各类误差的数学表达式:

$$\text{MaxAE} = \max_{1 \leq i \leq n} |p_i - x_i| \quad (16)$$

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |p_i - x_i| \quad (17)$$

$$\text{MRE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{p_i - x_i}{x_i} \right| \times 100\% \quad (18)$$

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (p_i - x_i)^2} \quad (19)$$

其中, p_i 为训练模型第 i 序列的预测值, x_i 为训练集第 i 序列的真实值, n 为训练集的样本组个数。

2) LSTM 参数寻优的误差分析

影响 LSTM 模型预测效果的模型参数有隐藏节点数、迭代次数和学习率等,通过对 LSTM 的参数进行优化调节,提高模型预测准确性^[20]。模型参数寻优如表 1 所示,从实验样本中选取 2 400 组作为验证集数据,调节隐藏节点数、迭代次数和学习率,进行 30 次参数寻优实验,比较均方根误差来寻找模型的最优参数。

通过表 1 可以看出,当固定迭代次数和学习率时,随着隐藏节点数的增加,模型预测结果的均方根误差先降低后增加,在隐藏节点数为 20 时达到最好预测效果;当固定隐藏节点数和学习率时,随着迭代次数增加,模型预测结果的均方根误差逐渐减小,同时训练时间会随之增加,当迭代次数超过 150 后,迭代次数增加,模型预测结果的均方根误差没有明显下降,但训练时间明显增长,为

表 1 不同参数条件下实验结果的均方根误差

Table 1 Root mean square error of experimental results under different parameter conditions

参数	实验组									
	1	2	3	4	5	6	7	8	9	10
隐藏节点数	5	10	15	20	25	30	35	40	15	15
迭代次数	150	150	150	150	150	150	150	150	50	75
学习率	0.01	0.01	0.01	0.01	0.01	0.01	0.01	0.01	0.01	0.01
均方根误差	3.200	2.535	2.368	2.271	2.303	2.535	2.455	2.475	3.990	2.998

参数	实验组									
	11	12	13	14	15	16	17	18	19	20
隐藏节点数	15	15	15	20	20	20	20	20	20	25
迭代次数	100	125	200	50	75	100	125	200	300	100
学习率	0.01	0.01	0.01	0.01	0.01	0.01	0.01	0.01	0.01	0.01
均方根误差	2.58	2.719	2.347	3.559	2.966	2.812	2.5	2.44	2.33	3.244


参数	实验组									
	21	22	23	24	25	26	27	28	29	30
隐藏节点数	25	20	20	20	20	20	20	20	20	20
迭代次数	200	100	150	100	150	100	150	100	150	200
学习率	0.01	0.1	0.1	0.05	0.05	0.005	0.005	0.001	0.001	0.001
均方根误差	2.291	3.42	2.473	2.972	2.408	2.862	2.413	8.332	5.044	4.506

了兼顾预测准确性和模型训练速度两个性能指标,模型的迭代次数设置为 150;当固定隐藏节点数和迭代次数时,通过调节学习率发现,学习率过大会使训练值在最优值附近来回震荡而无法收敛;学习率太小会导致收敛速度过慢,训练时间太长;选择合适的学习率以保证训练模型不会产生震荡并能快速收敛,学习率设置为 0.01 时,模型的收敛效果较好。


3) 误差对比

本实验选取 7 200 组实验数据作为训练集,2 400 组实验数据作为测试集,分别采用 BP、RBF、LSTM 和 Kalman-LSTM 模型进行预测实验,对比分析各模型的平均绝对误差、平均相对误差、最大绝对误差和均方根误差。LSTM 模型参数设置如下:隐藏节点数为 20,迭代次数为 150,学习率为 0.01。各模型的误差对比如图 9 所示,由图 9(a)和(b)可以看出,随着含沙量的增加,LSTM 和 Kalman-LSTM 的平均绝对误差都在 0.5~4.0 kg/m³ 范围内,而 BP 模型的平均绝对误差基本都在 2.5 kg/m³ 以上,在低含沙量条件下的平均绝对误差最高达到 11.17 kg/m³,说明在 0~300 kg/m³ 量程范围内,LSTM 和 Kalman-LSTM 具有更好的预测性能;由图 9(c)和(d)可知,RBF 的最大绝对误差超过 50 kg/m³,BP 的最大绝对误差接近 20 kg/m³,Kalman-LSTM 的最大绝对误差不超过 10 kg/m³,BP 在整个测量范围下均方根误差最大,Kalman-LSTM 整体均方根误差最小,说明 Kalman-LSTM 融合模型的预测结果准确度和稳定性最好,可信度最高;随着含沙量的增加,Kalman-LSTM、LSTM、RBF 和 BP 模

