

基于 VMD-CNN-BiLSTM 的瓦斯浓度预测模型

莘宇 陈果 宋佳铃 周旭*

华北理工大学应急管理与安全工程学院 唐山 063210

摘要: 针对煤矿瓦斯浓度时间序列的非平稳特性及多因素耦合影响导致的预测精度不足问题, 创新性地提出基于变分模态分解-卷积神经网络-双向长短期记忆网络 (VMD-CNN-BiLSTM) 的混合瓦斯浓度预测模型。以内蒙古某煤矿的瓦斯浓度数据为基础, 采用 VMD 算法对瓦斯浓度时序数据进行多尺度分解, 降低非平稳性干扰; 运用卷积神经网络 (CNN) 提取分解后模态分量的局部时序特征; 最后结合 BiLSTM 捕捉序列的前后向依赖关系, 利用 BiLSTM 的输出层进行预测, 得到未来短期内的瓦斯浓度值。实验结果表明, 该模型在 MSE (4.69E-08)、RMSE (3.77E-05)、MAE (0.000545818) 和 R^2 (0.9976) 等评价指标上表现优异, 相较于传统方法, 该模型在瓦斯浓度预测中显著提升了预测精度和稳定性, 验证了模型在特征提取、非线性映射和时序建模方面的协同优势, 为煤矿安全监测提供了更可靠的智能预警方案。

关键词: 瓦斯浓度预测; 变分模态分解; 卷积神经网络; 双向长短期记忆网络

引言

煤矿瓦斯事故长期以来频繁发生, 对我国矿井工人的生命安全构成严重威胁, 也极大地阻碍了采矿产业的稳健前行。瓦斯浓度不仅呈现出显著的非线性与周期性特征, 还受到地质构造、通风条件、采煤工艺等多种复杂因素的交互影响, 这使得对其进行精准预测极具挑战。基于此, 瓦斯浓度的有效预测不仅能够预防瓦斯事故提供关键支撑, 也对保障矿井生产的安全与可持续发展, 有着极其重要的现实意义。

为实现煤矿瓦斯浓度的有效预测, 众多学者开展了广泛而深入的研究, 将多种机器学习算法引入该领域, 致力于提升预测的精度。孙林等^[1]运用最小二乘支持向量机 (LS-SVM), 对回采工作面瓦斯涌出量展开预测, 模型运行稳定, 完全契合瓦斯涌出量实时在线预测的严苛要求, 实现精准预测。温廷新等^[2]创新性地因子分析理论与随机森林算法相结合, 用于煤与瓦斯突出等级的预测。实践证明, 该预测模型不仅准确率高, 而且具有很强的实际应用价值。姚青华等人^[3]对于矿井瓦斯浓度预测, 深入研究基于改进 BP 神经网络^[4], 在数据处理和浓度预测方面表现得更为精准高效, 大幅提升了预测的精准度。近年来, 深度学习方法的兴起, 为瓦斯浓度预测带来新的突破, 进一步提高了预测的准确性。刘超等人^[5]提出, 运用卷积神经网络 (CNN)^[6]提取瓦斯浓度时间序列的变化趋势及局部关联特征, 再借助门控循环单元 (Gate Recurrent Unit, GRU)^[7]实现精准预测。兰

海平等^[8]构建了基于 LSTM^[9]的瓦斯浓度预测与防突预警系统, 显著提升了预测的精确性。综上, 一系列研究充分表明, 数学方法与计算技术的有机结合, 在提升瓦斯涌出量预测效果方面发挥了关键作用, 推动着煤矿瓦斯防治技术不断进步。

研究表明, 尽管当前瓦斯浓度预测模型在精度提升已取得显著进展, 但瓦斯在时间序列中的非平稳特性仍是一个巨大的挑战, 增加了预测的复杂性。因此, 有必要进一步优化模型以更好地进行精准预测。本文利用内蒙古某煤矿实时监测数据, 基于 CNN-BiLSTM 模型的预测, 并将其与 CNN 和 BP、RNN、LSTM、MLP 等模型结合的组合模型的性能进行比较分析, 证明 CNN-BiLSTM 瓦斯预测模型的优越性。进一步引入 VMD 信号分解技术对原始瓦斯时序数据进行多尺度特征提取, 构建 VMD-CNN-BiLSTM 预测模型, 能够精准捕捉瓦斯变化的复杂波动特征, 提升时序预测的可靠性与准确性, 显著增强了矿井安全风险防控的科学决策能力。

