

文章编号: 1671-251X(2024)11-0092-08

DOI: 10.13272/j.issn.1671-251x.2024080022

# 基于 GAT-Informer 的采空区煤自燃温度预测模型

贾澎涛<sup>1</sup>, 张杰<sup>1</sup>, 郭风景<sup>2</sup>

(1. 西安科技大学 计算机科学与技术学院, 陕西 西安 710054;

2. 陕西陕煤蒲白矿业有限公司, 陕西 渭南 715517)

**摘要:** 现有的煤自燃温度预测模型仅考虑监测数据前后的时间关联性, 未考虑监测点之间的空间关系, 并存在多步长煤自燃温度预测精度低的问题。针对上述问题, 提出了一种基于图注意力网络(GAT)和 Informer 模型(GAT-Informer)的采空区煤自燃温度预测模型。首先, 采用随机森林回归法和 Savitzky-Golay 滤波器对采空区沿空侧煤自燃监测数据中的异常值、缺失值和噪声进行处理, 并使用 Z-score 方法对数据进行标准化。其次, 采用 GAT 提取多个监测点煤自燃监测数据间的空间特征。然后, 使用 Informer 模型的编码器对包含空间特征的数据进行编码, 利用多头概率稀疏自注意力机制捕捉数据之间的长期依赖关系和时间特征; 解码器通过交叉注意力机制与编码器交互, 结合编码器提取的全局特征与目标序列的上下文依赖关系, 生成特征矩阵并输入全连接层, 得到煤自燃温度预测值。最后, 对 Informer 模型输出的煤自燃温度预测值进行反标准化处理, 恢复到原始数据尺度, 得到最终的预测结果。实验结果表明, 相较于循环神经网络(RNN)、长短期记忆网络(LSTM)、门控循环单元(GRU)和 Informer 模型, GAT-Informer 模型在 6 个监测点上预测 24 步长煤自燃温度时, 均方误差(MSE)分别平均降低了 15.70%, 22.15%, 25.45%, 36.49%, 平均绝对误差(MAE)分别平均降低了 16.01%, 14.60%, 20.30%, 26.27%, 表明 GAT-Informer 模型能有效提高煤自燃温度多步长预测精度。

**关键词:** 煤自燃; 煤自燃温度预测; 多步长时间序列预测; 图注意力网络; Informer; 数据时空特征  
中图分类号: TD323 文献标志码: A

Coal spontaneous combustion temperature prediction model for goaf area based on GAT-Informer

JIA Pengtao<sup>1</sup>, ZHANG Jie<sup>1</sup>, GUO Fengjing<sup>2</sup>

(1. College of Computer Science and Technology, Xi'an University of Science and Technology, Xi'an 710054, China;

2. Shaanxi Shanmei Pubai Mining Co., Ltd., Weinan 715517, China)

**Abstract:** The existing coal spontaneous combustion temperature prediction models only consider the temporal correlation of the monitoring data, ignoring the spatial relationships between monitoring points, and suffer from low accuracy in multi-step temperature prediction of coal spontaneous combustion. To address these issues, a coal spontaneous combustion temperature prediction model for goaf areas based on graph attention network (GAT)-Informer model (GAT-Informer) was proposed. First, the random forest regression method and Savitzky-Golay filter were used to handle outliers, missing values, and noise in the spontaneous combustion monitoring data along the goaf side, and the Z-score method was applied to standardize the data. Secondly, GAT was employed to extract spatial features from the spontaneous combustion monitoring data at multiple monitoring points. Then, the encoder of the Informer model was used to encode the data containing spatial features, utilizing a multi-head probabilistic sparse self-attention mechanism to capture long-term dependencies and temporal features among the data. The decoder interacted with the encoder through a cross-attention mechanism, combining global

收稿日期: 2024-08-10; 修回日期: 2024-11-19; 责任编辑: 盛男。

基金项目: 国家自然科学基金项目(51974236)。

作者简介: 贾澎涛(1977—), 女, 陕西蒲城人, 教授, 博士, 研究方向为机器学习、煤矿灾害预警等, E-mail: jiapengtao@xust.edu.cn。

引用格式: 贾澎涛, 张杰, 郭风景. 基于 GAT-Informer 的采空区煤自燃温度预测模型[J]. 工矿自动化, 2024, 50(11): 92-98, 108.

JIA Pengtao, ZHANG Jie, GUO Fengjing. Coal spontaneous combustion temperature prediction model for goaf area based on GAT-Informer[J]. Journal of Mine Automation, 2024, 50(11): 92-98, 108.



扫码移动阅读

features extracted by the encoder with the contextual dependencies of the target sequence to generate a feature matrix, which was then fed into the fully connected layer to obtain the coal spontaneous combustion temperature prediction value. Finally, the predicted temperature value output from the Informer model was de-standardized to restore it to the original data scale, yielding the final prediction results. Experimental results showed that, compared to recurrent neural network (RNN), long short-term memory (LSTM), gated recurrent unit (GRU), and the Informer model, the GAT-Informer model reduced the mean squared error (MSE) by an average of 15.70%, 22.15%, 25.45%, and 36.49%, respectively, and the mean absolute error (MAE) by an average of 16.01%, 14.60%, 20.30%, and 26.27%, respectively, when predicting the coal spontaneous combustion temperature at 24 time steps across six monitoring points. These results indicate that the GAT-Informer model effectively improves the multi-step prediction accuracy of coal spontaneous combustion temperature.

