

DOI: 10.19650/j.cnki.cjsi.J2107486

基于量子粒子群与深度学习的煤矿瓦斯涌出量软测量*

付 华¹, 赵俊程¹, 付 昱¹, 卢万杰², 徐耀松¹

(1. 辽宁工程技术大学电气与控制工程学院 辽宁 125105; 2. 辽宁工程技术大学机械工程学院 辽宁 123000)

摘 要:针对现有的绝对瓦斯涌出量软测量方法普遍未考虑瓦斯涌出量自身历史数据的前后影响,提出一种基于深度学习中长短时记忆网络(LSTM)的瓦斯涌出量软测量模型,利用绝对瓦斯涌出量及其相关影响因素历史数据的时间序列进行预测。考虑到 LSTM 模型需特别注意控制学习率以防止因出现梯度问题从而影响结果,对 LSTM 单元结构做出调整,引入 softsign 函数,通过其变化相对缓和的一阶导数以更好的解决梯度问题,使网络更快收敛且更不容易出现饱和。针对 LSTM 中存在诸多超参数,结合量子粒子群算法(QPSO)对其优化,使绝对瓦斯涌出量软测量结果精度最优,并利用核主成分分析对测量指标降维,加快模型收敛速度。对比改进后的模型与初始模型,得到改进的模型具有更高的精度和效率,均方根误差、平均绝对百分比误差和拟合优度决定系数 3 种误差评价指标分别为 0.080、0.82% 和 0.988。将提出的模型与 ELM、PSO-SVM、PSO-BP 以及 GRU 模型对比,可得到提出的模型误差更小,测量结果优于其他模型。实验结果表明,提出的瓦斯涌出量软测量模型具有更好的表现。

关键词: 瓦斯涌出量;软测量;深度学习;长短时记忆网络;softsign 函数;量子粒子群

中图分类号: TH865 TD712 **文献标识码:** A **国家标准学科分类代码:** 440.75

Soft measurement of coal mine gas emission based on quantum-behaved particle swarm optimization and deep learning

Fu Hua¹, Zhao Juncheng¹, Fu Yu¹, Lu Wanjie², Xu Yaosong¹

(1. Faculty of Electrical and Control Engineering, Liaoning Technical University, Liaoning 125105, China;

2. College of Mechanical Engineering, Liaoning Technical University, Liaoning 123000, China)

Abstract: The existing soft measurement methods of absolute gas emission generally do not consider the influence of the historical data of gas emission. To address this issue, a soft measurement model of gas emission based on the long short-term memory (LSTM) in deep learning is proposed. The time series of historical data of absolute gas emission and its related influencing factors are utilized for prediction. Due to the gradient problem, the LSTM model needs to pay special attention to control the learning rate to prevent the severe decreasing of prediction results. The LSTM cell structure is adjusted, and the softsign function is introduced to solve the gradient problem through its first derivative with relatively gentle changes. In this way, the network convergence is faster and less prone to saturation. In view of the existence of many hyperparameters in LSTM, the quantum-behaved particle swarm optimization (QPSO) algorithm is used to optimize the soft measurement accuracy of absolute gas emission. And the kernel-principal component analysis is utilized to reduce the dimension of measurement indexes to accelerate the convergence speed of the model. Comparing the improved model with the initial model, the improved model has higher accuracy and efficiency. The root mean squared error, mean absolute percentage error and goodness of fit determinant are 0.080, 0.82% and 0.988, respectively. Comparing the proposed model with ELM, PSO-SVM, PSO-BP and GRU models, the proposed model has smaller error and better measurement results than other models. Experimental results show that the proposed soft measurement model of gas emission has better performance.

Keywords: gas emission; soft measurement; deep Learning; long short-term memory; softsign function; quantum-behaved particle swarm optimization

收稿日期:2021-02-06 Received Date: 2021-02-06

* 基金项目:国家自然科学基金(51974151,71771111)、辽宁省高等学校(境)外培养项目(2019GJWZD002)、辽宁省高等学校创新团队项目(LT2019007)、辽宁省自然科学基金指导计划项目(20180550438)、辽宁省教育厅科技项目(LJ2019QL015)资助

0 引言

井下煤矿瓦斯事故频发,瓦斯涌出量是判断是否存在安全隐患的重要依据,对其进行精准有效的测量能够很大程度避免危险发生。由于井下环境特殊,开采过程机理复杂,瓦斯涌出量不易直接测量,因此可通过数学方法对其进行软测量^[1]。

近年来,许多学者提出了瓦斯涌出量的各种测量方法与模型。温廷新等^[2]将反向传播神经网络(back propagation neural network, BPNN)、粒子群算法(particle swarm optimization, PSO)和AdaBoost自适应算法融合,对瓦斯涌出量以分源预测的方式进行软测量。董晓雷等^[3]利用遗传算法寻找支持向量机(support vector machine, SVM)的最优惩罚参数 c 和核函数参数 g ,并结合SVM训练速度快且具有良好泛化性能的特点,建立了基于SVM耦合遗传算法的回采工作面瓦斯涌出量预测模型。徐耀松等^[4]提出一种改进的万有引力算法,训练BP神经网络的初始权值和阈值,提高了瓦斯涌出量的预测精度与收敛速度。

