

DOI:10.19651/j.cnki.emt.2212489

# 融合时空特征的浓雾短临趋势预测算法<sup>\*</sup>

应嘉顺<sup>1,2</sup> 张金艺<sup>1,2</sup> 陈琪<sup>3</sup>

(1. 上海大学特种光纤与光接入网重点实验室 上海 200444; 2. 上海大学特种光纤与先进通信国际合作联合实验室 上海 200444; 3. 上海三思电子工程有限公司 上海 201100)

**摘要:** 为减少浓雾可能导致的各项损失,浓雾短临趋势预测已成为气象短临预测领域的研究热点。然而,目前相关研究较多侧重于浓雾所具有的时间特征,忽略其空间特征,从而导致预测准确率较低。为此,提出一种融合时空特征的浓雾短临趋势预测算法。该算法通过将多气象站点抽象为图数据的节点,引入图注意力网络,实现空间特征的提取;在此基础上,针对性地调整长短期记忆网络,结合时间信息,对所提取的空间特征进一步提取时间特征,实现特征级融合,并使用全连接层输出能见度预测值;最后根据能见度预测值,对浓雾短临趋势开展预测。本文所提算法针对美国国家环境信息中心的公开气象数据开展了 2 h 内的浓雾短临趋势预测实验,实验结果表明所提算法的 *F1-score* 和 *TS-score* 较基线模型有 2%~12% 的提升,证明所提算法具有良好的实际应用价值。

**关键词:** 浓雾短临趋势预测;时空特征融合;图注意力网络;长短期记忆网络

中图分类号: TP389 文献标识码: A 国家标准学科分类代码: 520.2060

## Algorithm of short-term prediction for dense fog's trend based on fusion of spatio-temporal features

Ying Jiashun<sup>1,2</sup> Zhang Jinyi<sup>1,2</sup> Chen Qi<sup>3</sup>

(1. Key Laboratory of Specialty Fiber Optics and Optical Access Networks, Shanghai University, Shanghai 200444, China;  
2. Joint International Research Laboratory of Specialty Fiber Optics and Advanced Communication, Shanghai University,  
Shanghai 200444, China; 3. Shanghai Sansi Institute for System Integration, Shanghai 201100, China)

**Abstract:** In order to reduce various losses that may be caused by dense fog, the short-term prediction of dense fog's trend has become a research hotspot in the field of meteorological short-term prediction. However, current researches focus on the temporal features of dense fog while ignoring its spatial features, so the prediction accuracy is still at a relatively low level. To this end, this paper proposes an algorithm of short-term prediction for dense fog's trend based on fusion of spatio-temporal features. The algorithm takes multi-stations as nodes in the graph data. By advancing Graph Attention Network, we realize the extraction of spatial features. On this basis, combined with time information, adjusting the Long-Short Term Memory network to further extract temporal features from the spatial features in order to realize feature-level fusion. Then we use the fully connected layer to output the predicted value of visibility. Further we can get to the predict result  $t$  based on the predicted value of visibility. We apply the algorithm on meteorological data released by National Centers for Environmental Information to carry out the experiment. The experimental results show that the *F1-score* and *TS-score* of the proposed algorithm take an improvement of 2%~12% on baseline models, which proves that the proposed algorithm has a great practical application value.

**Keywords:** short-term prediction for dense fog's trend; spatio-temporal features; graph attention network; long-short term memory

## 0 引言

浓雾是一种常见的天气现象,其所导致的视程障碍往

往会造成人员及财产不同程度的损失。世界气象组织定义的短临预测主要面向局部地区未来 6 h 的天气状况开展。

针对浓雾而言,其持续的时间通常少于 3 h<sup>[1]</sup>,在此期间,浓

收稿日期:2022-12-26

\* 基金项目:上海市闵行区重大产业技术攻关计划(2022MH-ZD19)、十三五国家重点研发计划项目(2017YFB0403500)、高等学校学科创新引智计划(111)项目(D20031)资助

雾会经历发生、维持、消散等趋势变化<sup>[2]</sup>。因此,为了降低浓雾带来的种种损失,开展两小时内的浓雾短临趋势预测成为了亟需解决的问题。

浓雾短临趋势预测通常建立于天气学原理、数值天气预报(numerical weather prediction, NWP)技术和数理统计方法。周须文等<sup>[3]</sup>对低能见度雾的生消机理进行研究,建立能见度气象因子的回归方程,进而实现对浓雾的预测和预报;杨小兵等<sup>[4]</sup>在确定出浓雾形成的重要指示变量基础上,提出了基于“能见度前期震荡”和“大气温度回温波动”特性的浓雾短临预测模型;Shukla 等<sup>[5]</sup>通过将数据同化系统与基于 NWP 技术开发的预测模型结合,实现了对浓雾事件的预测。然而,浓雾的生消机理十分复杂<sup>[6]</sup>,上述方法,特别是基于 NWP 技术的方法,在鲁棒性等方面存在局限,为实现浓雾短临趋势预测,需要对应调整多组参数,增加了错误预测的可能。近年来,伴随着海量气象数据的产生以及人工智能技术的快速发展,为了更好地提高气象数据的利用率,相关研究将人工智能技术应用于浓雾短临趋势预测,以提升预测精度。苗开超等<sup>[7]</sup>基于长短期记忆(long-short term memory, LSTM)网络构建了大雾临近预报框架,对大雾短临趋势进行有效预测;方楠等<sup>[8]</sup>分时期构建基于 LSTM 的预测模型,实现不同时期单站点低能见度的预测;Meng 等<sup>[9]</sup>使用 LSTM 和注意力机制,构造基于编码器-解码器架构的网络实现对机场跑道视程的预测;Kamangir 等<sup>[10]</sup>将数值天气预报模型与 3D 卷积神经网络技术(3D-convolutional neural network, 3D-CNN)相结合,对毗邻港口的机场成功实现了低能见度雾的分级预测;Kim 等<sup>[11]</sup>使用深度神经网络模型和随机森林模型对韩国两个地区的浓雾开展预测。以上处理浓雾短临趋势预测问题的深度学习方法主要聚焦于气象数据所具有的时间特征,大多采用以处理时间序列为主的递归神经网络及其变体,尽管其预测效果相较普通模型有一定的提升,但是这类方法得到的预测结果与前一时刻仍有较强的相关性,对突发的浓雾现象预测准确率较低。而以浓雾为代表的气象现象通常具有较强的空间相关性<sup>[12]</sup>,因此,在算法中增加面向空间相关性处理的部分将弥补仅考虑时间相关性方法的不足,提高预测的精度。周扬<sup>[13]</sup>将气象数据重构成具有空间网络结构的时间序列数据,以此构建 CNN-GRU 模型,对上海市的能见度开展预测;贺玺<sup>[14]</sup>构建时空注意力机制引导的图卷积网络(graph convolutional network, GCN)实现对能见度的预测。上述方法从时空特征的角度出发,预测效果较仅考虑时间特征的模型有进一步的提升,然而,气象站点不规则的空间分布以及浓雾生消机理复杂等特点使得时空特征,特别是空间特征的提取尚不充分,预测准确性仍有一定的提升空间。

