

DOI: 10.13382/j.jemi.B2407965

基于 SSA-LSTM-Attention 的典型液压系统压力数据高精度预测方法*

周浩¹ 冯浩¹ 周晨曦¹ 殷晨波² 曹东辉³ 马守磊²

(1. 南京信息工程大学人工智能学院 南京 210044; 2. 南京工业大学机械与动力工程学院 南京 211816;

3. 三一重机有限公司 苏州 215334)

摘要: 液压系统压力传感器作为挖掘机自动控制系统的核心元件,其可靠性直接影响整机操控性能。针对复杂恶劣工况下压力传感器失效导致控制系统信号缺失的关键问题,提出一种基于深度学习的高精度压力数据实时预测方法。首先,基于37吨级挖掘机电液比例控制系统构建试验平台,采集实际挖装作业工况下多源传感器数据;其次,采用最大信息系数法进行特征相关性分析,将125维原始数据降维至10维有效特征,并通过卡尔曼滤波与标准化处理构建高质量数据集;进而设计基于注意力机制的特征权重分配模块,结合麻雀搜索算法(sparrow search algorithm, SSA)优化长短期记忆神经网络(long short term memory, LSTM)的超参数配置,构建SSA-LSTM-Attention融合预测模型。通过对比卷积神经网络(convolutional neural network, CNN)、循环神经网络(gate recurrent unit, GRU)、LSTM等典型预测模型的实验验证,该方法在关键压力数据预测中展现出显著优势。实验结果表明,相较于传统LSTM模型,SSA-LSTM-Attention模型的平均绝对误差和均方根误差分别降低54.45%和54.56%。研究证实所提方法能有效解决传感器失效工况下的数据补偿问题,为工程机械智能控制系统容错设计提供理论支撑。

关键词: 挖掘机; 液压系统; 压力预测; 工程机械; LSTM

中图分类号: TH173; TN98

文献标识码: A

国家标准学科分类代码: 460.45

High accuracy prediction method for typical hydraulic system pressure data based on SSA-LSTM-Attention

Zhou Hao¹ Feng Hao¹ Zhou Chenxi¹ Yin Chenbo² Cao Donghui³ Ma Shoulei²

(1. School of Artificial Intelligence, Nanjing University of Information Science & Technology, Nanjing 210044, China;

2. School of Mechanical and Power Engineering, Nanjing University of Technology, Nanjing 211816, China;

3. Sany Heavy Machinery Co., Ltd., Suzhou 215334, China)

Abstract: As the core component of automatic control system of hydraulic excavator, the reliability of hydraulic system pressure sensor directly affects the control performance of the whole excavator. To solve the key problem of loss of control system signal caused by pressure sensor failure under complex and severe working conditions, this study proposes a high-precision pressure data real-time prediction method based on depth learning. Firstly, based on the electro-hydraulic proportional control system of 37t hydraulic excavator, a test platform is established to collect the data of multi-source sensor under the actual excavation and loading operation condition; Secondly, the maximum information coefficient method is used to analyze the feature correlation, and the 125-dimensional original data is reduced to the 10-dimensional effective feature, and the high-quality data set is constructed by means of Kalman filtering and standardization; Then, the feature weight distribution module based on attention mechanism is designed, and the super-parameter configuration of long short term memory(LSTM) network is optimized by combining with sparrow search algorithm(SSA) to construct the SSA-LSTM-Attention fusion prediction model. Through the experimental verification of seven typical prediction models, such as convolutional neural network(CNN), gate recurrent unit(GRU) and LSTM, this method shows significant advantages in key pressure data prediction. The experimental results show that the mean absolute error and root mean square error of SSA-LSTM-Attention model are reduced by 54.45% and 54.56% respectively compared with the traditional LSTM model. The research proves that the proposed method can effectively solve the data compensation problem under sensor failure condition, and provide theoretical support for the fault tolerant design of intelligent control system of engineering machinery.

Keywords: excavators; hydraulic system; pressure prediction; engineering machinery; LSTM

收稿日期: 2024-11-17 Received Date: 2024-11-17

* 基金项目: 中国博士后科学基金(2025T180363)、江苏省自然科学基金(BK20221342)、国家自然科学基金(52105064)项目资助

0 引言

随着我国现代化进程的推进,挖掘机作为工程机械的代表性机型,广泛应用在工程建设、矿业、林业、市政工程等领域。这些建设工程和挖掘机销量的大幅度增加,也意味着对施工质量、安全操作提出了更高的要求。然而,挖掘机作业环境恶劣,工况复杂多变^[1],这对参与控制的高精度高频响传感器的可靠性提出了严苛的要求^[2]。如果这些传感器失效导致挖掘机整机控制失效,不仅降低工作效率^[3],还可能导致无法估量的人身伤害。因此,本文旨在通过构建神经网络模型来实现传感器信号的软测量^[4],这对提高挖掘机控制系统可靠性和整机安全性具有重要意义。