上述研究普遍从绝对瓦斯涌出量相关影响因素出发,通过将其他因素作为影响因子得到绝对瓦斯涌出量的测量值,未将瓦斯涌出量自身历史数据对当前乃至未来的影响考虑在内,因此,一些学者从时间序列的角度出发,兼顾绝对瓦斯涌出量自身因素的前后影响,使问题转化为具有非线性属性的绝对瓦斯涌出量在时间序列上的回归预测,利用历史数据对未来的瓦斯涌出量进行软测量。Yang等^[5]在灰色预测GM(1, 1)模型的基础上进行了二次参数拟合,将得到第二个拟合参数用于趋势预测,使用马尔可夫状态转移概率矩阵方法对其结果进行二次拟合。樊保龙等^[6]利用局部均值分解方法(local mean decomposition, LMD)方法将瓦斯涌出量的历史数据分解得到多个生产函数分量,对每个分量使用SVM函数拟合,但其未针对SVM参数优化问题进行讨论。施式亮等^[7]与樊保龙等相似,根据瓦斯涌出时序数据,针对非静态信号,使用经验模态分解(empirical mode decomposition, EMD)方法获得多个本征模态函数,对每个函数建立SVM模型,同时又使用PSO算法优化SVM参数,该模型的主要问题在于优化的模型易陷入局部最优,所得出的最佳参数未从全局出发考虑。代巍等^[8]通过变分模态分解将历史瓦斯涌出量分解为若干固有分量并分析其局部特征,分别建立相关向量机(relevance vector machine, RVM)模型,并通过差分进化(differential evolution, DE)算法优化参数。

不难发现,现有的从时间序列角度对绝对瓦斯涌出量进行软测量的研究,较多学者都通过有关支持向量机

的方法实现。由于绝对瓦斯涌出量相关因素具有非线性属性^[9],使得上述方法的精度提升有限。近年来,深度学习^[10]由于其精度高,抓取信息能力强等特点,应用愈加广泛,但其对于瓦斯涌出量软测量问题的可行性及效果研究较少。利用瓦斯涌出量相关因素的历史数据,提出改进深度学习中的长短时记忆网络模型(long short-term memory, LSTM)对未来的绝对瓦斯涌出量进行软测量,使用量子粒子群(quantum-behaved particle swarm optimization, QPSO)优化模型超参数,以达到较高的精度。为提升收敛速度,使用核主成分分析(kernel principal component analysis, KPCA)对数据做主成分提取,简化模型输入。

1 LSTM模型及超参数优化

1.1 LSTM瓦斯涌出量测量模型

LSTM可通过每个单元中的遗忘门(forget gate)、输入门(input gate)和输出门(output gate)以及由tanh激活函数构成的细胞单元状态(cell state)实现历史信息的取舍^[11]。LSTM虽然解决了传统循环神经网络存在的长期依赖问题^[12],处理梯度问题的能力也有了提升,但它依然需要十分注意学习率以防止梯度消失或梯度爆炸^[13]。softsign函数^[14]与LSTM单元中使用的tanh激活函数有相似之处,tanh与softsign函数数学表达如式(1)、(2),其函数曲线及一阶导数曲线如图1所示。

$$\tanh(x) = \frac{1 - e^{-2x}}{1 + e^{-2x}} \quad (1)$$

$$\text{softsign}(x) = \frac{x}{1 + |x|} \quad (2)$$

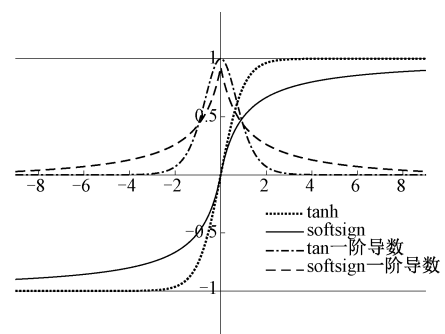


图1 Tanh与Softsign函数及其一阶导数曲线

Fig. 1 Tanh and Softsign functions and their first derivative curve

由图1可知,softsign函数较tanh函数的曲线更平坦,一阶导数变化相对缓和,因此能更好的解决梯度问题,使网络更快收敛且更不容易出现饱和。研究发现,通过softsign函数对LSTM单元加以改进,在单元状态中使

用 softsign 函数代替 tanh 函数,可使梯度问题得以更好的解决,迭代次数得以减少,预测效果也有提升。

改进的 LSTM 单元中,上一单元的输出与当前时刻的涌出量通过遗忘门与输入门决定历史数据与当前的瓦斯涌出量对未来的影响,即:

$$f_i = \sigma(W_f \cdot [h_{i-1}, x_i] + b_f) \quad (3)$$

$$i_i = \sigma(W_i \cdot [h_{i-1}, x_i] + b_i) \quad (4)$$

式中: σ 代表 sigmoid 函数; x 为单元输入; h 为单元输出; t 代表当前时刻^[15]; W 与 b 为各自的权重与偏置项,共同决定信息的取舍。