综上所述,针对现有基于深度学习的浓雾短临趋势预测方法时空特征提取不充分、误差仍较大的问题,本文基于图注意力网络(graph attention network, GAT)<sup>[15]</sup>和

LSTM,提出一种融合时空特征的浓雾短临趋势预测算法。该算法将多气象站点抽象为图结构的节点后,针对浓雾生消机理复杂的特点,对 GAT 进行改进以更好地提取空间特征。在得到空间特征的基础上,结合浓雾生消时间分布规律,进一步地加入时间信息,针对性地改进调整 LSTM 的输入特征的构成,更好地实现时间特征的提取及时空特征的融合。根据时空特征得到能见度预测值后,结合浓雾短临趋势预测流程,得到最终的预测结果。实验验证结果表明,本文所提算法在美国国家环境信息中心(national centers for environmental information, NCEI)公开气象数据上的预测结果较基线模型均有提升。

## 1 算法框架

浓雾的种类主要包括辐射雾、锋面雾、平流雾等,虽然这些浓雾的成因通常有较大的区别,但浓雾短临趋势普遍具有一定的规律性<sup>[16]</sup>。文献[2]以一次大范围强浓雾具体示例展开,从时间和空间两个维度分析造成其发生、维持、消散等趋势的因素;文献[1,17]从时空分布的角度,分别针对四川及安徽多年间出现的浓雾现象进行统计研究,由此可见,浓雾存在时间相关性和空间相关性。当出现浓雾现象时,通常其影响范围跨度较大且将持续一段时间,在其影响范围内,各地将先后出现一定的发生、维持、消散的浓雾短临趋势变化。此外,浓雾现象出现的前后,除了对能见度有直接影响外,温度、相对湿度、风力等气象要素也伴随着一定的变化规律。

因此,若针对某个站点的浓雾短临趋势开展预测,考虑到该站点所在区域内其余多个站点对该站点可能存在的影响,充分发挥时间相关性和空间相关性,将区域内其余多个站点所采集到的气象数据与所求站点的气象数据进行聚合与更新,提高浓雾短临趋势预测的准确率。基于上述思考,利用多气象站点采集的气象数据构成的原始气象信息  $\mathbf{M} = \{\mathbf{M}_1, \mathbf{M}_2, \dots, \mathbf{M}_V\}$ ,  $\mathbf{M}_v \in R^{C \times T}$  与时间信息  $\mathbf{TI} = [\text{月份信息}, \text{时刻信息}]$ , 本文针对浓雾所具有的空间相关性,将多气象站点抽象为图结构中的节点,引入 K 头 GAT 网络,在此基础上实现对空间特征  $\tilde{\mathbf{h}}$  的提取;针对浓雾所具有的时间相关性,由空间特征  $\tilde{\mathbf{h}}$ 、原始气象信息  $\mathbf{M}$ 、时间信息  $\mathbf{TI}$  共同组成的联合特征  $\mathbf{X}$  作为输入,采用 LSTM 网络,学习其中长期的依赖信息,提取时间特征,并实现时空特征融合  $\tilde{\mathbf{f}}$ ,在此基础上,全连接层输出能见度预测值  $\mathbf{Vis}_{pred} = \{Vis_{pred,1}, \dots, Vis_{pred,V}\}$ ,  $Vis_{pred,v} \in R$ ;对于能见度预测值  $\mathbf{Vis}_{pred}$ ,本文依据现行国家标准《雾的预报等级》(GB/T 27964-2011)中对浓雾能见度大小的规定,设定能见度阈值为 500 m,对应浓雾短临趋势预测流程,得到区域内各个站点的浓雾短临趋势预测结果  $\mathbf{Status} = \{Status_1, \dots, Status_V\}$ ,  $Status_v \in \{"\text{发生}", "\text{维持}", "\text{消散}", "\text{长期无雾"}\}$ 。整体算法框架如图 1 所示。