1 基础模型

1.1 VMD

VMD 是一种自适应的信号分解方法, 它将输入的时间序列信号分解为多个内在模态分量 (IMFs), 每个 IMF 都代表信号中的一个独特频带或时间尺度, 通过对模态分量的带宽和中心频率进行约束, 确保分解得到的 IMFs 在频域上有良好的分离性和紧凑性, 从而有助于提取出原始数据中的

有用信息和特征。因此，VMD 方法适用于处理和分析复杂、非线性的瓦斯气体浓度时间序列数据。VMD 算法将信号分解问题转化为一个变分问题，目标是最小化以下函数^[10]：

$$\min_{u_1, u_2, \dots, u_k} \sum_{k=1}^K (\alpha_k \| \mathcal{D}(u_k) \|_2^2 + \beta_k \| \mathcal{H}(\mathcal{D}(u_k)) \|_1) + \lambda \| f - \sum_{k=1}^K u_k \|_2^2$$

其中， u_k 是第 k 个模态， α_k 和 β_k 是控制带宽的参数， \mathcal{D} 是微分算子， \mathcal{H} 是 Hilbert 变换， λ 是平衡项系数。每个模态 $u_k(t)$ 定义为幅度调制 - 频率调制 (AM-FM) 信号：

$$u_k(t) = A_k(t) \cos(\phi_k(t))$$

其中是 $A_k(t)$ 瞬时幅度， $\phi_k(t)$ 是瞬时相位，其导数 $\omega_k(t) = \phi_k'(t)$ 是瞬时频率^[11]。每个模态的带宽通过 H1 高斯平滑性的位移信号来估计。

1.2 CNN

卷积神经网络 (CNN) 是深度学习领域常用的特征提取算法，对于局部和全局特征提取具有强大的优越性，使用 CNN 对数据进行特征提取。CNN 由多个卷积层、池化层和全连接层组成。卷积层通过卷积核在输入数据上滑动，提取局部特征；池化层则对卷积层的输出进行下采样，减少数据的维度和计算量；全连接层则将提取的特征进行组合和分类。在瓦斯浓度预测中，将时间序列数据转换为二维矩阵形式作为 CNN 的输入，通过卷积和池化操作，提取出数据中的时空特征，为后续的 BiLSTM 处理提供基础。

$$h_c = \max_k (W_c \cdot x + b_c)$$

式中， W_c 和 b_c 分别是卷积核和偏置项， \max 表示池化操作，目标是在时间维度上取最大值。

1.3 BiLSTM

利用 CNN 提取出时序特征后，使用 BiLSTM 对时间序列数据进行处理。BiLSTM 由前向 LSTM 和后向 LSTM 组成，能够同时捕捉时间序列数据中的前向和后向依赖关系。在瓦斯浓度预测中，我们将 CNN 提取的特征作为 BiLSTM 的输入，通过前向和后向 LSTM 的交互作用，捕捉数据中的长期依赖关系，同时利用 BiLSTM 的输出层进行预测，得到未来短期内的瓦斯浓度值。

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \\ C_t = f_t * C_{t-1} + i_t * \tilde{C}_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) h_t = o_t * \tanh(C_t)$$

式中， f_t ， i_t ， o_t 分别是遗忘门、输入门和输出门的

激活值， C_t 是单元状态， h_t 是隐藏状态， σ 是 sigmoid 函数， $*$ 表示主元素乘法。

2 瓦斯浓度预测模型

煤矿井下动态环境中瓦斯浓度受多因素耦合作用，传统方法因难以全面采集多源数据而存在分析局限。本研究基于时间序列的连续性特征，针对瓦斯浓度难以精准预测问题，构建 VMD-CNN-BiLSTM 模型。