**Key words:** coal spontaneous combustion; coal spontaneous combustion temperature prediction; multi-step time series prediction; graph attention network; Informer; spatiotemporal data features

## 0 引言

煤自燃是在煤炭开采和储运过程中常见的重大灾害之一,严重威胁煤矿安全生产和矿工生命安全<sup>[1-3]</sup>。为减少煤自燃引发的瓦斯爆炸、粉尘爆炸、矿井火灾等灾害,煤自燃预测成为防治煤自燃灾害的关键<sup>[4-5]</sup>,其中最有效的方式是研究煤自燃过程中温度与指标气体浓度之间的规律<sup>[6-7]</sup>,建立煤自燃温度预测模型。

近年来随着人工智能技术的快速发展,已有许多学者将传统机器学习和深度学习与煤自燃指标气体相结合,对煤自燃温度进行预测。赵琳琳等<sup>[8]</sup>利用主成分分析法(Principal Component Analysis, PCA)提取 O<sub>2</sub> 浓度等指标的主成分,并将主成分作为自适应增强(Adaptive Boosting, AdaBoost)算法输入参数,发火情况作为 AdaBoost 算法输出参数,建立了不平衡数据下采空区自然发火 PCA-AdaBoost 预测模型,提高了采空区自然发火预测准确率。咎军才等<sup>[9]</sup>建立了 BP 神经网络预测模型,选取 CO, CO<sub>2</sub>, CH<sub>4</sub>, C<sub>2</sub>H<sub>4</sub>, C<sub>2</sub>H<sub>6</sub> 气体浓度作为特征,对煤自燃温度进行预测。郑学召等<sup>[10]</sup>采用随机森林算法构建了基于向量的煤自燃温度预测模型。汪伟等<sup>[11]</sup>将粒子群优化(Particle Swarm Optimization, PSO)算法和改进反向传播神经网络(Back Propagation Neural Network, BPNN)结合,构建了基于 PSO-BPNN 的煤自燃预测模型,克服了收敛速度慢、易陷入局部最优的缺点。基于机器学习的方法具有泛化能力好、计算效率高等优点,但在预测准确性方面还有待进一步提高。随着深度学习的发展,一些学者将简单循环单元(Simple Recurrent Unit, SRU)<sup>[12]</sup>、长短期记忆网络(Long Short-Term Memory, LSTM)<sup>[13]</sup>、门控循环单元(Gated Recurrent Unit, GRU)<sup>[14]</sup>、Transformer<sup>[15]</sup>模

型等应用于煤自燃温度预测,取得了较好的效果,但这些模型多数仅针对单一监测点进行预测,对于多监测点情况,无法考虑监测点的空间关系。另外,在预测步长方面,目前大部分研究致力于提高煤自燃温度的单步长预测精度,对煤自燃温度的多步长预测研究较少。

煤矿采空区是一个复杂的环境空间,采空区气体是流动的,不同位置的遗煤量也不相同。对采空区沿空侧进行监测时,布置的多个监测点之间具有空间关联性<sup>[16]</sup>,所以在预测采空区的煤自燃温度时,需要将采空区多个煤自燃监测点作为一个整体进行研究<sup>[17-18]</sup>。本文将图注意力网络(Graph Attention Networks, GAT)<sup>[19]</sup>与 Informer 模型<sup>[20]</sup>进行融合,提出了一种 GAT-Informer 模型,并用于采空区煤自燃温度预测,可有效提取采空区多个监测点煤自燃监测数据间的空间关联特征和时间关联特征,提高煤自燃温度多步长预测精度。

## 1 GAT-Informer 模型

GAT-Informer 模型由输入层、GAT、Informer 模型和输出层 4 个部分组成,如图 1 所示。

### 1.1 输入层

采集采空区沿空侧煤柱布置的多个监测点数据,设煤自燃监测数据集合为 $\{D^1, D^2, \dots, D^M\}$ ,其中 $D^m = \{D_1^m, D_2^m, \dots, D_n^m\}$ ( $m = 1, 2, \dots, M$ ,  $M$ 为监测点数量), $D_t^m$ 为第 $m$ 个监测点的第 $t$ ( $t = 1, 2, \dots, n$ ,  $n$ 为监测数据的时间序列总长度)个时刻特征数据, $D_t^m = [d_{t1}^m, d_{t2}^m, \dots, d_{ts}^m]$ , $d_{tf}^m$ 为第 $m$ 个监测点的第 $t$ 个时刻的第 $f$ ( $f = 1, 2, \dots, s$ ,  $s$ 为指标特征数量)个指标特征值。