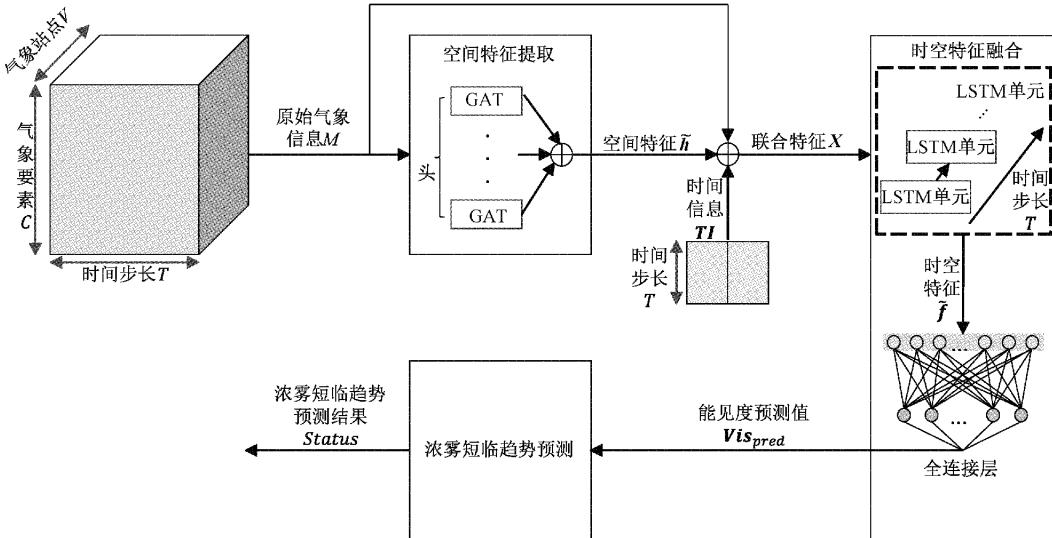


图 1 融合时空特征的浓雾短临趋势预测算法框架

## 2 引入图注意力网络的空间特征提取

图结构的连接状况一般通过邻接矩阵表示,在气象预测领域中通常将各个气象站点视为图结构中的节点后,根据各节点之间空间上的相对位置,通过河流的流向或者经纬度计算得到的距离构建对应的邻接矩阵<sup>[18-19]</sup>。然而浓雾形成机理复杂,不仅与空间上的相对位置相关,还可能受到空间中其它因素如地形、盛行风和急流等<sup>[20]</sup>的影响。因此,仅根据空间上的相对位置确定的邻接矩阵可能导致后续所得到的节点表示不能完整体现空间特征。为此,本文针对性地将图结构的邻接矩阵  $A$  视作可学习的参数,在提高空间特征提取能力的同时,更进一步了解节点间的影响关系。并由式(1)得到的归一化后的邻接矩阵  $\hat{A}$  推得度矩阵  $\hat{D}$ ,并使用对称标准化得到  $\tilde{A}$ 。

$$\hat{A} = \frac{A - A_{\min}}{A_{\max} - A_{\min}} \quad (1)$$

$$\hat{D} = \sum \hat{A} \quad (2)$$

$$\tilde{A} = \hat{D} - \frac{1}{2} \hat{A} \hat{D} - \frac{1}{2} \quad (3)$$

其中,  $\hat{A}$  由邻接矩阵  $A$  归一化后得到;  $A_{\min}$  与  $A_{\max}$  分别代表邻接矩阵  $A$  中最小的元素值与最大的元素值;  $\hat{D}$  表示根据  $\hat{A}$  得到的度矩阵;  $\tilde{A}$  表示对称标准化的邻接矩阵。

图卷积神经网络主要分为谱方法和空间方法两类:谱方法通过图谱理论和卷积定理定义图卷积,空间方法从节点域出发,通过聚合函数实现中心节点和邻居节点的聚合<sup>[21]</sup>。GAT 作为空间方法的一种,基于注意力机制构建聚合函数,将邻居节点的特征以加权和的形式聚合到中心节点,得到中心节点的空间特征表示,实现空间特征的提取。GAT 的输入是由多个气象节点的特征向量组成的特

征集  $h$ :

$$h = \{h_1, h_2, \dots, h_V\}, h_i \in R^d \quad (4)$$

其中,  $h_i$  代表气象节点  $i$  的特征向量;  $V$  代表气象节点的个数;  $d$  代表气象节点的特征个数且满足  $d = C \times T$ , 即气象要素的种类数  $C$   $\times$  时间步长  $T$ 。

在 GAT 中首先通过一个共享的权值矩阵  $W$  对每个节点的特征向量实现  $d \rightarrow d'$  的特征维度转换,再利用自注意力机制,计算两个节点间的注意力因子  $e_{i,j}$ :

$$e_{i,j} = a(Wh_i \| Wh_j) \quad (5)$$

其中,权值矩阵  $W \in R^{d' \times d}$ ;  $a$  为单层前馈神经网络,  $a \in R^{2d'}$ ;  $\|$  表示拼接操作;  $e_{i,j}$  体现邻居节点  $j$  对中心节点  $i$  的重要性。

其次,对邻居节点  $j$  与中心节点  $i$  的注意力因子使用 LeakyReLU 进行非线性映射,并采用 Softmax 得到邻居节点  $j$  与中心节点  $i$  的归一化的注意力得分  $\alpha_{i,j}$ :

$$\alpha_{i,j} = \frac{\exp(\text{LeakyReLU}(e_{i,j}))}{\sum_{k \in N(i)} \exp(\text{LeakyReLU}(e_{i,k}))} \quad (6)$$

其中,需要特别注意的是 Softmax 计算过程中涉及中心节点  $i$  与其所有邻居节点  $k \in N(i)$  的注意力因子  $e_{i,k}$ ,而本文用于表征图结构连接状况的邻接矩阵是通过端到端学习得到的,因此在计算该步时默认中心节点  $i$  与其余所有节点均有连接。

进一步,根据式(6)得到的中心节点  $i$  与各个邻居节点之间的注意力得分,利用加权求和的方式计算中心节点  $i$  的表示  $h'_i$ :

$$h'_i = \sigma \left( \sum_{j \in N(i)} \alpha_{i,j} Wh_j \right) \quad (7)$$

其中,  $\sigma(\cdot)$  为激活函数,  $h'_i \in R^{d'}$ 。

最后,针对式(6)与(7),为体现图结构的连接状况,设计基于 GAT 与端到端学习的邻接矩阵的聚合函数。对特征集中每一个节点进行上述步骤后,得到整体特征表示

$\mathbf{h}' \in R^{V \times d'}$ , 与对称标准化的邻接矩阵  $\tilde{\mathbf{A}}$  相乘, 得到融合加权空间信息的特征表示  $\hat{\mathbf{h}}$ :

$$\hat{\mathbf{h}} = \tilde{\mathbf{A}}\mathbf{h}' \quad (8)$$

其中, 融合加权空间信息的特征表示  $\hat{\mathbf{h}} \in R^{V \times d'}$ , 对应节点  $i$  的节点特征表示  $\hat{\mathbf{h}}_i \in R^{d'}$ 。