同时,包含当前瓦斯涌出量输入信息的单元状态通过 softsign 函数更新为:

$$C_i^- = \text{softsign}(W_c \cdot [h_{i-1}, x_i] + b_c) \quad (5)$$

则输出的单元状态 C_i 为:

$$C_i = f_i \circ C_{i-1} + i_i \circ C_i^- \quad (6)$$

式中:符号 \circ 代表 Hadamard 积^[16]。

将历史与当前瓦斯涌出量的信息经输出门,并通过当前输出的单元状态 C_i ,得到包含瓦斯涌出量信息的当前时刻的单元输出 h_i , 即:

$$o_i = \sigma(W_o \cdot [h_{i-1}, x_i] + b_o) \quad (7)$$

$$h_i = o_i \circ \tanh(C_i) \quad (8)$$

1.2 LSTM 超参数优化

LSTM 模型中包含许多超参数^[17],其中输入层单元个数与输入数据维数相同,全连接层单元个数与输出维数相同,其他无法直接确定且对瓦斯涌出量测量精度影响较大的超参数包括:隐含单元个数 G 、学习率 ξ 以及训练迭代次数 T 。若通过测试确定这 3 个超参数,需要大量实验,可使用寻优算法使其理想^[18-19]。量子粒子群基于量子计算改良了粒子群^[20],在多维搜索空间内,代表超参数的粒子在 $t+1$ 时刻的速度和位置信息更新为:

$$\omega = \omega_{\max} - \frac{n_k(\omega_{\max} - \omega_{\min})}{n_{\max}} \quad (9)$$

$$P_m^- = \frac{1}{n} \sum_{k=1}^n p_k^t \quad (10)$$

$$v^{t+1} = \eta_1 p_{id} + (1 - \eta_1) p_{gd} \quad (11)$$

$$x_{id}^{t+1} = v^{t+1} \pm \omega \cdot |P_m^- - x_{id}^t| \cdot \ln\left(\frac{1}{\eta_2}\right) \quad (12)$$

式中: v 为代表超参数的粒子在搜索空间的速度; x 为粒子位置; ω 为权重,控制平衡; $\omega_{\max} = 2, \omega_{\min} = 0.1$; n 为种群数量; P_m^- 为所有粒子适应度平均值; η 为 $[0, 1]$ 内的均匀随机数; n_k 和 n_{\max} 为当前和最大迭代次数; i 和 g 代表个体和全局, p_{id} 和 p_{gd} 为局部和全局最优粒子^[21]。

由式(9)~(12)得, ω 随 n_k 增大而减小,会降低 QPSO 的收敛速度与精度,搜寻速度取决于 p_{id} 和 p_{gd} ,若全局搜索能力与局部搜索能力矛盾时,需加以平衡。通过引入动态权重^[22],平衡搜寻能力,如式(13)、(14):

$$\omega_d = \frac{\frac{p_i}{P_m^-}}{(1 + e^{\frac{-p_i}{P_m^-}})^{n_k}} \quad (13)$$

$$v^{t+1} = \omega_d p_{id} + (1 - \omega_d) p_{gd} + \eta_1 p_{gd} \quad (14)$$

式中: ω_d 是动态权重; p_i 是第 i 个粒子的适应度。将 G 、 ξ 、 T 这 3 个超参数作为粒子,利用引入动态权重的 QPSO 对其寻优。

2 瓦斯涌出量软测量模型的构建

2.1 瓦斯涌出量影响因素核主成分分析

瓦斯涌出量及其相关影响因素的历史数据共同构成数据集 \tilde{X} , 则 $\tilde{X} = [X_1 \ X_2 \ \cdots \ X_p]^T$, 其中, p 为绝对瓦斯涌出量软测量指标的选取种类数, $X_p = [X_p(1) \ X_p(2) \ \cdots \ X_p(m)]$, m 为该指标在时间序列上排列后的样本大小。对 \tilde{X} 进行核主成分分析,将 \tilde{X} 映射到高维空间^[23], 即:

$$K = (K_{ij})_{m \times m} = K(X_i, X_j) = (\varphi(X_i), \varphi(X_j)) \quad (15)$$

式中: φ 为非线性映射, $i, j = 1, 2, \dots, m$ 。将 K 中心化得到 \tilde{K} , 并对其协方差矩阵特征分解^[24], 得到 N 个特征值 λ 和特征向量 μ 。筛选所有特征值中最大的 q 个特征值, 指定其贡献度为 m , 则通过这 q 个特征值及其对应的特征向量可计算提取主成分后的 X , 即:

$$X = \tilde{K}^T \cdot \left[\frac{1}{\sqrt{\lambda_1}} \mu_1, \frac{1}{\sqrt{\lambda_2}} \mu_2, \dots, \frac{1}{\sqrt{\lambda_q}} \mu_q \right] \quad (16)$$

2.2 瓦斯涌出量 QPSO-LSTM 软测量模型

设提取主成分后降至 q 维的瓦斯涌出量软测量的指标为 $X = [X_1 \ X_2 \ \cdots \ X_q]^T$, 取 X 的前 80% 作为训练集 R , 后 20% 作为测试集 E 。训练前对数据标准化以消除量纲, 对 R 中的数据采用零均值和标准方差的处理方法得到 R' , 处理方法如式(17)所示。

$$X'_{ij} = \frac{X_{ij} - \frac{\sum X_i}{0.8 \cdot m}}{\sqrt{\frac{1}{0.8 \cdot m} \sum \left(X_{ij} - \frac{\sum X_i}{0.8 \cdot m} \right)^2}} \quad (17)$$