采空区环境复杂,设备工作不稳定,采集到的数据有较多的异常值和较大的噪声,会影响数据的预测精度,因此,在煤自燃温度预测前需要对数据进行

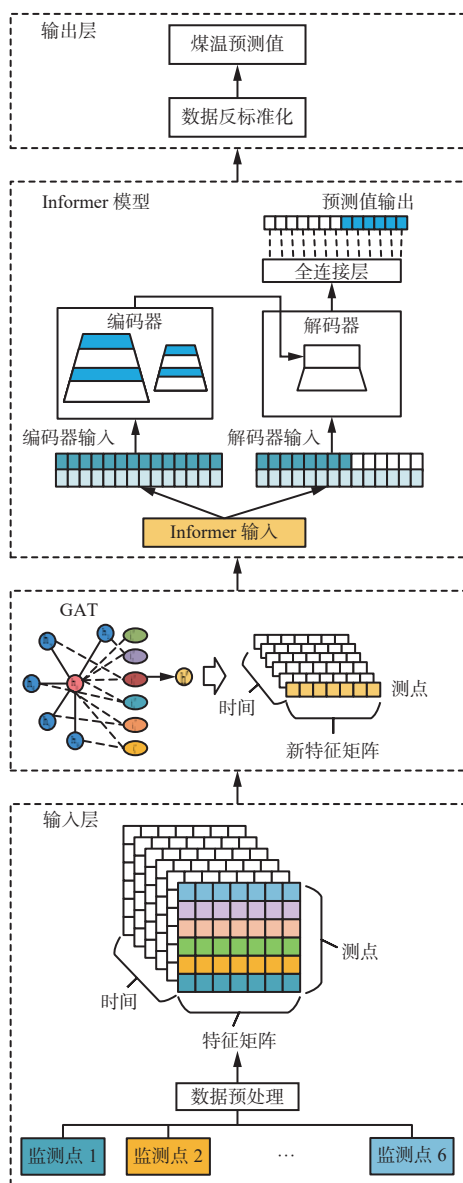


图 1 GAT-Informer 模型架构

Fig. 1 Graph attention network(GAT)-Informer model architecture  
预处理。采用随机森林回归法<sup>[21]</sup>对缺失值和异常值处进行插补,通过 Savitzky-Golay 滤波器<sup>[22]</sup>进行平滑去噪处理,使用 Z-score 方法对数据进行标准化,从而重构符合 GAT 输入要求的特征矩阵集合  $\{X^1, X^2, \dots, X^M\}$ , 其中  $X^m$  为第  $m$  个监测点的特征矩阵,  $X^m \in \mathbf{R}^{n \times s}$ 。

## 1.2 GAT

GAT 利用注意力机制来捕捉煤自燃监测点之间的关系。通过计算 1 个监测点与其关联监测点之间的注意力权重,根据权重来更新当前监测点状态,进而对多个煤自燃监测点之间的空间特征进行提取。GAT 结构如图 2 所示。

根据采空区沿空侧煤柱各煤自燃监测点的位置信息,选取 1 个中心监测点及其所有关联监测点,构造图邻阶矩阵。对于单个图注意力层,模型的输入




图 2 GAT 结构

Fig. 2 GAT structure

为  $\{X^1, X^2, \dots, X^M\}$ , 计算关联监测点  $p$  ( $p = 1, 2, \dots, M$ ) 对于中心监测点  $c$  的注意力权重  $e_{cp}$ :

$$e_{cp} = a(WX_t^c, WX_t^p) \quad (1)$$

式中:  $a$  为权重向量,用于衡量关联监测点对中心监测点的注意力强度;  $W$  为可学习的共享的权重矩阵,  $W \in \mathbf{R}^{F \times F'}$ ,  $F$  为输入特征维度,  $F'$  为输出特征维度;  $X_t^c$  和  $X_t^p$  分别为中心监测点  $c$  和关联监测点  $p$  的  $t$  时刻特征矩阵。

对于中心监测点  $c$  及其关联监测点  $p$ , 使用 LeakyReLU 激活函数对它们之间的注意力权重进行非线性变换,得到归一化处理后的关联监测点  $p$  对于中心监测点  $c$  的注意力权重  $\alpha_{cp}$ :

$$\alpha_{cp} = \frac{\exp(\text{LeakyReLU}(a^T |WX_t^c| |WX_t^p|))}{\sum_{p=1}^M \exp(\text{LeakyReLU}(a^T |WX_t^c| |WX_t^p|))} \quad (2)$$

式中 LeakyReLU( $\cdot$ ) 为 LeakyReLU 激活函数。

根据计算出的注意力权重  $\alpha_{cp}$ , 得到中心监测点的特征矩阵:

$$X_t^{c'} = \sigma \left( \sum_{p=1}^M \alpha_{cp} WX_t^p \right) \quad (3)$$

在 GAT 中使用多头注意力机制来增强模型的学习能力,即调用  $G$  组相互独立的图注意力层,将各层运算结果进行拼接,将拼接后的结果采用平均操作的方式,更新中心监测点的特征矩阵:

$$X_t^{c'} = \sigma \left( \frac{1}{G} \sum_{g=1}^G \sum_{p=1}^M \alpha_{cp}^g W^g X_t^p \right) \quad (4)$$

式中  $\alpha_{cp}^g$  和  $W^g$  分别为第  $g$  个图注意力层关联监测点  $p$  对于中心监测点  $c$  的注意力权重和共享权重矩阵。

最终得到  $n$  个时刻中心监测点的新特征矩阵  $X^{c'} = [X_1^{c'} X_2^{c'} \dots X_n^{c'}]$ 。  $X^{c'}$  结合了周围有关联的监测点信息,可有效表示空间区域内的煤自燃状态。