型的平均相对误差均减小,说明本文的电容法更适合用于较高含沙量水体的测量。



(a) 模型平均绝对误差对比
(a) Comparison of the mean absolute error of the models



(b) 模型平均相对误差对比
(b) Comparison of the mean relative error of the models

表 2 不同网络模型的误差对比

Table 2 Comparison of errors of different network models

误差类型	网络模型类型			
	BP	RBF	LSTM	Kalman-LSTM
MaxAE/(kg·m ⁻³)	19.814	54.886	11.919	8.499
MAE/(kg·m ⁻³)	4.186	1.121	2.002	1.982
MRE/%	6.552	1.813	2.921	2.542
RMSE/(kg·m ⁻³)	5.599	3.156	2.589	2.470

悬移质含沙量。本文在含沙量范围为 0~300 kg/m³、温度范围为 5℃~30℃ 的实验条件下,对比 Kalman-LSTM 神经网络融合模型、LSTM 神经网络模型、BP 神经网络模型和 RBF 神经网络模型的数据融合效果,Kalman-LSTM 融合模型的均方根误差最小,预测效果最好。实验结果表明,Kalman-LSTM 融合模型既能通过 Kalman 滤波器对传感器输出值进行最优估计,减小了传感器测量过程中的随机误差,又能通过 LSTM 神经网络将含沙量信息与电容值、温度、电导率等环境信息进行数据融合,降低了温度对电容法测量含沙量的影响,提高了电容法测量含沙量的稳定性和准确性。

参考文献


[1] 展小云,曹晓萍,郭明航,等. 径流泥沙监测方法研究现状与展望[J]. 中国水土保持,2017(6):13-17.
ZHAN X Y, CAO X P, GUO M H, et al. Status and prospects of research on runoff sediment monitoring methods[J]. Soil and Water Conservation in China, 2017(6):13-17.

[2] RAI A K, KUMAR A. Continuous measurement of suspended sediment concentration; Technological advancement and future outlook [J]. Measurement, 2015, 76: 209-227.


[3] FELIX D, ALBAYRAK I, BOES R M. Continuous measurement of suspended sediment concentration; Discussion of four techniques[J]. Measurement, 2016, 89: 44-47.

[4] 范少英,胡光乾,张冉,等. 基于置换法解决含沙量实时监测问题的研究[J]. 人民黄河,2021,43(S1):9-10.
FAN SH Y, HU G Q, ZHANG R, et al. Research on the solution of real-time sediment concentration monitoring based on the replacement method[J]. Yellow River, 2021, 43(S1):9-10.

[5] 曾为军,张云伟,陈岭,等. 基于计时与光照法的坡面径流量及含沙量动态检测系统[J]. 农业工程学报,2014,30(24):114-123.
ZENG W J, ZHANG Y W, CHEN L, et al. Dynamic measured system for hillslope runoff rate and sediment concentration based on time method and illumination method[J]. Transactions of the Chinese Society of Agricultural Engineering, 2014, 30(24):114-123.



(c) 模型最大绝对误差对比
(c) Comparison of the maximum absolute error of the models



(d) 模型均方根误差对比
(d) Comparison of the root mean square error of the models

图 9 各模型的误差对比

Fig.9 Comparison of the errors of the models

在相同实验条件下,不同网络模型的误差对比如表 2 所示,Kalman-LSTM 融合模型的均方根误差为 2.470 kg/m³,平均绝对误差为 1.982 kg/m³,平均相对误差为 2.542%,表明 Kalman-LSTM 融合模型的预测效果优于 LSTM 模型;Kalman-LSTM 融合模型在均方根误差、平均相对误差和平均绝对误差等评价指标上都明显优于 BP 模型;Kalman-LSTM 融合模型相比于 RBF 模型,Kalman-LSTM 融合模型的最大绝对误差为 8.499 kg/m³,均方根误差为 2.470 kg/m³,表明 Kalman-LSTM 融合模型在整个量程范围内的预测结果的准确性和稳定性要优于 RBF 模型。Kalman-LSTM 融合模型结合了 Kalman 滤波对线性随机动态数据的最优估计和 LSTM 对长序列数据的非线性拟合能力,预测准确性和稳定性好,泛化能力和可信度高。