使用多头注意力机制进一步增强算法的表征能力, 即重复上述步骤  $K$  次, 并最后通过拼接对多个注意力头实现整合, 完成对整体空间特征  $\tilde{\mathbf{h}}$  的提取, 对应节点  $i$  的节点空间特征表示:

$$\tilde{\mathbf{h}}_i = \parallel_{k=1}^K \hat{\mathbf{h}}_i^k \quad (9)$$

针对浓雾所具有的空间相关性, 通过多头图注意力机制, 结合端到端学习的邻接矩阵  $\mathbf{A}$ , 得到最终的节点空间特征表示  $\tilde{\mathbf{h}}_i$ , 充分利用节点间的不同影响程度, 实现算法的空间特征提取。

### 3 基于长短期记忆网络的时空特征融合

在得到空间特征  $\tilde{\mathbf{h}}$  后, 为了进一步获取气象数据中的时间特征, 引入可以有效提取时间特征的 LSTM<sup>[22]</sup>。通过单元记忆细胞  $c_t$  及 3 种门控设计: 遗忘门 FG、输入门 IG 和输出门 OG, LSTM 可以有效地传递每个时间步中提取到的信息。LSTM 单元结构如图 2 所示。

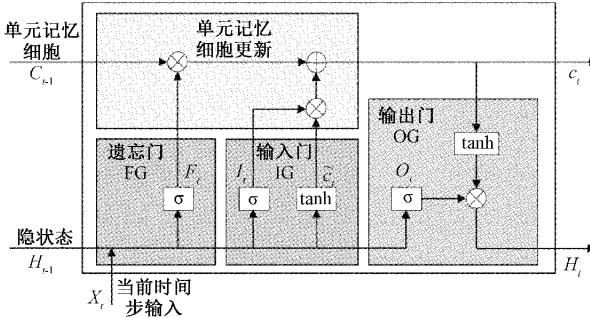


图 2 LSTM 单元结构

由于浓雾现象的时间分布有明显规律, 在秋冬季节与早晚时刻相比其余季节与时刻更易出现浓雾现象<sup>[16]</sup>, 因此根据这一规律, 对 LSTM 输入特征的构成进行改进调整, 将气象数据所在月份与时刻对应时间分布规律分配不同的权重后作为特征输入 LSTM, 有助于更好地提取时间特征, 完成时空特征融合。所以, LSTM 的输入  $\mathbf{X}$  由经过维度变换后的空间特征  $\tilde{\mathbf{h}}' \in R^{T \times L}, L = (V \times d' \times K)/T$ 、原始气象信息  $\mathbf{M} \in R^{T \times (C \times V)}$  及时间信息  $\mathbf{Tl} \in R^{T \times 2}$  拼接而成:

$$\mathbf{X} = \tilde{\mathbf{h}}' \parallel \mathbf{Tl} \parallel \mathbf{M}, \mathbf{X} \in R^{T \times (L+2+(C \times V))} \quad (10)$$

遗忘门 FG 根据上一个时间步的 LSTM 单元传入的隐状态  $\mathbf{H}_{t-1}$  与当前时间步的输入  $\mathbf{X}_t$ , 控制上一个单元记

忆细胞  $c_{t-1}$  中信息的丢弃或者保留, 遗忘门 FG 的  $\mathbf{F}_t$  计算公式为:

$$\mathbf{F}_t = \sigma(\mathbf{W}_F [\mathbf{H}_{t-1} \parallel \mathbf{X}_t] + \mathbf{b}_F) \quad (11)$$

其中,  $\mathbf{W}_F$  为遗忘门权重;  $\mathbf{b}_F$  为遗忘门偏置项;  $\sigma(\cdot)$  为激活函数, 通常选择 Sigmoid 函数。

输入门 IG 首先根据  $\mathbf{H}_{t-1}$  与  $\mathbf{X}_t$  得到候选单元记忆细胞  $\tilde{c}_t$ , 对应当前时间步产生的新信息; 其次类似于遗忘门 FG, 通过输入门 IG 的  $\mathbf{I}_t$  控制候选单元记忆细胞  $\tilde{c}_t$  对当前单元记忆细胞  $c_t$  的更新, 候选单元记忆细胞  $\tilde{c}_t$  与输入门 IG 的  $\mathbf{I}_t$  计算公式分别为:

$$\tilde{c}_t = \tanh(\mathbf{W}_I [\mathbf{H}_{t-1} \parallel \mathbf{X}_t] + \mathbf{b}_I) \quad (12)$$

$$\mathbf{I}_t = \sigma(\mathbf{W}_I [\mathbf{H}_{t-1} \parallel \mathbf{X}_t] + \mathbf{b}_I) \quad (13)$$

其中,  $\mathbf{W}_I$  与  $\mathbf{W}_t$  为输入门权重;  $\mathbf{b}_I$  与  $\mathbf{b}_t$  为输入门偏置项。

由此, 当前单元记忆细胞  $c_t$  根据遗忘门及输入门分别进行选择性遗忘及记忆, 因此  $c_t$  更新公式为:

$$c_t = \mathbf{F}_t \times c_{t-1} + \mathbf{I}_t \times \tilde{c}_t \quad (14)$$

输出门 OG 控制当前单元记忆细胞  $c_t$  对隐状态  $\mathbf{H}_t$  的更新:

$$\mathbf{O}_t = \sigma(\mathbf{W}_O [\mathbf{H}_{t-1} \parallel \mathbf{X}_t] + \mathbf{b}_O) \quad (15)$$

$$\mathbf{H}_t = \mathbf{O}_t \times \tanh(c_t) \quad (16)$$

其中,  $\mathbf{W}_O$  为遗忘门权重;  $\mathbf{b}_O$  为遗忘门偏置项。

针对浓雾所具有的时间相关性及浓雾生消时间分布规律, 基于 LSTM, 调整输入特征的构成, 特别是加入带权重的时间信息, 从时间序列角度充分提取各类气象要素在浓雾影响下的特征。最后时间步输出的隐状态  $\mathbf{H}_T$  即为特征级融合后的时空特征  $\tilde{f}$ , 至此实现算法的时空特征融合。进一步的, 针对所获取的时空特征  $\tilde{f}$  经过全连接层输出能见度预测值  $Vis_{pred}$ 。