## 1.3 Informer 模型

Informer 模型接收 GAT 的输出  $X^{c'}$ , 对数据进行



编码,实现对煤自燃温度的预测。Informer 模型采用多头概率稀疏自注意力机制,挖掘向量之间的潜在联系,并且可以一次性给出长时间序列的预测结果,有效解决了传统神经网络对长时间序列预测不足导致的误差增大问题。

Informer 模型主要由编码器和解码器组成。数据先进入编码器的 Embedding 层,该层包含 3 个编码模块,即 Embedding 编码模块、位置编码模块和时间戳编码模块,各模块分别对输入数据进行编码,将编码后的数据进行拼接,得到编码后的特征矩阵  $X$ 。

将编码后的特征矩阵  $X$  处理成 3 个同尺寸矩阵,分别为查询矩阵  $Q \in \mathbf{R}^{L_Q \times d}$ 、键矩阵  $K \in \mathbf{R}^{L_K \times d}$ 、值矩阵  $V \in \mathbf{R}^{L_V \times d}$  ( $L_Q, L_K, L_V$  分别为  $Q, K, V$  序列长度,  $d$  为序列特征维度):

$$\begin{cases} Q = XW_Q \\ K = XW_K \\ V = XW_V \end{cases} \quad (5)$$

式中  $W_Q, W_K, W_V$  分别为  $Q, K, V$  的权重矩阵。

通过对键矩阵  $K$  随机采样,得到采样后的  $\bar{K}$ ,此时,查询矩阵  $Q$  的第  $i$  行  $q_i$  对应的稀疏性度量值为

$$\bar{M}(q_i, \bar{K}) = \max_j \left\{ \frac{q_i \bar{k}_j^T}{\sqrt{d}} \right\} - \frac{1}{L_K} \sum_{j=1}^{L_K} \frac{q_i \bar{k}_j^T}{\sqrt{d}} \quad (6)$$

式中  $\bar{k}_j$  为  $\bar{K}$  的第  $j$  行。

选取对应稀疏性度量值较高的  $q_i$ , 组成新的查询矩阵  $\bar{Q}$ , 计算概率稀疏自注意力:

$$A(Q, K, V) = \text{Softmax} \left( \frac{\bar{Q} K^T}{\sqrt{d}} \right) V \quad (7)$$

为增强模型在长序列数据中捕捉长期依赖关系的能力,同时有效降低计算复杂度,将  $h$  个概率稀疏自注意力头  $\text{head}_1, \text{head}_2, \dots, \text{head}_h$  进行拼接:

$$A_M(Q, K, V) = \text{Concat}(\text{head}_1, \text{head}_2, \dots, \text{head}_h) \quad (8)$$

式中:  $A_M(Q, K, V)$  为多头概率稀疏自注意力;  $\text{Concat}(\cdot)$  表示拼接操作;  $\text{head}_h = A(Q_h, K_h, V_h)$ ,  $Q_h, K_h, V_h$  分别为第  $h$  个概率稀疏自注意力头的查询矩阵、键矩阵、值矩阵。

编码器蒸馏层接收第  $J$  层经过多头概率稀疏自注意力运算后的输出,该层包含一维卷积和最大池化操作,实现维度压缩。从第  $J$  层提取特征传递到第  $J+1$  层的操作过程为

$$X'_{J+1} = \text{MaxPool}(\text{ELU}(\text{Convld}([X'_J]_{AB}))) \quad (9)$$

式中:  $X'_{J+1}$  为蒸馏后第  $J+1$  层  $t$  时刻的特征矩阵;  $\text{MaxPool}(\cdot)$  为最大池化函数;  $\text{ELU}(\cdot)$  为 ELU 激活函数;  $\text{Convld}(\cdot)$  为一维卷积滤波器;  $X'_J$  为第  $J$  层  $t$  时刻的

特征矩阵;  $[\cdot]_{AB}$  表示多头概率稀疏自注意力运算。

Informer 模型解码器由 2 个多头自注意力层组成。通过引入生成式解码器和掩码机制,煤自燃温度预测结果只依赖于待预测序列之前的数据。在此机制下,待预测序列的数据会被掩码(置为 0),确保模型只关注已知数据部分。解码器的输入  $Y'_{\text{de}}$  为部分真实值序列  $Y'_{\text{token}}$  和待预测序列  $Y'_0$  的拼接:

$$Y'_{\text{de}} = \text{Concat}(Y'_{\text{token}}, Y'_0) \quad Y'_{\text{de}} \in \mathbf{R}^{(L_{\text{token}}+L_y) \times d_{\text{model}}} \quad (10)$$

式中:  $L_{\text{token}}$  为待预测序列前一段真实值序列的长度;  $L_y$  为待预测序列的长度;  $d_{\text{model}}$  为模型特征维度。

编码器与解码器之间通过交叉注意力机制实现信息交互。解码器利用编码器提取的全局特征信息,结合目标序列的上下文依赖关系,构建特征矩阵,将特征矩阵输入全连接层,从而输出煤自燃温度的预测值。