式中: X_i 为 R 的第 i 行, $1 \leq i \leq n$, X'_{ij} 为 X_{ij} 的处理结果。记录处理过程中的均值与方差, 使用与 R 相同的参数标准化测试集 E , 可知处理得到的 E' 的均值与方差不一定为 0 和 1。

根据 R' 准备变量 $X_{R'}$ 及其响应 $Y_{R'}$ 。指定 $Y_{R'}$ 为 $X_{R'}$ 向后移动一个时间步, 并在 E' 中用同样方法指定 $X_{E'}$ 与 $Y_{E'}$ 。

将隐含单元个数 G 、学习率 ξ 以及训练迭代次数 T 这 3 个超参数作为粒子, 初始化种群大小, 使 G 的区间为 $[100, 300]$, T 为 $[1000, 2000]$, 初始学习率 ξ 为

[0.001, 0.01], 每隔 0.25 T 降低 ξ 至原来的 [0.1, 0.5]。使用引入动态权重的 QPSO 对 G 、 ξ 、 T 寻优, 在 R' 上迭代。每迭代一次, 更新一次 p_{id} 和 p_{gd} , 通过式(10)、(12) ~ (14) 更新速度和位置。在搜索种群空间内, 寻优通过适应度函数 fit 衡量结果。适应度的计算通过两种方式, 一种通过 R' 中预测值的均方误差实现, 如式(18), 另一种通过 R' 中预测曲线拟合情况实现, 如式(19)所示。

$$fit_1 = \frac{1}{0.8 \cdot m} \sum_{i=1}^{0.8 \cdot m} (Y_i - \tilde{Y}_i)^2 \tag{18}$$

$$fit_2 = \frac{\sum_{i=1}^{0.8 \cdot m} (Y_i - \tilde{Y}_i)^2}{\sum_{i=1}^{0.8 \cdot m} (\tilde{Y} - \tilde{Y}_i)^2} \tag{19}$$

式中: \tilde{Y}_i 为绝对瓦斯涌出量真实值, Y_i 代表当前训练得到的预测值。指定寻优迭代次数, 观察适应度迭代图, 若当前适应度在迭代的最后阶段趋于平缓, 则保留当前结果, 否则增加迭代次数, 重新寻优, 继续更新 p_{id} 和 p_{gd} 。通过比较两种适应度下误差, 确定最优的参数。每次寻优的过程中, 令模型在 R' 上通过式(20)、(21) 所示的反向传播实现反向传导, 利用式(3) ~ (8) 反复处理 $X_{R'}$ 与 $Y_{R'}$, 不断迭代使每个 LSTM 单元内部参数逼近最优解。

$$\tilde{\alpha} = \beta \tilde{\alpha} - (1 - \beta) d\alpha^2 \tag{20}$$

$$\alpha' = \alpha - \gamma \frac{d\alpha}{\sqrt{\tilde{\alpha}}} \tag{21}$$

式中: $\tilde{\alpha}$ 代表参数 α 梯度指数的加权平均值, α 代表当前更新的参数, 如权重 W 和偏置项 b , α' 代表更新后的参数

β 控制需要平均的步长, γ 控制更新的步长。模型每次更新, α' 的值赋给 α , 继续迭代, 直至迭代结束, 确定模型参数, 输出预测值 Y'_{ij} , 再对 Y'_{ij} 利用式(22) 反标准化, 得到最终的绝对瓦斯涌出量预测值 Y_{ij} 。

$$Y_{ij} = Y'_{ij} \cdot \sqrt{\frac{1}{0.8 \cdot m} \sum \left(X_{ij} - \frac{\sum X_i}{0.8 \cdot m} \right)^2} + \frac{\sum X_i}{0.8 \cdot m} \tag{22}$$

3 实验测试及分析

为验证 QPSO-LSTM 瓦斯涌出量软测量模型的可靠性, 选取山西潞安集团李村煤矿瓦斯涌出量及相关影响因素的历史数据进行测试。

3.1 瓦斯涌出量影响因素预处理

回采工作面瓦斯涌出量影响因素较多^[25], 选取包含绝对瓦斯涌出量在内的 10 个影响因素, 分别是: 绝对瓦斯涌出量 X_1 、煤层瓦斯含量 X_2 、煤层深度 X_3 、煤层厚度 X_4 、采高 X_5 、开采强度 X_6 、工作面采出率 X_7 、推进速度 X_8 、邻近层瓦斯含量 X_9 、邻近层厚度 X_{10} 。选取上述因素近 10 000 组历史监测数据, 其中, 前 8 000 组样本用于软测量模型拟合, 后 2 000 组用于绝对瓦斯涌出量的预测。列举各类影响因素中 10 组数据, 如表 1 所示, 由绝对瓦斯涌出量历史 10 000 个数据构成的时间序列如图 2 所示, 对其利用小波变换^[26] 提取 5 层细节分量和近似分量, 将 1、2 层细节分量置零, 重构小波分解向量, 实现瓦斯涌出量数据的降噪, 降噪结果如图 3 所示。