### 4 融合时空特征的浓雾短临趋势预测

在第 3 章得到的预测能见度值  $Vis_{pred}$  的基础上, 对应所设定的能见度阈值 500 m, 制订如图 3 所示的浓雾短临趋势预测流程。需要注意的是, 为了使本文的算法具有可扩展性以适应其他雾的等级或不同标准下浓雾对应能见度值的大小, 同时为了更加直观地展现出能见度预测值  $Vis_{pred}$  与能见度真实观测值  $Vis_{true}$  的误差, 以及由能见度预测值  $Vis_{pred}$  与多个历史能见度真实观测值所构成的能见度整体变化情况, 本文将算法归为对能见度值的拟合任务, 配合本章所提流程实现分类目的。

首先, 对单站点能见度预测值  $Vis_{pred,v}$ , 对应能见度阈值确定站点预测状态  $State_{predict,v} \in \{"\text{浓雾}": state1, "\text{非浓雾}": state2\}$ ; 其次, 读取该站点的历史状态  $State_{history,v} \in \{state1, state2\}$ , 与预测状态  $State_{predict,v}$  比较; 最后, 根据比较结果, 进一步细分得到该站点的浓雾短临趋势预测结果  $Status_v \in \{"\text{发生}": status1, "\text{维持}": status2, "\text{消散}":$

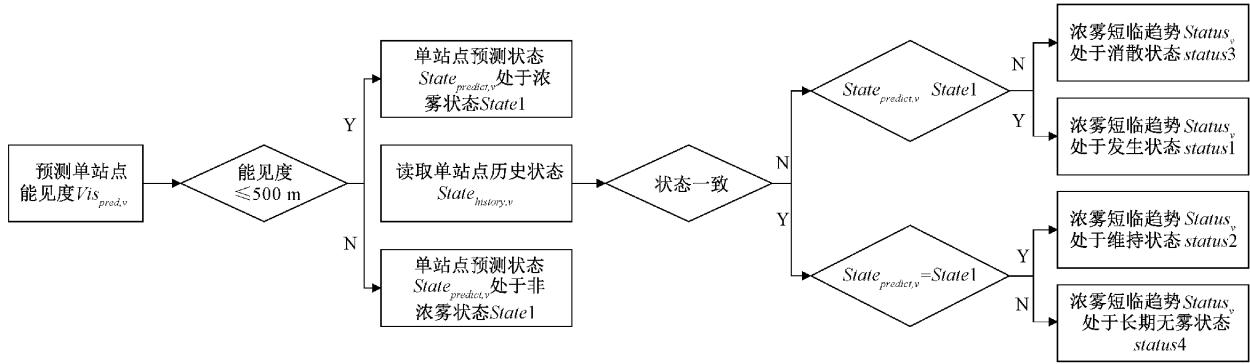


图 3 浓雾短临趋势预测流程

*status3*, "长期无雾";*status4*)。根据上述流程,结合本文所提算法,对应图 1 中各个环节,实现融合时空特征的浓雾短临趋势预测的整体算法的伪代码如表 1 所示。

表 1 融合时空特征的浓雾短临趋势预测算法伪代码实现

输入: $\mathbf{M}$ —— 原始气象信息	$\mathbf{TI}$ —— 时间信息
输出: $Status$ —— 浓雾短临趋势预测结果	

```

1: 读取输入  $\mathbf{M}$  与  $\mathbf{TI}$ , 初始化站点历史状态存储列表
   $State_{history} = []$ , 站点预测状态存储列表  $State_{predict} = []$ ,
  设定站点状态查询字典  $State\_map = \{"Vis \leq 500m": "浓雾", "Vis > 500m": "非浓雾"\}$  ;
2: for  $v = 1, 2, \dots, V$  do:
3:   从  $\mathbf{M}_v$  中读取第  $T$  时刻  $Vis_T$ , 查询  $State\_map$  获取
  状态,存入  $State_{history}$  ;
4:   END for
5: 通过 GAT 对  $\mathbf{M}$  提取空间特征  $\tilde{\mathbf{h}}$ ;
6: 由  $\tilde{\mathbf{h}}, \mathbf{M}$  与  $\mathbf{TI}$  组合的  $\mathbf{X}$  进一步提取时间特征,得到融
  合后的时空特征  $\tilde{\mathbf{f}}$ ;
7: 通过全连接层得到多气象站点能见度预测值  $Vis_{pred}$  ;
8: for  $v = 1, 2, \dots, V$  do:
9:   对  $Vis_{pred,v}$  查询  $State\_map$  获取预测状态,存入
   $State_{predict,v}$  ;
10:  if ( $State_{predict,v} = "浓雾" \neq State_{history,v}$ ):  $Status_v = "发生"$ ;
11:  if ( $State_{predict,v} \neq "浓雾" = State_{history,v}$ ):  $Status_v = "消散"$ ;
12:  if ( $State_{predict,v} = "浓雾" = State_{history,v}$ ):  $Status_v = "持续"$ ;
13:  if ( $State_{predict,v} \neq "浓雾" \neq State_{history,v}$ ):  $Status_v = "长期无雾"$ ;
14:  END for
15: 结束程序
  
```

## 5 验证与结果分析

### 5.1 数据集描述及预处理

本文所用数据由 NCEI 公开气象数据中获得,选取地理位置坐标为北纬 50.317° 至北纬 59.041°,西经 -6.855° 至东经 1.978° 范围内英国地区的逐时气象观测数据,考虑到气象数据质量、气象站点间距离等因素,经过数据清洗筛选后,选定如图 4 所示的 8 个站点所采集的逐时气象观测数据作为本文数据来源。

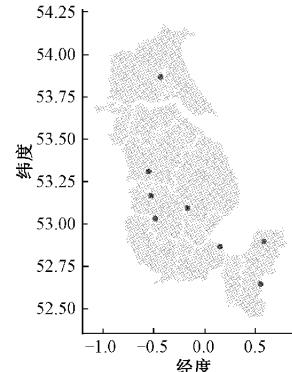


图 4 英国区域选取气象站点分布图(东米德兰-东英格兰)