#### 1.4 输出层

输出层对 Informer 模型输出的煤自燃温度预测值进行反标准化处理,恢复到原始数据尺度,得到最终的煤自燃温度预测结果。

## 2 实验与结果分析

### 2.1 数据来源

为验证 GAT-Informer 模型在预测煤自燃温度时的准确性,基于陕西某煤矿采空区沿空侧煤柱部署的 6 个煤自燃监测点的监测数据进行分析。

通过对采空区遗煤煤样程序升温结果进行分析,选取与煤自燃温度有关联关系的 5 种特征气体 ( $\text{CO}, \text{CO}_2, \text{CH}_4, \text{O}_2, \text{C}_2\text{H}_4$ ) 及  $\text{N}_2$ 、湿度和温度,共 8 种指标特征数据。使用矿用本安型多参数传感器进行数据采集,采集时间为 2022-10-11T12:00—2022-10-23T23:55,采集周期为 5 min,应采集 21 600 条数据,每个监测点的数据量为 3 600 条,实际采集数据 21 588 条,缺失数据 12 条。采用箱线图分析数据,确定异常数据 6 条。使用随机森林回归法对缺失值和异常值处进行插补,再采用 Savitzky-Golay 滤波器进行平滑去噪处理,预处理后的煤自燃监测温度分布如图 3 所示。将预处理后的煤自燃监测数据以 7:1:2 的比例划分为训练集、验证集和测试集。

### 2.2 实验环境

实验硬件配置: Intel(R) Core(TM) i5-6300HQ CPU @ 2.30 GHz, 16 GiB 内存。实验软件环境: Windows(64 位)操作系统,编程语言为 Python-3.7,编程平台为 PyCharm2018.3.7,集成环境为 Anaconda Navigator-1.3.1,深度学习框架为 PyTorch1.13.1。




图 3 多监测点温度分布

Fig. 3 Temperature distribution of multiple monitoring points

### 2.3 评价指标

为评估模型性能,选取均方误差(Mean Squared Error, MSE)及平均绝对误差(Mean Absolute Error, MAE)作为评价指标。模型评价指标的大小体现预测值与真实值之间的偏差程度,指标值越小,表明煤自燃温度预测值和真实值越接近,预测结果越准确。

### 2.4 预测结果分析

实验中分别采用循环神经网络(Recurrent Neural Network, RNN)、LSTM、GRU、Informer 和 GAT-Informer 模型进行煤自燃温度预测。设置历史数据窗口步长为 48。

对于监测点 1,设置预测煤自燃温度的步长为 1, 6, 12, 24 和 48,各模型在不同步长下的预测结果对比见表 1 和表 2。

表 1 不同步长下各模型 MSE

Table 1 Mean squared error(MSE) of each model at different steps

模型	步长				
	1	6	12	24	48
RNN	0.012 9	0.043 3	0.191 1	0.471 3	0.770 8
LSTM	<b>0.005 0</b>	0.025 0	0.192 9	0.466 7	1.565 9
GRU	0.008 8	<b>0.023 3</b>	0.241 4	0.508 7	1.384 4
Informer	0.051 1	0.220 9	0.325 0	0.658 9	0.682 4
GAT-Informer	0.017 6	0.137 2	<b>0.187 8</b>	<b>0.403 7</b>	<b>0.404 0</b>

表 2 不同步长下各模型 MAE

Table 2 Mean absolute error(MAE) of each model at different steps

模型	步长				
	1	6	12	24	48
RNN	0.058 9	0.151 6	0.293 9	0.496 7	0.659 2
LSTM	<b>0.048 1</b>	0.110 6	0.310 2	0.473 1	1.029 2
GRU	0.052 4	<b>0.104 5</b>	0.368 9	0.527 9	0.927 9
Informer	0.170 7	0.359 1	0.406 4	0.583 7	0.633 4
GAT-Informer	0.090 7	0.223 6	<b>0.274 7</b>	<b>0.392 9</b>	<b>0.477 3</b>

从表 1 和表 2 可看出,在步长为 1 和 6 时,RNN,

LSTM 和 GRU 模型表现出的性能较好,但随着预测的步长增加,GAT-Informer 模型不论是在 MSE 还是 MAE 上,都取得了最好的预测效果。

为更清晰地对比各模型的煤自燃温度预测效果,针对 6 个监测点,设置预测的步长为 24,不同模型预测结果对比见表 3 和表 4。

表 3 不同监测点下各模型 MSE

Table 3 MSE of each model under different monitoring points

模型	监测点					
	1	2	3	4	5	6
RNN	0.471 3	0.155 4	0.242 9	0.274 6	0.335 3	0.472 7
LSTM	0.466 7	0.157 2	0.392 5	0.276 0	0.392 7	0.483 4
GRU	0.508 7	0.149 2	0.334 6	0.280 6	0.388 7	0.637 2
Informer	0.658 9	0.223 5	0.313 5	0.383 1	0.470 0	0.524 3
GAT-Informer	<b>0.403 7</b>	<b>0.119 6</b>	<b>0.139 2</b>	<b>0.259 6</b>	<b>0.326 4</b>	<b>0.444 0</b>