表 1 回采工作面瓦斯涌出量监测数据
Table 1 Monitoring data of gas emission from mining face

样本	$X_1 /$ ($\text{m}^3 \cdot \text{min}^{-1}$)	$X_2 /$ ($\text{m}^3 \cdot \text{t}^{-1}$)	$X_3 /$ m	$X_4 /$ m	$X_5 /$ m	$X_6 /$ ($\text{t} \cdot \text{d}^{-1}$)	X_7	$X_8 /$ ($\text{m} \cdot \text{d}^{-1}$)	$X_9 /$ ($\text{m}^3 \cdot \text{t}^{-1}$)	$X_{10} /$ m
1	7.68	4.34	607	6.1	6.1	3 087	0.785	2.77	3.02	1.74
2	7.80	4.03	604	6.2	6.2	3 354	0.812	2.64	3.15	1.80
3	8.51	4.80	634	6.5	6.5	3 620	0.773	2.92	2.98	1.92
4	7.95	4.67	640	6.3	6.3	3 412	0.802	2.75	2.56	1.75
5	7.24	4.21	590	5.9	5.9	3 139	0.795	2.85	3.40	1.50
6	7.34	3.82	579	3.1	3.1	3 122	0.743	2.65	2.68	1.59
7	8.04	4.62	629	6.4	6.4	3 456	0.803	2.80	3.35	1.61
8	7.69	4.43	609	6.1	5.9	3 620	0.781	2.79	3.31	1.67
9	7.48	4.21	601	5.2	6.1	2 956	0.694	2.68	3.24	1.73
10	8.02	4.52	613	5.9	6.3	3 056	0.810	2.81	3.16	1.67




图2 瓦斯涌出量时间序列

Fig. 2 Time series of gas emission




图3 瓦斯涌出量时间序列降噪结果

Fig. 3 Noise reduction results of gas emission time series

对10类软测量指标降噪后进行核主成分分析,按顺序排列各个主成分的方差贡献度并计算累计方差贡献度,如表2所示。

表2 主成分贡献度及累计贡献度

Table 2 Principal component contribution and cumulative contribution

	方差贡献度	累计方差贡献度
第一主元	0.619 0	0.619 0
第二主元	0.148 7	0.767 7
第三主元	0.092 9	0.860 6
第四主元	0.041 0	0.901 6
第五主元	0.036 3	0.937 9
第六主元	0.019 2	0.957 1
第七主元	0.015 7	0.972 8
第八主元	0.013 4	0.986 2
第九主元	0.009 8	0.996 0
第十主元	0.004 0	1

由表2可知,前3个主元的累计方差贡献度为0.8606,表明这3个主元能够实现所有主元表达能力的85%以上,因此选取前3个主元作为瓦斯涌出量软测量模型的输入向量,列举每个主元的特征向量中的10个元素,如表3所示。

表3 主成分的特征向量

Table 3 Eigenvectors of principal components

第一主元	第二主元	第三主元
-0.251 9	0.044 9	-0.187 1
0.066 3	-1.414 2	-0.343 1
1.948 6	1.728 5	1.216 4
0.464 0	-0.179 6	1.528 3
-1.418 4	0.942 8	-1.070 9
-1.153 3	-1.302 0	-1.642 7
0.702 6	0.381 6	0.956 5
-0.225 4	0.269 4	-0.083 2
-0.782 1	-0.965 3	-0.499 1
0.649 5	0.493 9	0.124 8

3.2 LSTM模型对比实验

1) softsign函数与tanh函数对比实验

针对softsign函数与tanh函数的软测量结果不同,控制瓦斯涌出量LSTM软测量模型除激活函数以外的其他参数相同,指定LSTM层数为3,在预测样本中使用两种函数的结果如图4所示。




图4 Softsign函数与tanh函数的测量结果

Fig. 4 Measurements of Softsign and tanh functions

根据图4中的结果,通过均方根误差(RMSE)、平均绝对百分比误差(MAPE)^[27]和拟合优度决定系数(R²)^[28]3种指标,计算绝对对瓦斯涌出量的软测量结果的误差,得出不同层数对结果的影响。3种评价指标的数学表达式为:

$$\delta_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \tilde{Y}_i)^2} \quad (23)$$

$$\delta_{\text{MAPE}} = \frac{1}{n} \sum_{i=1}^n \left| \frac{Y_i - \tilde{Y}_i}{\tilde{Y}_i} \right| \times 100\% \quad (24)$$

$$\delta_{\text{R}^2} = 1 - \frac{\sum_{i=1}^n (Y_i - \tilde{Y}_i)^2}{\sum_{i=1}^n (\bar{Y} - \tilde{Y}_i)^2} \quad (25)$$

式中: n 为测试集样本个数; Y_i 为预测值; \tilde{Y}_i 为实际值。3种误差中, RMSE与MAPE的值越小,软测量精度越高,

决定系数 R^2 的结果越接近 1,软测量的效果越理想。对比实验的结果如表 4。

表 4 不同激活函数误差对比

Table 4 Error comparison of different activation functions

激活函数	RMSE	MAPE/%	R^2
softsign	0.131	1.08	0.967
tanh	0.142	1.17	0.961

由表 4 易知,使用 softsign 函数的软测量模型的精度要高于使用 tanh 函数。此外,在表 4 的实验中,使用 softsign 函数的模型进行了约 500 轮迭代后,绝对瓦斯涌出量软测量结果趋于稳定,若要求使用 tanh 函数的模型的精度近似达到 softsign 函数的精度,需继续迭代约 500 轮。由此可得,使用 softsign 函数可使迭代次数减少,收敛速度加快,提高测量精度。