近年来,随着人工智能技术的迅速发展,人们对传感器设备和深度学习进行了许多研究,基于数据驱动的软测量方法受到了广泛关注^[5],并逐渐成为研究热点。其中,Zhang 等^[6]开发了一种基于反向传播(back propagation, BP)神经网络的位置软测量模型来估计气缸位置,验证和仿真结果表明,所提出的直驱式液压系统位置软测量模型的精度在 7 和 4 mm 之内。Huo 等^[7]提出一种基于径向基函数(radial basis function, RBF)神经网络的挖掘机的挖掘载荷软测量方法,该方法不需要了解土壤参数且建模方法简便。实验结果表明,其挖掘机动力行为误差小于 7%,为智能挖掘机的挖掘载荷预测奠定了基础。Ding 等^[8]提出了一种基于动态模型和多压力编码器反馈信息融合的终端力软测量方法,对于连续和突变的负载力,软测量精度可以达到 1.85%~2.47%和 4.60%。Xu 等^[9]介绍了一种基于液压拧紧系统的多视角网络模型,用于预测拧紧过程中的瞬间预紧力。Huo 等^[10]提出了一种基于混沌理论和支持向量回归(support vector regression, SVR)的挖掘机负载功率预测新模型,利用 SVR 进行非参数建模和预测。参考近年来对数据驱动的软测量预测方法的研究,主要集中在建筑领域、风能领域,很少提及挖掘机机器人数据预测方法^[11-13]。因此,有必要建立一个挖掘机机器人关键数据预测的方法,以准确预测挖掘机在作业过程中的数据。

在这些研究中,长短期记忆(long short-term memory, LSTM)在时间序列数据的预测中有着广泛的应用,并能够避免循环神经网络(recurrent neural network, RNN)梯度消失和爆炸。然而,预测精度的提高受到网络参数的严重制约。为了解决 LSTM 超参数的选择问题,人们采用了许多优化算法方法,其中最典型的是遗传优化算法(genetic algorithm, GA)、粒子群优化算法(particle swarm optimization, PSO)和麻雀搜索算法(sparrow search algorithm, SSA)等。相比于其他算法,SSA 是一种新的群

体智能优化算法,模拟了麻雀的觅食和反捕食行为。通过模拟发现者和跟随者的角色,SSA 能够快速收敛到全局最优解的附近。由于参数少、实现简单,SSA 在处理高维复杂问题时表现出了高效率 and 稳定性。SSA 和 LSTM 的结合最大限度地发挥了各自的优势,提高了模型的性能和泛化能力。

以往研究中提出的深度学习预测网络、优化算法和特征指标可能并不适用于挖掘机等工程设备。仅依靠 LSTM 网络不足以实现传感器数据的高精度预测。挖掘机在作业过程中会产生大量数据,包括数百种数据类型。然而,单独收集的压力数据不足以反映动态环境中各种压力传感器之间的关系。因此,有必要进一步研究,以准确预测挖掘机液压系统中的关键压力数据,同时还要考虑实用性和适应性,这对智能施工至关重要。本文采用 LSTM 神经网络以及注意力机制,结合挖掘机的工作状态和压力数据的时间序列,建立了挖掘机压力预测模型。用 SSA 算法,实现了模型参数的自动调整。为消除输入特征之间的信息冗余,保证提取特征的准确性,降低模型复杂度,采用最大信息系数方法对输入特征进行降维,并进行滤波降噪和归一化处理作为模型输入,最后,结合挖掘机的工作条件和特点,使用 37 t 级挖掘机 90°甩方作业时的压力数据对此模型以及其他 8 种模型进行了比较,验证了预测模型的准确性。

1 挖掘机器人系统模型

基于实验室三一重机 37 t 级的 SY375IDS 挖掘机器人分析其液压系统组成及工作原理。挖掘机器人液压系统原理如图 1 所示,主要包括供油元件(先导定量泵和主变量泵)、油液控制回路(电控手柄、电脑、先导阀和主阀)以及执行机构(阀控非对称液压缸)。挖掘机器人的工作装置包含多个独立的液压系统,可以分为动臂联、斗杆联和铲斗联。这几联系统在系统组成和工作原理上完全一致,仅有结构参数的区别。以铲斗联为例,其能量传输路线可以概述为柴油机→联轴器→液压泵(机械能转化为液压能)→多路阀→铲斗液压缸(液压能转化为机械能)→铲斗运动。

首先,当电控手柄或者电脑发出控制信号时,由先导定量泵供油的先导阀根据控制信号调节先导压力油的流向。接着,由主变量泵供油的多路阀接收来自先导阀的信号产生相应的阀芯位移。最后,在多路阀阀芯的推动下,液压缸的无杆腔或有杆腔的液压回路与主变量泵接通,液压缸伸出或者收回。同时,由各传感器采集的信号经数模转换后反馈至控制器,与期望轨迹相比较,形成闭环反馈控制。简而言之,液压缸的动作(伸出或者收回)由输出控制信号的大小(电控手柄或者电脑)决定,液压

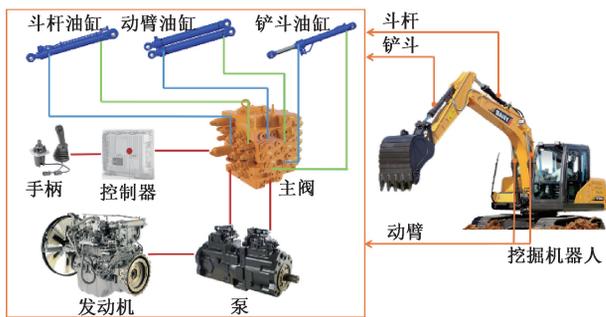


图 1 挖掘机器人液压系统原理

Fig. 1 Schematic diagram of hydraulic system for robotic excavator

缸的移动速度与控制信号的大小近似成比例关系。

2 挖土装车工况下作业数据采集与预处理

2.1 数据来源

本文使用的数据来自一台型号为 SY375IDS 的挖掘机。试验场地为湖州室外场地,开挖材料为普通土、岩

石。为了获得 SY375IDS 挖掘机在典型作业时的压力特性,收集有效数据,定义典型工况和熟练的操作人员。试验工况为 90°甩方,执行预挖掘、挖掘、举升、回转、卸载、复位回转循环动作。挖掘机下车部分保持不动,上车部分回转 90°,如图 2 所示。现场布置传感器放置示意图如图 3 所示,试验设备基本参数如表 1 所示。另外,为了避免个人操作习惯造成的不良影响,选择具有 3 年以上工作经验的操作人员驾驶挖掘机,保证测试数据的通用性。