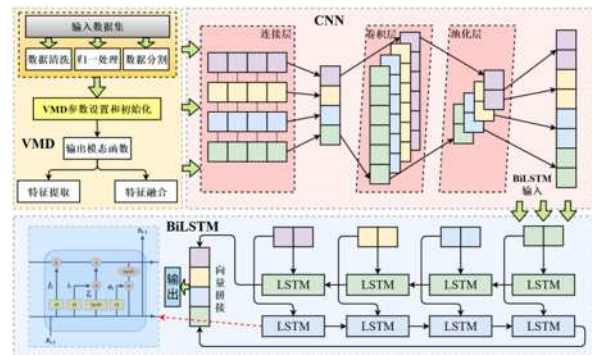


图 1 VMD-CNN-BiLSTM 预测模型

对于瓦斯浓度的预测，VMD-CNN-BiLSTM 主要通过如下步骤实现。

步骤 1：从原始数据集中提取瓦斯浓度序列，经预处理后采用变分模态分解 (VMD) 算法，将单维时序数据分解为多个固有模态分量 (IMF)，各模态分量分别表征瓦斯浓度的不同特征尺度。

步骤 2：初始化卷积神经网络 (CNN) 与双向长短期记忆网络 (BiLSTM) 的超参数，基于步骤 1 获得的瓦斯浓度模态分量的训练集进行模型训练，计算均方根误差损失函数，根据损失函数结果调整参数，待损失收敛后导入测试集进行测试，保存模型权重。

步骤 3：使用训练好的 VMD-CNN-BiLSTM 模型对瓦斯浓度模态分量的测试集进行测试，得到瓦斯浓度预测值。

步骤 4：通过选取的评价指标对 VMD-CNN-BiLSTM 模型最终的瓦斯浓度预测值进行分析评价。

3 实验结果

3.1 数据处理

本研究构建的瓦斯浓度预测模型，本文以内蒙古某煤矿工作面为实验背景，数据基础依赖于煤矿井下的实时监测网络，主要包括先进的瓦斯抽放钻孔和各类传感器，它们不间断地采集并记录井下环境中高精度和高频次的键气体浓度数据。

表 1 部分数据展示

O2	N2	CO	CO2	CH4
18.2292	81.5529	0.0028	0.2148	0.0003
16.7727	82.8538	0.0044	0.3685	0.0005
.....				
20.3384	73.4960	0.0007	0.1646	0.0003
18.4481	81.1614	0.0031	0.3870	0.0004

数据预处理直接关系到模型的训练效果和预测精度。

本研究的预处理过程主要包括数据清洗、缺失值处理及数据标准化。数据清洗旨在通过设定合理的阈值范围，识别与剔除原始数据集中的异常值，从而确保数据集的纯净度和一致性。针对缺失值，采用三次样条插值法进行填充，确保数据完整性。通过数据标准化，将所有特征数据统一到相同的尺度范围，消除量纲影响，从而优化了算法的收敛速度和泛化能力。使模型能够更加公平地对待每一个特征，优化训练过程，进一步提升模型的整体性能与预测精度。

3.2 模型评价指标

为体现模型的优越性能，通过量化比较不同模型的性能，在瓦斯数据输入的前提下，选取均方误差（MSE）、均方根误差（RMSE）、平均绝对误差（MAE）和决定系数（ R^2 ）作为评价指标。

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$$

其中， y_i 是真实值， \hat{y}_i 是预测值， \bar{y} 是真实值的平均值， n 是数据样本数量。以上指标分别从不同角度反映了模型的预测精度和拟合程度。

3.3 结果与分析

3.3.1 消融实验

经过模型训练和参数优化，VMD-CNN-BiLSTM 模型主要参数设置如下：滑动窗口大小为 24，训练集、测试集划分比例为 [0.8, 0.2]，BiLSTM 神经元数量为 64，卷积层数量为 3，选用 Relu 函数为激活函数；为了避免模型训练时出现过拟合现象，选用 Adam 自适应模型优化器训练模型，学习率设置为 0.001，迭代轮次为 100 轮。