2) 不同 LSTM 层数对比实验

控制瓦斯涌出量 LSTM 软测量模型除层数以外的其他参数相同,使用 softsign 函数,分别令 LSTM 层数为 1 ~ 6,得到不同 LSTM 层数的测量结果及根据 3 种评价标准得到的误差结果。不同层数情况下,预测样本的绝对瓦斯涌出量测量结果如图 5 所示,其误差结果如表 5 所示。




图 5 不同 LSTM 层数的测量结果

Fig. 5 Measurements for different LSTM layers

表 5 不同 LSTM 层数误差对比

Table 5 Error comparison of different LSTM layers


LSTM 层数	RMSE	MAPE/%	R^2	训练时间
1	0.211	1.97	0.914	7 min 32 s
2	0.144	1.24	0.960	14 min 40 s
3	0.131	1.08	0.967	21 min 22 s
4	0.130	1.07	0.968	28 min 31 s
5	0.135	1.13	0.965	35 min 5 s
6	0.138	1.19	0.963	43 min 1 s

由测试结果可知,当层数 ≤ 4 时,3 种误差均随层数的增加而减小,当层数大于 4 时,误差的大小却均不降反


升,因此需控制 LSTM 在 4 层之内。此外,当层数小于等于 3 时,层数的增加使得误差的降低程度较为显著,而达到 4 层时,其误差较 3 层没有明显的减小,但所需的训练时间却增长了许多。因此,3 层 LSTM 可使瓦斯涌出量软测量模型在保证误差较低的同时,能够尽可能的缩短训练时间,综合实用性较强。

3.3 瓦斯涌出量 QPSO-LSTM 模型测量结果

控制量子粒子群算法其他参数相同,分别以式(18)、(19)两种适应度函数,在标准化后的训练集上寻优迭代,使 LSTM 超参数逼近最优解,两种适应度函数的寻优过程如图 6 所示。



(a) fit_1 寻优迭代图
(a) Optimizing iteration diagram of fit_1



(b) fit_2 寻优迭代图
(b) Optimizing iteration diagram of fit_2

图 6 两种适应度函数的寻优迭代过程

Fig. 6 Optimizing iteration processes for two fitness functions

由图 6 可知,两种适应度结果最终均保持稳定,当前寻优有效,其各自的绝对瓦斯涌出量测量结果如图 7 所示。




图 7 两种适应度函数的测量结果

Fig. 7 Measurement of two fitness functions

从图7可以看出,两种适应度函数寻优后的测量结果很相似,计算各自的RMSE、MAPE和 R^2 ,如表6所示。

表6 两种适应度函数寻优测量结果误差对比
Table 6 Error comparison of two fitness functions for optimizing measurement results

适应度函数	RMSE	MAPE/%	R^2
fit_1	0.084	0.84	0.986
fit_2	0.080	0.82	0.988

由表6可知,使用两种适应度函数寻优后的模型的测量精度均高于原始模型,其中,使用式(19)所示的适应度函数 fit_2 进行寻优后的结果相对较好。瓦斯涌出量QPSO-LSTM软测量模型预测样本的最终测量结果如图8所示。




图8 瓦斯涌出量QPSO-LSTM软测量模型测量结果
Fig. 8 Measurement of QPSO-LSTM soft measurement model for gas emission

3.4 不同模型误差对比

将本文提出的软测量模型与多种时间序列回归模型对比,比较预测样本的测量结果。与本文模型进行对比实验的模型包括:ELM模型、PSO-SVM模型、PSO-BP模型以及GRU模型。通过RMSE、MAPE和 R^2 3种评价指标进行对比,测量结果如图9所示,误差对比如表7所示。




图9 不同模型瓦斯涌出量测量结果
Fig. 9 Measurement of gas emission from different models

由表7可得,本文提出的瓦斯涌出量软测量模型的误差均小于其他模型,其中均方根误差和平均绝对百分比误差可分别缩小至0.080和0.82%,决定系数可优化至0.988。由结果可知,提出的瓦斯涌出量QPSO-LSTM软测量模型具有较高的精度,可以准确地预测井下瓦斯涌出量。

表7 不同模型测量结果误差对比
Table 7 Error comparison of measurements for different models

模型	RMSE	MAPE/%	R^2
ELM	0.147	1.49	0.958
PSO-SVM	0.106	1.05	0.978
PSO-BP	0.176	1.45	0.941
GRU	0.129	1.07	0.967
本文模型	0.080	0.82	0.988

4 结论

深度学习在瓦斯涌出量的测量问题上,可通过将其转化为具有非线性属性的绝对瓦斯涌出量及其相关影响因素在时间序列上的回归预测实现。利用历史数据对未来一段时间的瓦斯涌出量进行软测量,由深度学习中的LSTM构造的模型具有很大的使用价值;LSTM模型中,使用softsign函数代替tanh函数可以更好的解决梯度问题,减少模型的迭代次数,使模型具有更快的收敛速度,以提高绝对瓦斯涌出量的测量效率。使用引入动态权重的量子粒子群算法优化LSTM模型的参数,可使瓦斯涌出量测量精度更高。其中,均方根误差可缩小至0.080,平均绝对百分比可误差缩小0.82%,拟合优度决定系数可达0.988。通过实验对比可知,提出的瓦斯涌出量软测量模型具有更好的表现。