表 1 实验设备基本参数

Table 1 Basic parameters of experimental equipment

设备名称	型号	主要参数
挖掘机	SY375IDS	额定功率/(kW/r·min ⁻¹):212/2 000
		主泵最大流量/(L·min ⁻¹):149
压力传感器	HG3350G10	量程:0~60 MPa
	NMPXM1	精度:0.1%FS
控制器	BODAS	输出频率:50~250 Hz
	RC28-14/30	信号输出:4~20 mA
数据记录仪	ZLG	波特率:5 Kbps~1 Mbps
	CANDTU-	最高接收数据流量:>7 000/s
	200UR	



图 2 完整工作周期各阶段的动作图

Fig. 2 Movement diagrams for each phase of the complete working cycle

2.2 数据预处理

1) 相关性分析

基于数据驱动的深度学习方法只需要建立辅助变量与输出变量的关系模型来达到软测量目的。因此辅助变量的选取尤为重要,既要精准也要信息全面,从而提升网络适用性。由于挖掘机铲斗的结构和运动情况最为复杂,实验中选择铲斗大腔压力作为输出来验证模型性能。

首先通过机理分析对辅助变量进行初步筛选。挖掘机进行 90°甩方作业时,挖掘载荷依次通过铲斗、斗杆、动臂传递至回转平台,再到回转支承,最后传递至机架。根

据分析挖掘载荷的传递,挖掘机作业是通过各部件的紧密配合来完成的,部件之间相互耦合使得压力也会相互影响。因此初步筛选出各部件的主油路压力信号和先导回路压力信号共 25 组,如表 2 所示。

为降低特征维度并提高软测量模型的精确度,利用最大信息系数(maximal information coefficient, MIC)^[14]来选择辅助变量的最优子集。MIC 是一种用于衡量两个变量之间相关性的方法,它不依赖于测量数据的分布假设,与之前的研究相比,可以识别广泛的关联类别,捕获成对变量之间的依赖性,包括函数关系和非函数关系。其计



1. 压力传感器;2. 电子罗盘;3. 主阀;4. 拉线式位移传感器;
5. 数据采集系统;6. 挖掘机器人

图 3 现场布局中的传感器放置图

Fig. 3 Sensor placement diagram in the site layout

表 2 初步筛选的辅助变量

Table 2 Auxiliary variables for preliminary screening

变量	特征变量	变量	特征变量
X_1	动臂大腔压力	X_{14}	斗杆 1 卸载先导压力
X_2	动臂小腔压力	X_{15}	斗杆 2 卸载先导压力
X_3	斗杆大腔压力	X_{16}	铲斗挖掘先导压力
X_4	斗杆小腔压力	X_{17}	铲斗卸载先导压力
X_5	铲斗小腔压力	X_{18}	左回转先导压力
X_6	泵 1 压力	X_{19}	右回转先导压力
X_7	泵 2 压力	X_{20}	回转 A 口压力
X_8	动臂提升 1 先导压力	X_{21}	回转 B 口压力
X_9	动臂提升 2 先导压力	X_{22}	铲斗角度
X_{10}	动臂下降 1 先导压力	X_{23}	斗杆角度
X_{11}	动臂下降 2 先导压力	X_{24}	动臂角度
X_{12}	斗杆 1 挖掘先导压力	X_{25}	回转角度
X_{13}	斗杆 2 挖掘先导压力		

算公式如下:

$$MIC(x, y) = \max_{xy < B} \frac{I(x, y)}{\log_2(\min(x, y))} \quad (1)$$

$$I(x, y) = \sum_{x \in X} \sum_{y \in Y} p(x, y) \log\left(\frac{p(x, y)}{p(x) \cdot p(y)}\right) \quad (2)$$

式中: $I(x, y)$ 为变量 x 和 y 之间的互信息; $p(x, y)$ 为变量 x 和 y 的联合概率分布函数; $p(x)$ 、 $p(y)$ 分别是 x 和 y 的边缘概率分布函数; B 是最大网格大小限制。

根据上述 MIC 方法计算得到每个候选输入变量与输出变量铲斗大腔压力 X_{26} 的互信息值,如图 4 所示。本文筛选计算结果最大的 10 个的参数变量作为最终模型输入,即动臂大腔压力 X_1 、斗杆大腔压力 X_3 、斗杆小腔压力 X_4 、铲斗小腔压力 X_5 、泵 1 压力 X_6 、泵 2 压力 X_7 、回转 B 口压力 X_{21} 、铲斗角度 X_{22} 、斗杆角度 X_{23} 、动臂角度 X_{24} 。