4 结 论

本文将 Kalman 滤波和 LSTM 神经网络相结合,提出了 Kalman-LSTM 神经网络融合模型,应用于电容法测量

- [6] HUANG R, ZHANG Q, ZHANG W, et al. Mutual influences between synchronous measurement of salinity and sediment concentration [J]. *Measurement*, 2021, 178: 109409.
- [7] HAY A E, ZEDEL L, CHEEL R, et al. On the vertical and temporal structure of flow and stress within the turbulent oscillatory boundary layer above evolving sand ripples [J]. *Continental Shelf Research*, 2012, 46: 31-49.
- [8] MOORE S A, COZ J L, HURTHUR D, et al. On the application of horizontal ADCPs to suspended sediment transport surveys in rivers [J]. *Continental Shelf Research*, 2012, 46:50-63.
- [9] MOORE S A, COZ J L, HURTHUR D, et al. Using multi-frequency acoustic attenuation to monitor grain size and concentration of suspended sediment in rivers [J]. *Journal of the Acoustical Society of America*, 2013, 133(4): 1959-1970.
- [10] FLERI J R, LERA S, GEREVINI A, et al. Empirical observations and numerical modelling of tides, channel morphology, and vegetative effects on accretion in a restored tidal marsh [J]. *Earth Surface Processes and Landforms*, 2019, 44(11): 2223-2235.
- [11] 王仲明,王常明,王钢城,等. 水中泥沙浓度的超声成像测量研究[J]. *泥沙研究*, 2015(2): 24-28.
WANG ZH M, WANG CH M, WANG G CH, et al. Ultrasound imaging measurement of suspended sediment concentration in the water [J]. *Journal of Sediment Research*, 2015(2): 24-28.
- [12] ZHANG B, GAO Y X, CUI H H. A brief introduction to the measuring methods for sediment concentration of runoff and providing a new idea [J]. *Applied Mechanics and Materials*, 2014, 3047(530-531): 141-145.
- [13] 李德贵,张广海,叶繁,等. 基于 C8051F350 单片机的同位素测沙仪研制 [J]. *电子产品世界*, 2017, 24(8): 61-64.
LI D G, ZHANG G H, YE F, et al. To develop radioisotope sediment concentration meter based on C8051F350 MCU [J]. *Electronic Engineering & Product World*, 2017, 24(8): 61-64.
- [14] LIU M T, ZHANG CH C, TIAN ZH ZH, et al. The study of data fusion for high suspended sediment concentration measuring based on BP neural network [C]. 2015 12th IEEE International Conference on Electronic Measurement & Instruments, 2015: 1519-1523.
- [15] LIU M T, ZHANG CH C, LIU X M, et al. The study of data fusion for high suspended sediment concentration measuring using the IGA-RBF method [J]. *Journal of Intelligent & Fuzzy Systems: Applications in Engineering and Technology*, 2015, 28(2): 605-614.
- [16] 张颖,行鸿彦,张旭,等. 土壤水分传感器探头的仿真分析 [J]. *电子测量与仪器学报*, 2021, 35(4): 55-65.
ZHANG Y, XING H Y, ZHANG X, et al. Simulation analysis of soil moisture sensor probe [J]. *Journal of Electronic Measurement and Instrumentation*, 2021, 35(4): 55-65.
- [17] 陈思佳,罗志增. 基于长短时记忆和卷积神经网络的手势肌电识别研究 [J]. *仪器仪表学报*, 2021, 42(2): 162-170.
CHEN S J, LUO ZH Z. Research on gesture EMG recognition based on long short-term memory and convolutional neural network. [J]. *Chinese Journal of Scientific Instrument*, 2021, 42(2): 162-170.
- [18] BAYRAM A, KANKAL M, ÖNSOY H. Estimation of suspended sediment concentration from turbidity measurements using artificial neural networks [J]. *Environmental Monitoring & Assessment*, 2012, 184(7): 4355-4365.
- [19] SHU T X. Sensory data prediction using spatiotemporal correlation and LSTM recurrent neural network [J]. *Instrumentation*, 2019, 6(3): 10-17.
- [20] 陈禹,渠吉庆,唐文静,等. 基于 LSTM 的室内定位系统设计与实现 [J]. *电子测量技术*, 2021, 44(19): 161-166.
CHEN Y, QU J Q, TANG W J, et al. Design and implementation on indoor positioning system based on LSTM [J]. *Electronic Measurement Technology*, 2021, 44(19): 161-166.

作者简介



邓罗晟, 2018 年于重庆大学获得学士学位, 现为昆明理工大学硕士研究生, 主要研究方向为多传感器信息融合。
E-mail: 329643759@qq.com

Deng Luosheng received his B. Sc. degree in 2018 from Chongqing University.

Now he is a M. Sc. candidate at Kunming University of Science and Technology. His main research interest includes multi-sensor information fusion.



车国霖 (通信作者), 1998 年于电子科技大学获得学士学位, 2005 年于昆明理工大学获得硕士学位, 现为昆明理工大学副教授, 主要研究方向为智能控制及应用。
E-mail: 864111506@qq.com

Che Guolin (Corresponding author) received his B. Sc. degree from University of Electronic Science and Technology of China in 1998, M. Sc. degree from Kunming University of Science and Technology in 2005. Now he is an associate professor in Kunming University of Science and Technology. His main research interests include intelligent control and application.