参考文献

- [1] 赵超,陈肇泉,王斌,等. 基于互信息和IGSA优化ELM的重整芳烃收率软测量[J]. 仪器仪表学报, 2019,40(3):255-263.
ZHAO CH, CHEN ZH Q, WANG B, et al. Soft sensor modeling for reforming aromatic hydrocarbon yield based on MI and IGSA optimized ELM[J]. Chinese Journal of Scientific Instrument, 2019,40(3):255-263.
- [2] 温廷新,孙雪,孔祥博,等. 基于PSO-BP-AdaBoost模型的瓦斯涌出量分源预测研究[J]. 中国安全科学学报, 2016,26(5):94-98.
WEN T X, SUN X, KONG X B, et al. Research on prediction of gas emission quantity with sub sources basing

- on PSOBP-AdaBoost[J]. *China Safety Science Journal*, 2016,26(5):94-98.
- [3] 董晓雷,贾进章,白洋,等. 基于SVM耦合遗传算法的回采工作面瓦斯涌出量预测[J]. *安全与环境学报*, 2016,16(2):114-118.
DONG X L, JIA J ZH, BAI Y, et al. Prediction for gas-gushing amount from the working face of stope based on the SVM coupling genetic algorithm[J]. *Journal of Safety and Environment*, 2016,16(2):114-118.
- [4] 徐耀松,齐翠玉,丰胜成. 基于IGSA-BP网络的瓦斯涌出量预测模型[J]. *电子测量与仪器学报*, 2019, 33(5):111-117.
XU Y S, QI C Y, FENG SH CH. Gas emission prediction model based on IGSA-BP network[J]. *Journal of Electronic Measurement and Instrumentation*, 2019, 33(5):111-117.
- [5] YANG F F, JIAO Y F, ZHANG J F, et al. Study on simultaneous extraction of coal and gas and clean utilization in high-gas outburst mines [J]. *IOP Conference Series: Earth and Environmental Science*, 2020, 510(2), DOI: 10.1088/1755-1315/510/2/022013.
- [6] 樊保龙,白春华,李建平. 基于LMD-SVM的采煤工作面瓦斯涌出量预测[J]. *采矿与安全工程学报*, 2013, 30(6):946-952.
FAN B L, BAI CH H, LI J P. Forecasting model of coalface gas emission based on LMD-SVM method[J]. *Journal of Mining & Safety Engineering*, 2013, 30(6):946-952.
- [7] 施式亮,李润求,罗文柯. 基于EMD-PSO-SVM的煤矿瓦斯涌出量预测方法及应用[J]. *中国安全科学学报*, 2014, 24(7):43-49.
SHI SH L, LI R Q, LUO W K. Method for predicting coal mine gas emission based on EMD-PSO-SVM and its application [J]. *China Safety Science Journal*, 2014, 24(7):43-49.
- [8] 代巍,付华,冀常鹏,等. 回采工作面瓦斯涌出量VMD-DE-RVM区间预测方法[J]. *中国安全科学学报*, 2018, 28(9):109-115.
DAI W, FU H, JI CH P, et al. Interval prediction method for gas emission from coal mining face based on VMD-DE-RVM [J]. *China Safety Science Journal*, 2018, 28(9):109-115.
- [9] 秦冰,郝建峰,梁冰,等. 煤与瓦斯共采非线性约束多变量时空协同优化模型[J]. *煤炭学报*, 2019, 44(S2):593-600.
QIN B, HAO J F, LIANG B, et al. Nonlinear constrained multivariable spatiotemporal collaborative optimization model for coal and gas co-mining [J]. *Journal of China Coal Society*, 2019, 44(S2):593-600.
- [10] HUANG S C, PAREEK A, SEYYEDI S, et al. Fusion of medical imaging and electronic health records using deep learning: A systematic review and implementation guidelines[J]. *Npj Digital Medicine*, 2020, 3(1), DOI: 10.1038/s41746-020-00341-z.
- [11] NAVARES R, AZNARTE J L. Predicting air quality with deep learning LSTM: Towards comprehensive models[J]. *Ecological Informatics*, 2020, 55, DOI: 10.1016/j.ecoinf.2019.101019.
- [12] PREETHI D, NEELU K. EFS-LSTM (ensemble-based feature selection with LSTM) classifier for intrusion detection system [J]. *International Journal of e-Collaboration (IJeC)*, 2020, 16(4):72-86.
- [13] LONDHE A N, ATULKAR M. Semantic segmentation of ECG waves using hybrid channel-mix convolutional and bidirectional LSTM [J]. *Biomedical Signal Processing and Control*, 2021, 63, DOI: 10.1016/J.BSPC.2020.102162.
- [14] 王红霞,周家奇,辜承昊,等. 用于图像分类的卷积神经网络中激活函数的设计[J]. *浙江大学学报(工学版)*, 2019, 53(7):1363-1373.
WANG H X, ZHOU J Q, GU CH H, et al. Design of activation function in CNN for image classification [J]. *Journal of Zhejiang University (Engineering Science)*, 2019, 53(7):1363-1373.
- [15] 邵伟明,葛志强,李浩,等. 基于循环神经网络的半监督动态软测量建模方法[J]. *电子测量与仪器学报*, 2019, 33(11):7-13.
SHAO W M, GE ZH Q, LI H, et al. Semisupervised dynamic soft sensing approaches based on recurrent neural network [J]. *Journal of Electronic Measurement and Instrumentation*, 2019, 33(11):7-13.
- [16] 陈伟华,南鹏飞,闫孝姮,等. 基于深度学习的采煤机截割轨迹预测及模型优化[J]. *煤炭学报*, 2020, 45(12):4209-4215.
CHEN W H, NAN P F, YAN X H, et al. Prediction and model optimization of memory cutting trajectory based on deep learning [J]. *Journal of China Coal Society*, 2020, 45(12):4209-4215.
- [17] LI W D Y, NG W W Y, WANG T, et al. HELP: An LSTM-based approach to hyperparameter exploration in neural network learning [J]. *Neurocomputing*, 2021, 442:161-172.
- [18] VENKATESWARLU G, SISHAJ P S. PSO-LSTM for short term forecast of heterogeneous time series electricity price signals [J]. *Journal of Ambient Intelligence and*