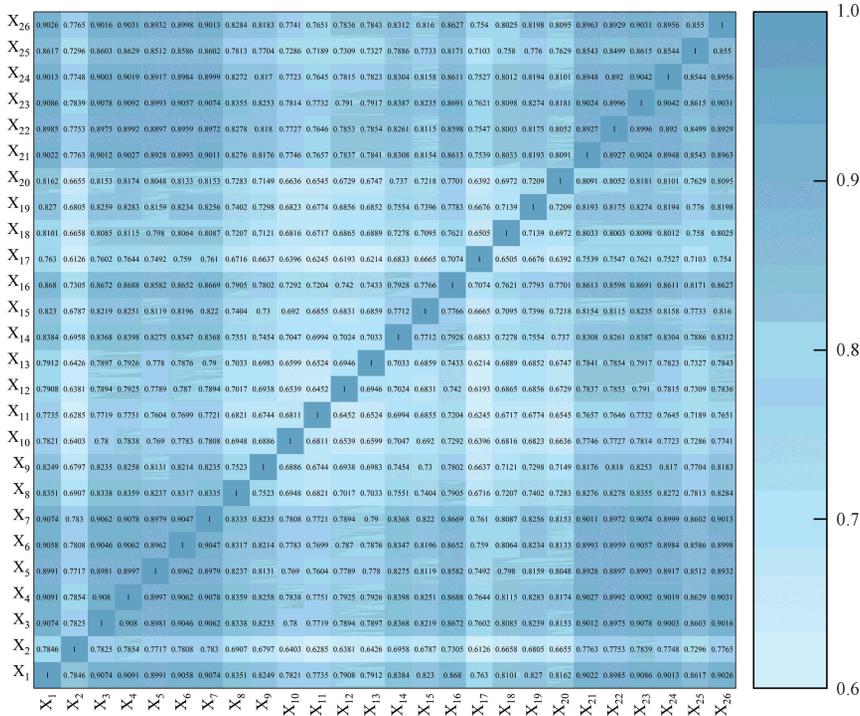


图 4 各输入变量的互信息值

Fig. 4 Maximum information coefficient value for each input variable

2) 卡尔曼滤波降噪

在实际实验中,挖掘机作业具有工况恶劣、干扰因素

多、冲击载荷频繁等特点,导致采集到的数据序列波动较大。对挖掘机压力预测有负面影响。干扰越大,预测的

准确性就越低。因此,为了更好的提取数据特征,必须进行数据滤波,将这些错误点进行去除。在预测压力之前首先需要对收集到的数据进行预处理。

利用卡尔曼滤波^[15]对筛选出的辅助变量数据集进行降噪处理。卡尔曼滤波器是一系列数学方程,能够通过最小化均方误差来递归且有效地估计过程的状态。卡尔曼滤波器的优点之一是它能够基于最少的数据来估计情况。卡尔曼滤波器理论基于状态空间方法,其中时间更新方程对信号生成过程的动态进行建模,时间更新方程对噪声和失真的观测信号进行建模。时间更新方程也可以称为预测方程,它利用上一个时刻的状态估计来得到此时的状态估计。同时,测量更新方程也称为校正方程,是当前用来改进预测的测量信息,希望得到更准确的状态估计。

3) 归一化

为了减少得到的数据噪声对测试结果的影响,还引入归一化作为数据预处理的方法,加快模型的收敛速度,提高模型的预测精度。归一化对于训练是至关重要的,如果不使用它,可能会出现严重的情况,例如模型不收敛。常用的归一化方法是将数据映射到 $[0, 1]$,其计算公式如下:

$$x^* = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (3)$$

式中: x^* 为归一化后的数据; x 为原始数据; x_{\max} 为原始数据中的最大值; x_{\min} 为原始数据中的最小值。

3 SSA-LSTM-Attention 预测模型

3.1 麻雀搜索算法

SSA 是 Xue 等^[16]受麻雀的觅食行为和反捕食行为的启发,提出的一种新型的群智能优化算法,由于该算法拥有优秀的全局搜索能力、较快的收敛速度、强鲁棒性等优点,易于实现和调节,故将该算法用于优化预测模型的超参数中。

在麻雀种群整个觅食过程中,分为发现者和跟随者两种不同的类型。发现者负责寻找食物,在寻找过程中优先获得食物并引导整个种群的行动。发现者的位置更新公式为:

$$X_{i,j}^{t+1} = \begin{cases} X_{i,j}^t \exp\left(-\frac{i}{\alpha I_{\max}}\right), R_2 < ST \\ X_{i,j}^t + QL, R_2 \geq ST \end{cases} \quad (4)$$

式中: t 为当前迭代次数; $X_{i,j}^t$ 为在 t 次迭代时第 i 只麻雀在第 j 维的位置; I_{\max} 为最大迭代次数; $\alpha \in (0, 1]$ 为随机数; $R_2 \in [0, 1]$ 为预警值; $ST \in [0.5, 1]$ 为安全阈值; Q 是服从正态分布的随机数; L 为一个 $1 \times d$ 的矩阵。

跟随者在发现者找到食物后,立刻离开原有位置去争夺食物。跟随者位置更新公式如下:

$$X_{i,j}^{t+1} = \begin{cases} Q \exp\left(\frac{X_{\text{worst}}^t - X_{i,j}^t}{i^2}\right), i > \frac{n}{2} \\ X_p^{t+1} + |X_{i,j}^t - X_p^{t+1}| A^+ L, \text{其他} \end{cases} \quad (5)$$

式中: X_p 为发现者当前占据的最优位置; X_{worst} 为当前最差位置; n 为麻雀的数量; A 是一个由随机-1或1组成的 $1 \times d$ 的矩阵,并且 $A^+ = A^T(AA^T)^{-1}$ 。

当掠食者入侵时,处于群体边缘的麻雀会意识到危险并向安全位置移动,其行为公式如下:

$$X_{i,j}^{t+1} = \begin{cases} X_{\text{best}}^t + \beta |X_{i,j}^t - X_{\text{best}}^t|, f_i > f_g \\ X_{i,j}^t + K \frac{|X_{i,j}^t - X_{\text{worst}}^t|}{f_i - f_w + \varepsilon}, f_i = f_g \end{cases} \quad (6)$$