所选气象站点的逐时历史气象观测数据采集时间自 2015 年 1 月 1 日 0 时 ~ 2021 年 12 月 31 日 23 时,共计 490 944 组样本数据,其中能见度低于 500 m 以下的样本数据约 7 100 时次。为构建原始气象信息  $\mathbf{M}$ ,选取气温、露点温度、能见度、风速、风向、气压和降雨量共  $C = 7$  类气象要素;为构建时间信息  $\mathbf{TI}$ ,选取样本采样时刻对应的月份信息及时刻信息。

针对原始气象信息  $\mathbf{M}$  中可能存在的气象数据缺失及异常数据的状况,本文采用拉格朗日二次插值法,利用缺失或异常的气象数据最近的 3 个同类别气象要素的采样值对进行插值,插值公式如下:

$$\begin{aligned}
 x_{m,j} &= \frac{(t_m - t_b)(t_m - t_c)}{(t_a - t_b)(t_a - t_c)}x_{a,j} + \\
 &\quad \frac{(t_m - t_a)(t_m - t_c)}{(t_b - t_a)(t_b - t_c)}x_{b,j} + \frac{(t_m - t_a)(t_m - t_b)}{(t_c - t_a)(t_c - t_b)}x_{c,j}
 \end{aligned} \quad (17)$$

其中,  $t_m$  为缺失或异常的气象数据所处时刻,  $t_a, t_b, t_c$  为  $t_m$  时刻附近的时刻且满足  $t_a < t_b < t_m < t_c$ ;  $x_{m,j}$  为第  $j$  类缺失或异常的气象数据插值后的结果,  $j = 1, 2, \dots, 7$ ;  $x_{a,j}, x_{b,j}$  和  $x_{c,j}$  分别对应  $t_a, t_b, t_c$  时刻的第  $j$  类气象数据。

同时,由于各气象要素数值区间有较大差异,采用式(18)对气温、露点温度、能见度、风速、风向、气压和降雨量 7 类气象数据进行归一化处理:

$$\hat{x}_j = \frac{x_j - x_{j,\min}}{x_{j,\max} - x_{j,\min}} \quad (18)$$

其中,  $\hat{x}_j$  为第  $j$  类气象数据归一化后得到的结果,  $j = 1, 2, \dots, 7$ ;  $x_j$  为第  $j$  类气象数据的原始数据;  $x_{j,\max}$  为第  $j$  类气象数据中的最大值;  $x_{j,\min}$  为第  $j$  类气象数据中的最小值。

## 5.2 实验环境及评价指标

实验所用软件环境为: Windows10 操作系统, Python3.8, Pytorch1.9; 硬件环境为: GPU: NVIDIA GeForce RTX 2060。

为了评估本文算法对浓雾短临趋势预测的准确性,采用  $F1\text{-score}$  和  $TS\text{-score}$  两个分类评价指标进行定量分析:

$$Precision = \frac{TP}{TP + FP} \quad (19)$$

$$Recall = \frac{TP}{TP + FN} \quad (20)$$

$$F1\text{-score} = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (21)$$

$$TS\text{-score} = \frac{TP}{TP + FP + FN} \quad (22)$$

其中,正样本对应 2 种情况:1)所需预测时刻  $T + N$  实际观测能见度值低于 500 m 时对应判别的浓雾短临趋势为“发生”或“维持”,即  $T + N$  时刻实际处于“浓雾”状态  $state_1$  时对应的  $Status_{true} \in \{"\text{发生"}: status_1, "\text{维持"}: status_2\}$ ; 2)所需预测时刻  $T + N$  实际观测能见度值高于 500 m 时对应的浓雾短临趋势为“消散”,即  $T + N$  时刻实际处于“非浓雾”状态  $state_2$  时对应的  $Status_{true} \in \{"\text{消散"}: status_3\}$ 。其余情况均视为负样本。 $TP$  表示对正样本准确预测的数量,  $TN$  表示对负样本准确预测的数量,  $FP$  表示对负样本错误预测为正样本的数量,  $FN$  表示对正样本错误预测为负样本的数量。

## 5.3 实验结果分析

为了测试本文所提算法的预测效果,针对空间特征的重要性方面的验证,本文与常见的基于时间特征的模型进行比较,包括 1D-CNN<sup>[23]</sup>、LSTM<sup>[7]</sup>; 同时为了说明时间特征的重要性,与仅捕获空间特征的 GCN<sup>[20]</sup>、GAT<sup>[15]</sup> 比较。为了验证本文所提算法模型中各部分模块设计的有效性,进行相应的消融实验,包括 GAT-LSTM、“仅空间特征”与“仅时间特征”。

实验中,对所使用的数据集以 8 : 2 的比例划分为训

练集和测试集,模型输入的时间步长  $T$  为 6,气象要素  $C$  为 7,气象站点  $V$  为 8,分别预测  $N = 1, 2$  h 的浓雾短临趋势。实验参数设置如下:训练轮次为 50,批大小为 64,采用 MSE 作为损失函数,初始学习率为 0.001,LSTM 层数为 3,GAT 层数为 1,多头注意力头数  $K$  为 6,使用 Adam 优化器训练模型。

实验中分别采用本文算法与基线模型对 8 个气象站点未来 2 h 内的浓雾短临趋势开展预测,结果对比如表 2 所示。从表 2 的结果可以看出,本文算法在对未来 2 h 内浓雾短临趋势预测的  $F1\text{-score}$  和  $TS\text{-score}$  两项指标较其它常见的基线模型均有 2%~12% 的提升,这两个指标的提升表征了算法对浓雾短临趋势分类准确率的提高。

表 2 不同基线模型及消融实验的预测效果对比

模型	$F1\text{-score}$		$TS\text{-score}$	
	未来 1 h	未来 2 h	未来 1 h	未来 2 h
1D-CNN <sup>[23]</sup>	0.752	0.575	0.625	0.425
LSTM <sup>[7]</sup>	0.776	0.678	0.631	0.475
GCN <sup>[20]</sup>	0.734	0.624	0.584	0.438
GAT <sup>[15]</sup>	0.759	0.632	0.616	0.442
GAT-LSTM	0.786	0.684	0.658	0.514
仅空间特征	0.764	0.649	0.628	0.463
仅时间特征	0.779	0.678	0.637	0.478
本文	0.805	0.691	0.682	0.547