表 4 不同监测点下各模型 MAE

Table 4 MAE of each model under different monitoring points

模型	监测点					
	1	2	3	4	5	6
RNN	0.496 7	0.306 7	0.376 3	0.368 5	0.393 3	0.474 4
LSTM	0.473 1	0.274 6	0.460 9	0.326 0	0.364 2	0.514 5
GRU	0.527 9	0.309 2	0.393 7	0.363 5	0.385 9	0.596 0
Informer	0.583 7	0.270 9	0.465 8	0.434 2	0.484 7	0.560 2
GAT-Informer	<b>0.392 9</b>	<b>0.231 1</b>	<b>0.299 5</b>	<b>0.301 7</b>	<b>0.357 6</b>	<b>0.460 6</b>

从表 3 和表 4 可看出,与 RNN, LSTM, GRU 和 Informer 模型相比,GAT-Informer 模型在 6 个监测点上均取得了最好的预测效果。

对于 6 个监测点,预测的步长为 24 时,GAT-Informer 模型相较于 RNN, LSTM, GRU 和 Informer 模型在 MSE 和 MAE 指标上的降低幅度见表 5。

表 5 各监测点上 GAT-Informer 模型相较于其他模型在 MSE 和 MAE 指标上的降低幅度

Table 5 Reduction in MSE and MAE metrics of GAT-Informer model compared with other models at each monitoring point

监测点	RNN		GRU		LSTM		Informer	
	MSE 降低	MAE 降低	MSE 降低	MAE 降低	MSE 降低	MAE 降低	MSE 降低	MAE 降低
	幅度/%	幅度/%	幅度/%	幅度/%	幅度/%	幅度/%	幅度/%	幅度/%
1	14.34	20.90	13.50	16.95	20.64	25.57	38.73	32.69
2	23.03	24.65	23.92	15.84	19.84	25.26	46.49	14.69
3	42.69	20.40	64.53	35.02	58.40	23.93	55.60	35.70
4	5.46	18.13	5.94	7.45	7.48	17.00	32.24	30.51
5	2.65	9.07	16.88	1.85	16.02	7.33	30.55	26.22
6	6.07	2.90	8.15	10.48	30.32	22.72	15.32	17.78

从表5可看出,与RNN, LSTM, GRU和Informer模型相比, GAT-Informer模型MSE分别平均降低了15.70%, 22.15%, 25.45%, 36.49%, MAE分别平均降低了16.01%, 14.60%, 20.30%, 26.27%, 表明GAT-Informer模型能有效提高煤自燃温度预测精度。

GAT-Informer模型在各监测点测试集上预测未来2 h(24个步长)中第1个5 min(1个步长)煤自燃温度的结果如图4所示。可看出GAT-Informer模型的预测曲线变化趋势与真实测量曲线变化趋势大致相同,说明GAT-Informer模型预测精度高。




图4 各监测点预测值与真实值对比

Fig. 4 Comparison between predicted and actual values at each monitoring point

为更清晰地展示GAT-Informer模型在煤自燃温度多步长预测的效果,针对监测点6, GAT-Informer模型预测未来24个步长的煤自燃温度结果如图5所示。可看出GAT-Informer模型预测的未来24个步长的煤自燃温度与真实值相差不大,趋势大致相同,煤自燃温度范围为37.4~37.7 °C,变化幅度较小,说明该模型在对煤自燃温度的多步长预测时具有良好的效果。




图5 煤自燃温度多步长预测结果

Fig. 5 Multi-step prediction results of coal spontaneous combustion temperature

### 3 结论

1) 基于GAT-Informer的采空区煤自燃温度预测模型通过GAT提取采空区各监测点煤自燃监测数据之间的空间特征关系;将包含空间特征的数据传入Informer模型,利用多头概率稀疏自注意力机制提取数据的长时间依赖特征,捕捉数据变化的时间序列趋势,并通过蒸馏层进一步提取特征;解码器结合编码器提取的全局特征与目标序列的上下文依赖关系,生成特征矩阵并输入到全连接层,经反标准化处理得到煤自燃温度预测结果。

2) 相较于RNN, LSTM, GRU, Informer等单一煤自燃温度预测模型, GAT-Informer模型在预测步长为24时, MSE分别平均降低了15.70%, 22.15%, 25.45%, 36.49%, MAE分别平均降低了16.01%, 14.60%, 20.30%, 26.27%, 表明GAT-Informer模型能有效提高煤自燃温度预测精度,适合于采空区多监测点多步长煤自燃温度的预测。

3) 未来将对GAT-Informer模型结构进一步优化,加入多特征融合模型,挖掘指标气体与煤自燃温度之间的关系,进一步提高模型的整体预测精度和泛化性能。

### 参考文献(References):

- [1] 邓军, 白祖锦, 肖旸, 等. 煤自燃灾害防治技术现状与挑战[J]. 煤矿安全, 2020, 51(10): 118-125.  
DENG Jun, BAI Zujin, XIAO Yang, et al. Present situation and challenge of coal spontaneous combustion disasters prevention and control technology[J]. Safety in Coal Mines, 2020, 51(10): 118-125.