式中: X_{best} 为当前全局最优位置; β 为步长控制参数; $K \in [-1, 1]$ 是一个随机数; f_i 是当前麻雀的适应度值; f_g 和 f_w 分别为当前搜索范围内最好和最差的适应度值; ε 是最小的常数,以避免零除误差。

3.2 基于 LSTM 及注意力机制的压力预测模型

LSTM 网络是一种特殊的循环神经网络^[17],是为了解决一般的 RNN 存在的长期依赖问题而专门设计出来的。它不仅具有 RNN 网络原有的时间相关性特征,而且通过增加门控机制解决了 RNN 网络的梯度爆炸和消失、不保留长距离信息等问题。LSTM 单元的更新过程如下:

$$\begin{cases} f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \\ i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \\ C'_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \\ C_t = f_t C_{t-1} + i_t C'_t \\ o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \\ h_t = o_t \tanh(C_t) \end{cases} \quad (7)$$

式中: f_t 、 i_t 、 o_t 分别为遗忘门、输入门和输出门的输出; W_f 、 W_i 、 W_o 为3个门对应的权重; b_f 、 b_i 、 b_o 为3个门对应的偏置向量; C'_t 为中间变量,用以控制输入的数据; x_t 为当前时刻的输入; W_c 为学习权重参数向量; b_c 为偏差; C_{t-1} 和 C_t 为上一时刻和当前时刻的输出结果; h_{t-1} 和 h_t 为上一时刻和当前时刻的隐藏层状态; σ 为 Sigmoid 函数; \tanh 为双曲正切函数。

传统的 LSTM 神经网络在处理非常长的序列时会出现性能下降,注意力机制^[18]可以让模型在每个时间步自适应地选择重要的信息,从而更有效地捕捉长期依赖关系。注意力机制能有效地提取输入序列中的特征,注意力机制允许模型根据某个方面关注特征,从而缓解模型瓶颈。注意力机制通过计算不同输入特征的权重,增强了 LSTM 网络在预测过程中对关键特征的识别和利用,

从而提升了模型的预测精度和可靠性。故将注意力机制引入 LSTM 中, 以此建立预测模型, 模型结构如图 5 所示。

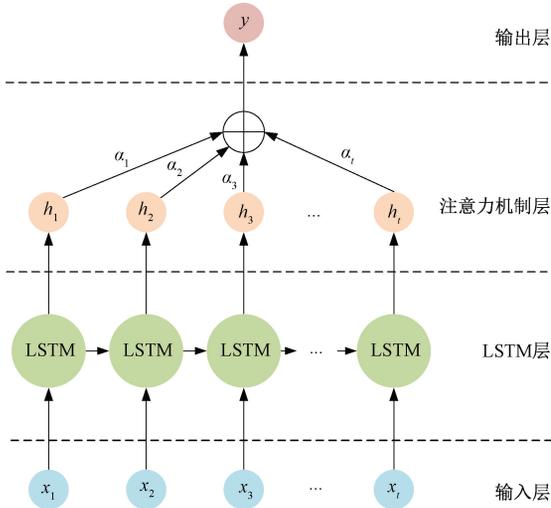


图 5 LSTM-Attention 模型结构

Fig. 5 LSTM-Attention model structure diagram

图 5 中, $\{x_1, x_2, x_3, \dots, x_t\}$ 是 LSTM 模型的输入序列, LSTM 层负责处理序列数据, 得到隐藏层的输出向量 $\{h_1, h_2, h_3, \dots, h_t\}$, 用注意力机制计算隐藏层输出的重要性, 从而赋予各输入特征的不同权重并加权求和, 注意力机制公式如下:

$$e_i = \tanh(W h_i + b) \tag{8}$$

$$\alpha_i = \frac{\exp(e_i)}{\sum_{j=1}^i e_j} \tag{9}$$

$$c = \sum_{i=1}^i \alpha_i h_i \tag{10}$$

式中: e_i 为 t 时刻的隐藏层输出向量; h_i 为 LSTM 第 t 个时间点的输出; α_i 为第 t 个时间点的注意力权重; W 为权重系数; c 为输出的加权总和。输出层输出模型的预测结果, 表达式为:

$$y = \sigma(Wc + b) \tag{11}$$

式中: y 为预测输出值; b 为偏置向量; σ 表示 Sigmoid 函数。

3.3 性能评估

为了更全面地评估模型的效果, 本文采用了均方根误差 (root mean squared error, RMSE)、平均绝对误差 (mean absolute error, MAE)、决定系数 (coefficient of determination, R^2) 和最大误差指标来评估模型的预测性能。各指标的计算公式如下:

$$\begin{cases} RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - y'_i)^2} \\ MAE = \frac{1}{n} \sum_{i=1}^n |y_i - y'_i| \\ R^2 = 1 - \frac{\sum_{i=1}^n (y_i - y'_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \end{cases} \tag{12}$$

式中: n 为样本数量; y_i 为预测的压力的真实值; y'_i 为模型预测的压力值。RMSE 和 MAE 的计算值越接近 0, 预测结果越接近真实值, 预测模型越好。 $R^2 \in [0, 1]$, R^2 的值越大, 拟合效果越好。

4 实验结果与讨论

4.1 模型参数

实验数据集采用从实际场地采集的采样频率为 50 Hz 的 10 000 个采样数据。这个实验数据集将按照 8 : 2 的比例分成两部分。其中前 80% 用于训练模型, 后 20% 用于测试实验结果。麻雀优化算法用于对 LSTM 网络进行优化, 以确定最优超参数。麻雀算法优化的 LSTM 超参数类别和范围如表 3 所示。