消融实验中, GAT-LSTM 的预测效果优于其它仅考虑一种特征的模型,证明从时空特征角度开展浓雾短临趋势预测的重要性。“仅空间特征”与“仅时间特征”两部分模块各自的预测效果在指标上也分别优于 GAT 与 LSTM,表明两部分模块改进部分均有助于提高预测准确率。与 GAT-LSTM 相比,本文算法对未来 1 h 的浓雾短临趋势预测的  $F1\text{-score}$  和  $TS\text{-score}$  分别提升了 2.42% 与 3.65%,证明由两部分模块组合后的本文算法可以更有效地对浓雾短临趋势准确分类。

此外,通过本文算法中用于空间特征提取的 GAT 与通过端到端方式学习得到的邻接矩阵均可以更加直观地了解各个气象站点间相互影响程度。8 个气象站点间的邻接矩阵对应的可视化热力图如图 5 所示,除主对角线外,矩阵中各元素的值表明通过大量训练后学习得到的 8 个气象站点间隐藏的空间关系,避免了仅由空间上的相对位置确定的邻接矩阵可能导致空间特征提取不充分的问题。各站点间的注意力得分如图 6 所示,注意力得分矩阵表明了不同邻居节点的气象数据所包含的特征信息对中心节点空间特征提取时的影响程度。为直观地展示不同模型对能见度值的预测效果,选取某个站点的两个时段开展浓雾短临趋势预测,如图 7 所示。