- [2] 杨峰峰, 王海晖, 苏伟伟, 等. 采空区自燃危险区域判别与防控技术研究综述[J]. 煤矿安全, 2023, 54(6): 66-75.  
YANG Fengfeng, WANG Haihui, SU Weiwei, et al. Review on identification and prevention and control technology of spontaneous combustion risk area in goaf[J]. Safety in Coal Mines, 2023, 54(6): 66-75.
- [3] 秦波涛, 仲晓星, 王德明, 等. 煤自燃过程特性及防治技术研究进展[J]. 煤炭科学技术, 2021, 49(1): 66-99.  
QIN Botao, ZHONG Xiaoxing, WANG Deming, et al. Research progress of coal spontaneous combustion process characteristics and prevention technology[J]. Coal Science and Technology, 2021, 49(1): 66-99.
- [4] 谭波, 邵壮壮, 郭岩, 等. 基于指标气体关联分析的煤自燃分级预警研究[J]. 中国安全科学学报, 2021, 31(2): 33-39.  
TAN Bo, SHAO Zhuangzhuang, GUO Yan, et al. Research on grading and early warning of coal spontaneous combustion based on correlation analysis of index gas[J]. China Safety Science Journal, 2021, 31(2): 33-39.
- [5] 邓军, 雷昌奎, 曹凯, 等. 采空区煤自燃预测的随机森林方法[J]. 煤炭学报, 2018, 43(10): 2800-2808.  
DENG Jun, LEI Changkui, CAO Kai, et al. Random forest method for predicting coal spontaneous combustion in gob[J]. Journal of China Coal Society, 2018, 43(10): 2800-2808.
- [6] 王怡, 谢军, 任广意. 采空区遗煤自然发火的指标气体研究[J]. 矿业研究与开发, 2020, 40(10): 118-122.  
WANG Yi, XIE Jun, REN Guangyi. Study on index gas in spontaneous combustion of goaf residual coal[J]. Mining Research and Development, 2020, 40(10): 118-122.
- [7] 文虎, 赵向涛, 王伟峰, 等. 不同煤体自燃指标性气体函数模型特征分析[J]. 煤炭转化, 2020, 43(1): 16-25.  
WEN Hu, ZHAO Xiangtao, WANG Weifeng, et al. Analysis on characteristics of indicator gases of spontaneous combustion of different coals[J]. Coal Conversion, 2020, 43(1): 16-25.
- [8] 赵琳琳, 温国锋, 邵良杉. 不均衡数据下的采空区煤自燃 PCA-AdaBoost 预测模型[J]. 中国安全科学学报, 2018, 28(3): 74-78.  
ZHAO Linlin, WEN Guofeng, SHAO Liangshan. PCA-AdaBoost model for predicting coal spontaneous combustion in caving zone with imbalanced data[J]. China Safety Science Journal, 2018, 28(3): 74-78.
- [9] 咎军才, 魏成才, 蒋可娟, 等. 基于 BP 神经网络的煤自燃温度预测研究[J]. 煤炭工程, 2019, 51(10): 113-117.  
ZAN Juncai, WEI Chengcai, JIANG Kejuan, et al. Prediction of coal spontaneous combustion temperature based on BP neural network[J]. Coal Engineering, 2019, 51(10): 113-117.
- [10] 郑学召, 李梦涵, 张熾妮, 等. 基于随机森林算法的煤自燃温度预测模型研究[J]. 工矿自动化, 2021, 47(5): 58-64.  
ZHENG Xuezhao, LI Menghan, ZHANG Yanni, et al. Research on the prediction model of coal spontaneous combustion temperature based on random forest algorithm[J]. Industry and Mine Automation, 2021, 47(5): 58-64.
- [11] 汪伟, 梁然, 祁云, 等. 基于 PSO-BPNN 的煤自燃危险性预测模型[J]. 中国安全科学学报, 2023, 33(7): 127-132.  
WANG Wei, LIANG Ran, QI Yun, et al. Prediction model of coal spontaneous combustion risk based on PSO-BPNN[J]. China Safety Science Journal, 2023, 33(7): 127-132.
- [12] 贾澎湃, 林开义, 郭风景. 基于 PSO-SRU 深度神经网络的煤自燃温度预测模型[J]. 工矿自动化, 2022, 48(4): 105-113.  
JIA Pengtao, LIN Kaiyi, GUO Fengjing. A temperature prediction model for coal spontaneous combustion based on PSO-SRU deep artificial neural networks[J]. Journal of Mine Automation, 2022, 48(4): 105-113.
- [13] 刘永立, 刘晓伟, 王海涛. 基于 LSTM 神经网络的煤矿火灾预测[J]. 黑龙江科技大学学报, 2023, 33(1): 1-5.  
LIU Yongli, LIU Xiaowei, WANG Haitao. Coal mine fire prediction based on LSTM neural network[J]. Journal of Heilongjiang University of Science and Technology, 2023, 33(1): 1-5.
- [14] 王斌, 贾澎湃, 郭风景, 等. 基于多特征融合的煤自燃温度深度预测模型[J]. 中国矿业, 2024, 33(2): 84-90.  
WANG Bin, JIA Pengtao, GUO Fengjing, et al. Deep prediction model of coal spontaneous combustion temperature based on multi-feature fusion[J]. China Mining Magazine, 2024, 33(2): 84-90.
- [15] 王树斌, 王旭, 闫世平, 等. 基于 Transformer 的矿井内因火灾时间序列预测方法[J]. 工矿自动化, 2024, 50(3): 65-70, 91.  
WANG Shubin, WANG Xu, YAN Shiping, et al. Transformer based time series prediction method for mine internal caused fire[J]. Journal of Mine Automation, 2024, 50(3): 65-70, 91.
- [16] 李艳昌, 张连超, 陶华焕. 陕北煤矿褐煤自燃预测函数模型研究[J]. 工业安全与环保, 2024, 50(6): 28-31.  
LI Yanchang, ZHANG Lianchao, TAO Huahuan. Study on prediction function model of lignite spontaneous combustion in Tiebei Coal Mine[J]. Industrial Safety and Environmental Protection, 2024, 50(6): 28-31.
- [17] 李鹏飞, 张 Tong, 金 Yantao. A spatio-temporal graph convolutional network for air quality prediction[J]. Sustainability, 2023, 15(9): 7624.