表 3 麻雀算法优化的超参数

Table 3 Hyperparameters for the optimisation of the sparrow algorithm

超参数	范围
隐含层节点	[16, 64]
迭代次数	[200, 500]
初始学习率	$[1 \times 10^{-3}, 1 \times 10^{-2}]$
L2 正则化	$[1 \times 10^{-5}, 1 \times 10^{-3}]$

适应度曲线如图 6 所示, 代表了模型使用麻雀算法在超参数空间中选择超参数组合进行训练的过程, 随着麻雀算法的优化搜索, 模型的训练过程逐渐稳定, 其目标值也降到最低。各模型的超参数设置如表 4 所示。

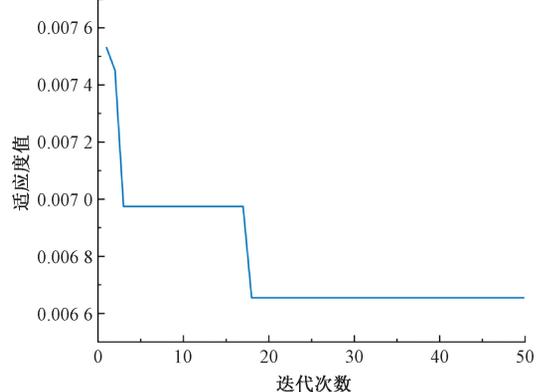


图 6 适应度曲线

Fig. 6 Fitness curve

表 4 预测模型超参数

Table 4 Prediction model hyperparameters

预测模型	隐藏层 节点	迭代 次数	初始学 习率	L2 正 则化
CNN	100	400	1×10^{-3}	1×10^{-4}
CNN-LSTM	64	500	1×10^{-3}	1×10^{-4}
GRU	80	400	5×10^{-3}	1×10^{-4}
PSO-GRU	60	384	8.3×10^{-3}	2.9×10^{-4}
LSTM	64	400	5×10^{-3}	1×10^{-4}
GA-LSTM	28	358	6.6×10^{-3}	8.2×10^{-3}
PSO-LSTM	37	347	4.5×10^{-3}	7.1×10^{-4}
LSTM-Attention	64	400	5×10^{-3}	1×10^{-4}
SSA-LSTM-Attention	23	375	1.4×10^{-3}	1.1×10^{-4}

4.2 各模型的试验结果对比

不同模型的测试效果如图 7 所示,不同模型的预测曲线和实际曲线大致拟合。但通过麻雀算法优化后,模型预测曲线的更加接近实际值。

根据式 (12) 可以得到不同模型的预测结果如表 5 所示。SSA-LSTM-Attention 模型的 MAE 和 RMSE 分别为 0.063 75、0.095 66 MPa,同 LSTM-Attention 模型相比,预测精度分别提升了 46.37%、42.65%;同 LSTM 模型相比,预测精度分别提升了 54.45%、54.56%。值得注意的是,SSA-LSTM-Attention 的预测精度比 PSO-LSTM 和 GA-LSTM 的预测精度高,说明 SSA 更适合于用来解决 LSTM