对瓦斯浓度数据集进行 VMD-CNN-BiLSTM 输入输出的预测。在 VMD-CNN-BiLSTM 模型中，VMD 算法首先被用于对瓦斯浓度数据进行分解，得到多个 IMF 分量之后，将 IMF 分量输入到 CNN 中提取局部特征。CNN 通过卷积操作、

激活函数和池化操作生成用于预测的特征向量，继续输入到 BiLSTM 中，使之捕捉时间序列中的前向和后向依赖关系，最终输出所预测的瓦斯气体浓度。训练效果如下表所示：

表 2 模型性能评估指标参数

气体	MSE	RMSE	MAE	R^2
瓦斯	4.69E-08	3.77E-05	0.000545818	0.9976

上述结果清晰呈现了 VMD - CNN - BiLSTM 模型在瓦斯浓度数据输入输出预测场景下的卓越性能，从数据层面来看，该模型在预测过程中 R^2 值高达 0.9976，MSE、RMSE 和 MAE 都非常小，有力地证实了 VMD - CNN - BiLSTM 模型在瓦斯浓度预测方面具备极高的准确性。由此可见，VMD - CNN - BiLSTM 模型在瓦斯浓度预测预警中表现出色，能精准预测浓度变化，为瓦斯相关作业环境的安全提供坚实保障。

3.3.2 对比模型分析

本文从多维度进行模型对比分析。在模型选择层面，选定 BP、RNN、LSTM 以及 MLP 这几种具有代表性的模型与 BiLSTM 进行对比。BP 作为传统神经网络的典型，RNN 开启序列数据处理的先河，LSTM 有效攻克 RNN 梯度难题，MLP 构建起多层感知的基础范式，而 BiLSTM 则在双向捕捉序列信息上独具优势，将它们纳入对比，搭建起全面且极具参考价值的评估框架。通过严谨的模型对比与多维度的性能评估，CNN - BiLSTM 在复杂任务与多样化数据场景下的卓越性能得以充分展现。

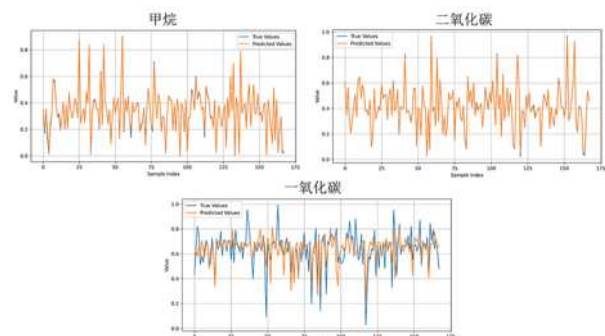


图 2 瓦斯浓度预测数值在验证集的拟合曲线

通过构建并训练 CNN-BiLSTM 模型，实验结果表明该方法具有良好的预测性能。如图 2 所示，模型在验证集上呈现出瓦斯浓度预测值与真实值的高度吻合特征，充分证明预测曲线与实测数据具有良好的一致性。经测试集评估验证，模型损失函数值稳定收敛至 0.0001 量级，充分验证了模型不仅具备优异的学习能力，同时展现出强大的泛化性能。

表 3 模型评价指标对比

气体	组合模型	MSE	RMSE	MAE	R ²
瓦斯	CNN-BP	6.6101E-09	8.1302E-05	5.9685E-05	0.8815
	CNN-RNN	7.3125E-09	8.5513E-05	6.9812E-05	0.8689
	CNN-LSTM	1.9461E-08	0.0001	0.0001	0.7256
	CNN-MLP	2.4491E-08	0.0002	0.0001	0.5609
	CNN-BiLSTM	6.3463E-09	7.9664E-05	5.7970E-05	0.8862

通过对表 3 数据深入剖析可知，在瓦斯浓度预测任务中，CNN - BiLSTM 模型性能卓越。其 MSE、RMSE 和 MAE 分别低至 6.3463E - 09、7.9664E - 05 和 5.7970E - 05，均低于其他模型，且 R² 值高达 0.8862，是所有模型中最高的，这表明该模型在解释瓦斯浓度变化方面优势独特。反观 CNN - LSTM 和 CNN - MLP 模型，虽然 MSE、RMSE 和 MAE 值同样很低，但 R² 值相对较低，反映出它们在解释数据变异方面能力欠佳，推测是过拟合或数据预处理异常所致。