- Humanized Computing, 2020; 1-11.
- [19] TRANG T K T, TAESAM L, JU Y S, et al. Deep learning-based maximum temperature forecasting assisted with meta-learning for hyperparameter optimization [J]. Atmosphere, 2020, 11 (5), DOI: 10.3390/atmos11050487.
- [20] WEI CH L, WANG G G. Hybrid annealing krill herd and quantum-behaved particle swarm optimization [J]. Mathematics, 2020, 8(9): 1403-1403.
- [21] NIU W J, FENG ZH K, CHENG CH T, et al. Forecasting daily runoff by extreme learning machine based on quantum-behaved particle swarm optimization [J]. Journal of Hydrologic Engineering, 2018, 23 (3), DOI: 10.1061/(ASCE) HE.1943-5584.0001625.
- [22] 郭兴海, 计明军, 温都苏, 等. “最后一公里”配送的分布式多无人机的任务分配和路径规划 [J/OL]. 系统工程理论与实践: 1- 28 [2021-03-30]. <http://kns.cnki.net/kcms/detail/11.2267.N.20200923.1021.004.html>.
GUO X H, JI M J, WEN D S, et al. Task assignment and path planning for distributed multiple unmanned aerial vehicles in the “last mile” [J/OL]. Systems Engineering-Theory & Practice: 1- 28 [2021-03-30]. <http://kns.cnki.net/kcms/detail/11.2267.N.20200923.1021.004.html>.
- [23] ROOPA H, ASHA T. Feature extraction of chest X-ray images and analysis using PCA and kPCA [J]. International Journal of Electrical and Computer Engineering (IJECE), 2018, 8 (5), DOI: 10.11591/ijece.v8i5.pp3392-3398.
- [24] CHEN B S, HUANG D CH, ZHANG F J. The modeling method of a vibrating screen efficiency prediction based on KPCA and LS-SVM [J]. International Journal of Pattern Recognition and Artificial Intelligence, 2019, 33(7), DOI: 10.1142/S0218001419500095.
- [25] 付华, 谢森, 徐耀松, 等. 基于 ACC-ENN 算法的煤矿瓦斯涌出量动态预测模型研究 [J]. 煤炭学报, 2014, 39(7): 1296-1301.
FU H, XIE S, XU Y S, et al. Gas emission dynamic prediction model of coal mine based on ACC-ENN algorithm [J]. Journal of China Coal Society, 2014, 39(7): 1296-1301.
- [26] BALDAZZI G, SOLINAS G, DEL V J, et al. Systematic analysis of wavelet denoising methods for neural signal processing [J]. Journal of Neural Engineering, 2020, DOI: 10.1088/1741-2552/abc741.
- [27] MAXIM V B, SERGEY G E. A nonlinear method of learning neuro-fuzzy models for dynamic control systems [J]. Applied Soft Computing Journal, 2020, 88, DOI: 10.1016/j.asoc.2019.106030.
- [28] 张丽强, 丛伟, 董罡, 等. 基于多元线性回归的单相电表相别判断方法 [J]. 电力自动化设备, 2020, 40(5): 144-156+187.
ZHANG L Q, CONG W, DONG G, et al. Method for single-phase electric meter phase identification based on multiple linear regression [J]. Electric Power Automation Equipment, 2020, 40(5): 144-156+187.

作者简介



付华, 1984 年于阜新矿业学院获得学士学位, 1994 年于阜新矿业学院获得硕士学位, 2006 年于辽宁工程技术大学获得博士学位, 现为辽宁工程技术大学教授, 主要研究方向为煤矿瓦斯检测、智能检测和数据融合技术。

E-mail: fxfuhua@163.com

Fu Hua received her B. Sc. degree and M. Sc. degree both from Fuxin Mining Institute in 1984 and 1994, and received her Ph. D. degree from Liaoning Technical University in 2006. She is currently a professor at Liaoning Technical University. Her main research interests include coal mine gas detection, intelligent detection and data fusion technology.



赵俊程 (通信作者), 2015 年于辽宁工程技术大学获得学士学位, 现为辽宁工程技术大学硕士研究生, 主要研究方向为煤矿瓦斯智能检测、检测技术与自动化装置。

E-mail: juncheng_orange@163.com

Zhao Juncheng (Corresponding author) received his B. Sc. degree from Liaoning Technical University in 2015. He is currently a master student at Liaoning Technical University. His main research interests include intelligent detection of coal mine gas, detection technology and automation device.