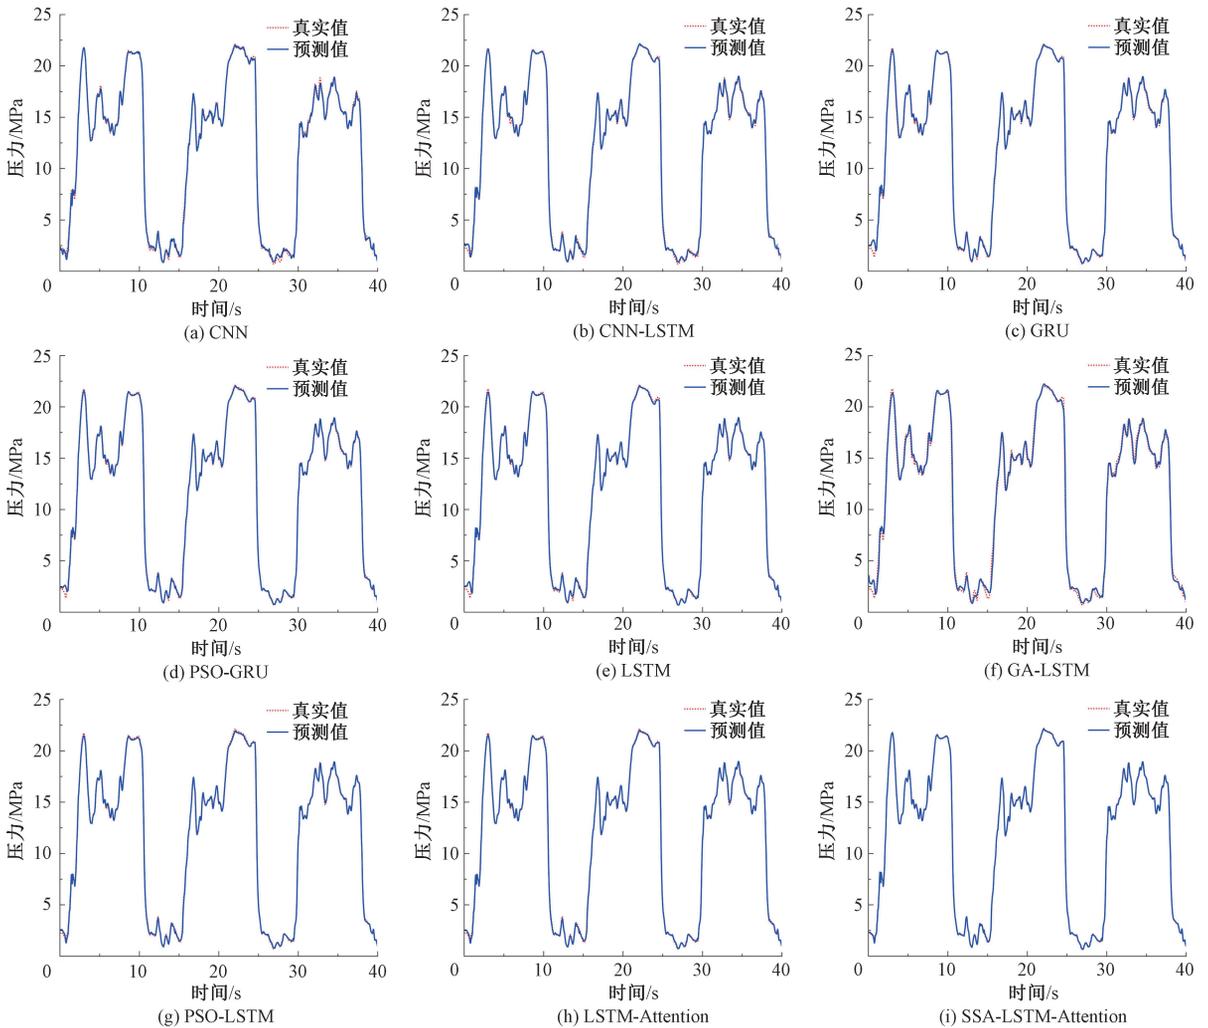


图 7 输出模型的测试效果

Fig. 7 Test results graph of the output mode

超参数的选择问题。LSTM-Attention 模型同 LSTM 模型相比,预测精度分别提升了 15.08%、20.78%,这是因为 LSTM-Attention 模型通过注意力机制通过计算不同输入特征的权重,增强了 LSTM 网络在预测过程中对关键特

征的识别和利用,从而提升了模型的预测精度和可靠性。对比其他 8 种模型,SSA-LSTM-Attention 模型的误差最小,说明该模型能够更准确的挖掘出压力信号的变化信息以及同其他压力信号的关联性。

在挖掘机的稳定控制中,必须避免工作装置突发的误动作,因此预测误差需控制在较小的范围内且不能出现较多异常值。由表 5 可知,不同模型的 RMSE 和 MAE 均小于 0.5 MPa,但预测值的有效性还需考虑实时预测误差。图 8 所示为不同模型的实时预测误差分布,其中 LSTM、LSTM-Attention、SSA-LSTM-Attention 3 种模型的压力值误差分布范围均在 ± 0.15 MPa 内,但 SSA-LSTM-Attention 的预测更加稳定,测试过程仅出现个别异常值,最大误差仅为 0.599 39 MPa。相比而言,LSTM 模型和 LSTM-Attention 模型的异常值较多且范围大。因此可判断 SSA-LSTM-Attention 模型对压力信号的预测稳定性最好。

表 5 各模型输出实验结果

Table 5 Each model outputs experimental results

预测模型	R^2	MAE	RMSE	最大误差
CNN	0.999 12	0.163 67	0.214 80	1.469 75
CNN-LSTM	0.999 03	0.158 29	0.225 01	1.314 13
GRU	0.999 05	0.147 46	0.223 46	1.564 86
PSO-GRU	0.999 31	0.131 31	0.190 41	1.128 19
LSTM	0.999 15	0.139 97	0.210 54	1.467 53
GA-LSTM	0.996 02	0.326 22	0.456 09	2.435 21
PSO-LSTM	0.999 43	0.125 92	0.173 07	0.978 37
LSTM-Attention	0.999 47	0.118 86	0.166 79	0.898 02
SSA-LSTM-Attention	0.999 83	0.063 75	0.095 66	0.599 39

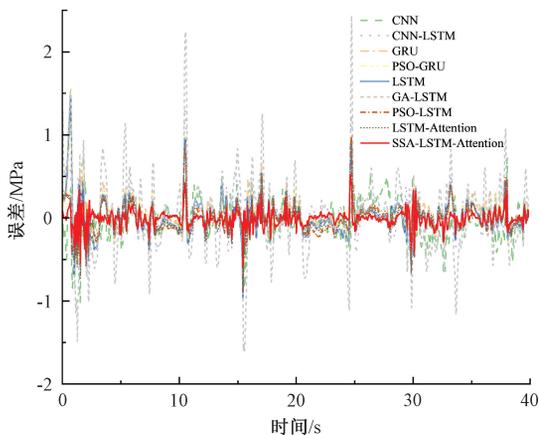


图 8 实时预测误差分布

Fig. 8 Distribution of real-time prediction errors

5 结 论

针对液压挖掘机在复杂工况下面临的压力传感器失效引发的控制信号缺失问题,本文提出一种融合麻雀搜索算法、注意力机制与长短期记忆网络的预测模型,旨在提升控制系统容错性与作业安全性。通过建立 37 t 级挖掘机测试平台,采集典型工况 90°甩方作业时的压力数

据。为消除输入特征之间的信息冗余,保证提取特征的准确性,采用基于最大信息系数特征筛选方法,从 125 维原始参数中提取 10 个强相关性特征,并进行滤波降噪和归一化处理作为模型输入。创新构建 SSA-LSTM-Attention 混合架构,采用注意力机制动态分配特征权重,结合 SSA 算法优化 LSTM 网络的隐含层节点数、学习率等超参数组合。实验对比 CNN、GRU、LSTM 等传统模型,SSA-LSTM-Attention 模型在压力数据预测中表现最优,其均方根误差与平均绝对误差分别为 0.095 66 和 0.063 75 MPa,较传统 LSTM 模型分别降低了 54.56% 和 54.45%,最大误差仅为 0.599 39 MPa。该方法能够应用于瞬态信号干扰、传感器间歇失效等典型故障场景的数据补偿,可为后续工程机械智能控制系统的容错架构设计提供数据支撑。