- 10-28.  
LI Wei, ZHANG Xing, ZHU Zhencai, et al. Automatic straightening device and method of fully mechanized mining face scraper conveyor: CN105000328A[P]. 2015-10-28.
- [13] 杨学军, 王然风, 王怀法, 等. 基于机器人的工作面液压支架姿态和直线度检测装置及方法: CN108663032A[P]. 2018-10-16.  
YANG Xuejun, WANG Ranfeng, WANG Huaifa, et al. The device and method of hydraulic support in working face: CN108663032A[P]. 2018-10-16.
- [14] 刘旭. 综采工作面模拟装置与模拟试验研究[D]. 徐州: 中国矿业大学, 2019.  
LIU Xu. Research on simulation device and simulation test of longwall mining[D]. Xuzhou: China University of Mining and Technology, 2019.
- [15] 夏婷. 综采工作面刮板输送机直线度检测方法研究[D]. 徐州: 中国矿业大学, 2019.  
XIA Ting. Research on straightness detection method of scraper conveyor in fully mechanized mining face[D]. Xuzhou: China University of Mining and Technology, 2019.
- [16] HE Kaiming, GKIOXARI G, DOLLAR P, et al. Mask R-CNN[C]. IEEE International Conference on Computer Vision, Venice, 2017. DOI: [10.1109/ICCV.2017.322](https://doi.org/10.1109/ICCV.2017.322).
- [17] RONNEBERGER O, FISCHER P, BROX T. U-net: convolutional networks for biomedical image segmentation[M]. Cham: Springer International Publishing, 2015: 234-241.
- [18] BADRINARAYANAN V, KENDALL A, CIPOLLA R. SegNet: a deep convolutional encoder-decoder architecture for image segmentation[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(12): 2481-2495.
- [19] CHEN L C, PAPANDREOU G, KOKKINOS I, et al. DeepLab: semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2018, 40(4): 834-848.
- [20] CHENG Bowen, MISRA I, SCHWING A G, et al. Masked-attention mask transformer for universal image segmentation[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, New Orleans, 2022: 1290-1299.
- [21] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection[C]. IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, 2016: 779-788.
- [22] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[J]. *Communications of the ACM*, 2017, 60(6): 84-90.
- [23] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[EB/OL]. [2024-05-20]. <https://arxiv.org/abs/1409.1556v6>.
- [24] SZEGEDY C, LIU Wei, JIA Yangqing, et al. Going deeper with convolutions[C]. IEEE Conference on Computer Vision and Pattern Recognition, Boston, 2015. DOI: [10.1109/CVPR.2015.7298594](https://doi.org/10.1109/CVPR.2015.7298594).
- [25] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Deep residual learning for image recognition[C]. IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, 2016. DOI: [10.1109/CVPR.2016.90](https://doi.org/10.1109/CVPR.2016.90).
- ~~~~~
- (上接第 98 页)
- [18] 程子均, 马六章, 张翼翔. 基于 LSTM-FC 的瓦斯浓度时空分布预测[J]. *计算机工程与应用*, 2020, 56(16): 258-264.  
CHENG Zijun, MA Liuzhang, ZHANG Yixiang. Prediction of spatiotemporal distribution of gas concentration based on LSTM-FC model[J]. *Computer Engineering and Applications*, 2020, 56(16): 258-264.
- [19] VELIČKOVIĆ P, CUCURULL G, CASANOVA A, et al. Graph attention networks[EB/OL]. [2024-07-22]. <https://arxiv.org/abs/1710.10903v3>.
- [20] ZHOU Haoyi, ZHANG Shanghang, PENG Jieqi, et al. Informer: beyond efficient transformer for long sequence time-series forecasting[C]. AAAI Conference on Artificial Intelligence, Vancouver, 2021: 11106-11115.
- [21] 王苏健, 贾澎涛, 金声尧. 基于随机森林回归的围岩应力插值方法[J]. *西安科技大学学报*, 2021, 41(2): 274-281.  
WANG Sujian, JIA Pengtao, JIN Shengyao. An interpolation method of surrounding rock stress based on random forest regression[J]. *Journal of Xi'an University of Science and Technology*, 2021, 41(2): 274-281.
- [22] 余琼芳, 唐高峰, 王联港. 基于改进 Informer 的综采工作面顶板压力多步长预测[J]. *矿业研究与开发*, 2023, 43(11): 61-67.  
YU Qiongfang, TANG Gaofeng, WANG Liangang. Multi-step prediction of roof pressure of comprehensive mining face based on the improved informer[J]. *Mining Research and Development*, 2023, 43(11): 61-67.