综合来看，CNN - BiLSTM 模型在瓦斯浓度预测中综合性性能更为突出，并且在瓦斯浓度预测任务中性能一致性高，展现出较强的鲁棒性与适应性，其在各评价指标数值上的显著优势，意味着该模型不仅预测误差小，还能更精准地阐释气体浓度变化的内在机制及规律。

4 结论

本文提出了一种基于变分模态分解（VMD）、卷积神经网络（CNN）与双向长短期记忆网络（BiLSTM）的混合预测模型（VMD-CNN-BiLSTM），用于解决煤矿瓦斯浓度时间序列的非平稳性及多因素耦合导致的预测精度不足问题。利用 VMD 对原始瓦斯浓度信号进行频域分解，生成具有独立频率特性的模态分量，有效降低数据非平稳性干扰并避免模态混叠；结合 CNN 的卷积和池化操作对模态分量进行局部时序特征提取，并借助 BiLSTM 的双向时序依赖捕捉能力，融合时间序列的前向与后向长期趋势及周期性变化，实现瓦斯浓度的精准预测。实验结果表明，该模型对瓦斯、一氧化碳和二氧化碳浓度预测的均方误差（MSE）、均方根误差（RMSE）和平均绝对误差（MAE）分别为 4.69E-08，3.77E-05 和 0.000545818，

显著低于传统模型，决定系数（R²）为 0.9976，验证了

其优越的预测性能与鲁棒性。该模型不仅为煤矿瓦斯灾害预警提供了可靠技术支持，其融合信号分解与深度学习的创新框架也为非平稳时序预测任务提供了重要参考。

参考文献：

- [1] 孙林, 杨世元. 基于 LS-SVM 的回采工作面瓦斯涌出量预测 [J]. 煤炭学报, 2008, 33(12): 1377-1380.
- [2] 温廷新, 张波, 邵良杉. 煤与瓦斯突出预测的随机森林模型 [J]. 计算机工程与应用, 2014, 50(10): 233-237.
- [3] 姚青华, 邱本花. 基于改进 BP 神经网络的矿井瓦斯浓度预测算法 [J]. 煤炭技术, 2017, 36(5): 82-184.
- [4] 魏涛. BP 神经网络在煤矿瓦斯安全事故预测中的应用 [J]. 煤炭技术, 2023, 42(12): 165-168.
- [5] 刘超, 雷晨, 李树刚, 薛俊华, 张超. 基于 CNN-GRU 的瓦斯浓度预测模型及应用 [J]. 中国安全生产科学技术, 2022, 18(9): 62-68.
- [6] 秦辉辉, 南新元, 毛同一. 融合改进的鱼鹰算法和 ATT-CNN-LSTM 的瓦斯浓度预测 [J]. 煤炭技术, 2024, 43(09): 194-199.
- [7] 马莉, 潘少波, 代新冠, 宋爽, 石新莉. 基于 PSO-Adam-GRU 的煤矿瓦斯浓度预测模型 [J]. 西安科技大学学报, 2020, 40(2): 363-368.
- [8] 兰海平, 张志刚, 徐再刚, 田祥贵, 张少超. 基于 LSTM 的瓦斯浓度预测与防灾预警系统设计 [J]. 矿业安全与环保, 2023, 50(2): 64-70.
- [9] 张若楠, 徐平安, 周小雨, 等. 基于堆 LSTM 的采煤工作面瓦斯浓度预测方法 [J]. 陕西煤炭, 2024, 43(09): 91-94.
- [10] Wang Y, Liu F, Jiang Z, et al. Complex variational mode decomposition for signal processing applications [J]. Mechanical systems and signal processing, 2017, 86: 75-85.
- [11] Lian J, Liu Z, Wang H, et al. Adaptive variational mode decomposition method for signal processing based on mode characteristic [J]. Mechanical Systems and Signal Processing, 2018, 107: 53-77.