参考文献

- [1] 孙金辉,谢丽蓉,于川,等. 原油含水率测量传感器性能优化实验研究[J]. 电子测量与仪器学报, 2022, 36(8): 97-104.
SUN J H, XIE L R, YU CH, et al. Experimental study on performance optimization of crude oil water content measurement sensor [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(8): 97-104.
- [2] 翁川,尹自强. 一种二级曲面测量装置的设计及其不确定度的标定[J]. 电子测量与仪器学报, 2022, 36(10): 39-48.
WENG CH, YIN Z Q. Design of a secondary surface measurement device and its uncertainty calibration [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(10): 39-48.
- [3] 骆俊伟,陆建山,周鸿波,等. 基于模糊的氢燃料电池时序采样能量控制方法[J]. 电子测量与仪器学报, 2023, 37(10): 202-210.
LUO J W, LU J SH, ZHOU H B, et al. A fuzzy-based energy control method for hydrogen fuel cell time-sampling [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(10): 202-210.
- [4] 乔景慧,李洪达,陈宇曦,等. 机理与数据驱动的软件手弯曲角度软测量模型[J]. 电子测量与仪器学报, 2023, 37(6): 147-158.
QIAO J H, LI H D, CHEN Y X, et al. Mechanism and data-driven soft measurement model for soft hand bending angle [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(6): 147-158.
- [5] YAN F, KONG L, LI Y, et al. A survey of data-driven soft sensing in ironmaking system: Research status and opportunities [J]. ACS Omega, 2024, 9(24):

- 25539-25554.
- [6] ZHANG S, CHEN T, MINAV T, et al. Position soft-sensing of direct-driven hydraulic system based on back propagation neural network [J]. *Actuators*, 2021, 10(12): 322.
- [7] HUO D, CHEN J, ZHANG H, et al. Intelligent prediction for digging load of hydraulic excavators based on RBF neural network [J]. *Measurement*, 2023, 206: 112210.
- [8] DING R, MU X, CHENG M, et al. Terminal force soft sensing of hydraulic manipulator based on the parameter identification [J]. *Measurement*, 2022, 200: 111551.
- [9] XU L, XU Y, WANG K, et al. Two-stream bolt preload prediction network using hydraulic pressure and nut angle signals [J]. *Engineering Applications of Artificial Intelligence*, 2024, 136: 109029.
- [10] HUO D, CHEN J, WANG T. Chaos-based support vector regression for load power forecasting of excavators [J]. *Expert Systems with Applications*, 2024, 246: 123169.
- [11] DONG J, XIE Z, JIANG H, et al. Multiple regression method for working face mining pressure prediction based on hydraulic support monitoring dataset [J]. *Frontiers in Earth Science*, 2023, 11: 1114033.
- [12] SAMADI M, SARKARDEH H, JABBARI E. Prediction of the dynamic pressure distribution in hydraulic structures using soft computing methods [J]. *Soft Computing*, 2021, 25: 3873-3888.
- [13] HESS N, SHANG L Z. Development of a machine learning model for elastohydrodynamic pressure prediction in journal bearings [J]. *Journal of Tribology*, 2022, 144(8): 081603.
- [14] WEI N, YIN C, YIN L, et al. Short-term load forecasting based on WM algorithm and transfer learning model [J]. *Applied Energy*, 2024, 353: 122087.
- [15] ZHAO F, GAO W, LU J, et al. Real-time concentration detection of Al dust using GRU-based Kalman filtering approach [J]. *Process Safety and Environmental Protection*, 2024, 189: 154-163.
- [16] XUE J, SHEN B. A novel swarm intelligence optimization approach: sparrow search algorithm [J]. *Systems Science & Control Engineering*, 2020, 8(1): 22-34.
- [17] 刘晓倩, 崔焕勇, 刘海宁, 等. 融合多特征选择和自注意力机制的 LSTM 燃料电池退化预测方法 [J]. *电子测量与仪器学报*, 2024, 38(5): 219-228.
- LIU X Q, CUI H Y, LIU H N, et al. An LSTM fuel cell degradation prediction method incorporating multi-feature selection and self-attention mechanism [J]. *Journal of Electronic Measurement and Instrumentation*, 2024, 38(5): 219-228.
- [18] NIU Z Y, ZHONG G Q, YU H. A review on the attention mechanism of deep learning [J]. *Neurocomputing*, 2021, 452: 48-62.

作者简介



周浩, 现为南京信息工程大学硕士研究生, 主要研究方向为流体传动与智能控制。
E-mail: 202312490768@nuist.edu.cn

Zhou Hao is now a M. Sc. candidate at Nanjing University of Information Science and Technology. His main research interests include fluid transmission and intelligent control.



冯浩(通信作者), 2020 年于南京工业大学获得博士学位, 现为南京信息工程大学副教授、硕士生导师, 主要研究方向为流体传动与控制、人工智能技术。
E-mail: fenghao@nuist.edu.cn

Feng Hao (Corresponding author) received his Ph. D. degree in 2020 from Nanjing Tech University. He is now an associate professor and M. Sc. supervisor, at Nanjing University of Information Science and Technology. His main research interests include fluid transmission and control and artificial intelligence technology.