其中,图 7(a)展示的是该站点经历能见度由持续处于

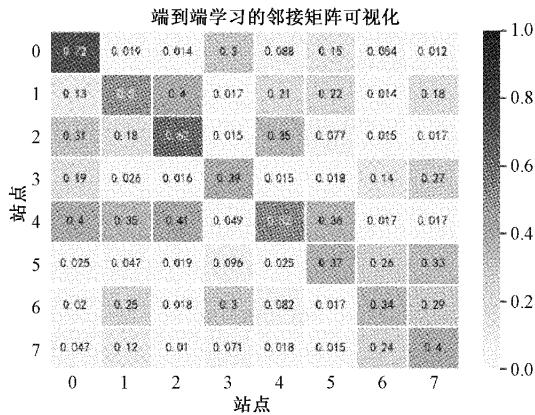


图 5 邻接矩阵可视化

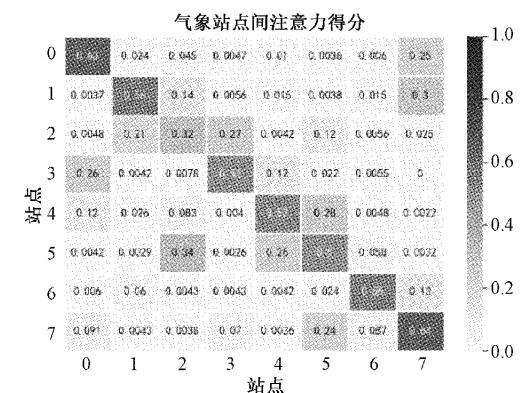
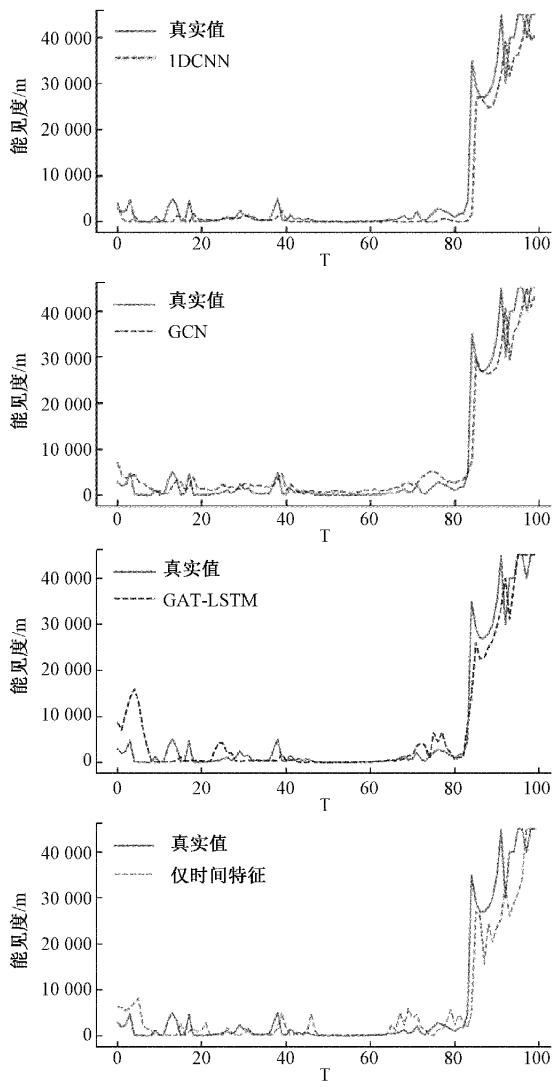
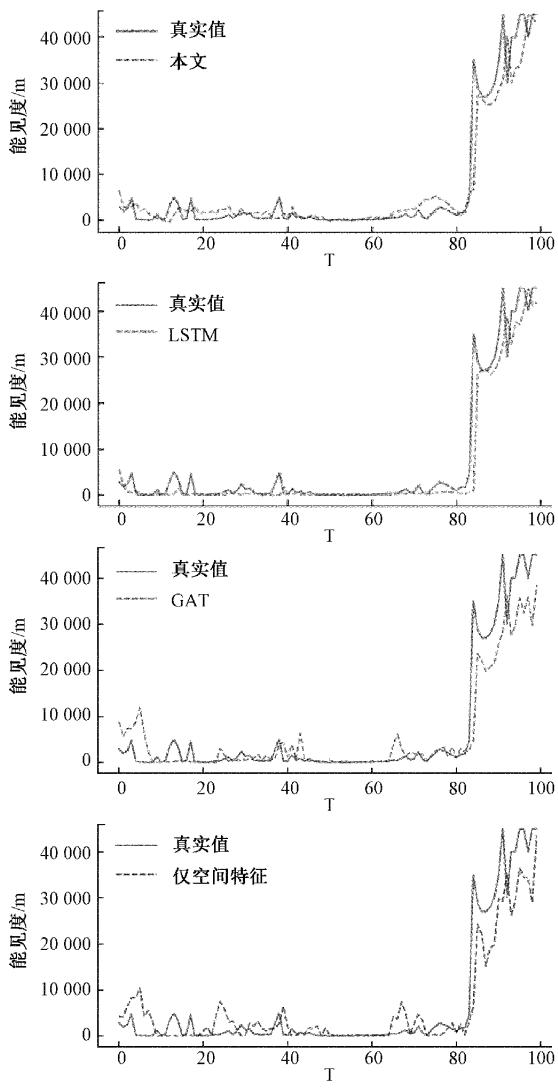
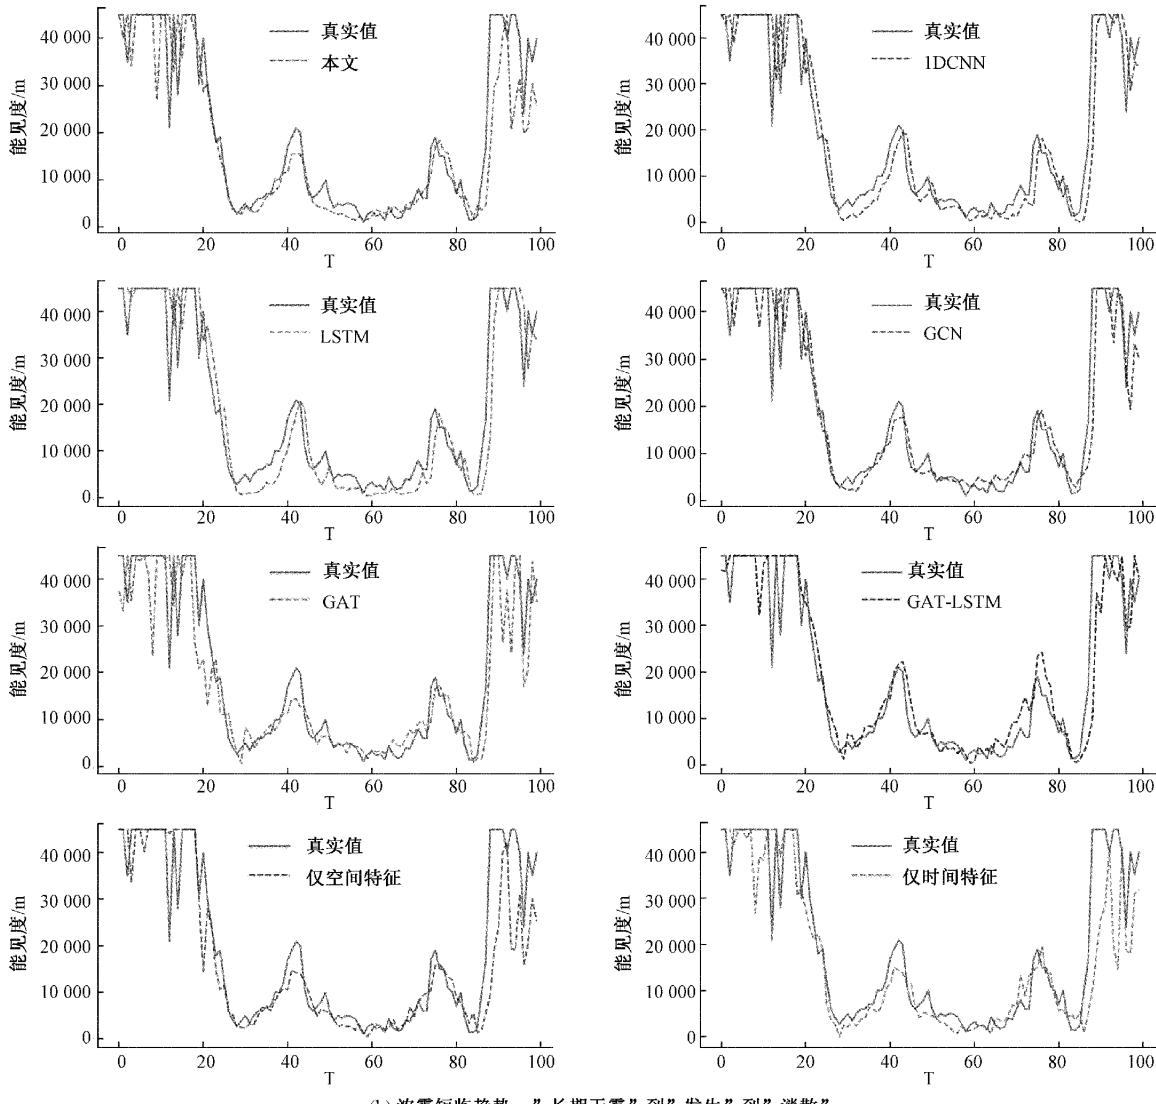


图 6 注意力得分可视化



(a) 浓雾短临趋势：“持续”到“消散”



(b) 浓雾短临趋势：“长期无雾”到“发生”到“消散”

图 7 对比实验和消融实验的能见度预测效果

低位到上升至高位的过程,即对应浓雾短临趋势“持续”到“消散”的过程,从图 7(a)中可以发现相比较其他模型,本文所提算法对能见度的预测与真实能见度的变化情况较为贴近,以 0~80 时刻为例,实际能见度大小处于 0~5 000 m 的震荡过程,而 LSTM、1D-CNN 等多个模型长时间预测能见度低于 500 m,造成部分的负样本被错误分类为正样本,而本文所提算法可以较好的贴近实际的震荡过程,并在较为突发的浓雾消散时刻可以准确做出短临趋势预测;图 7(b)展示的是该站点经历能见度从高位降低后,经历起伏,再恢复高位的过程,即处于“长期无雾”到有一定浓雾“发生”的趋势,再到浓雾“消散”的趋势变化过程,从图 7(b)中可以发现相比较其他模型,本文所提算法同样对能见度的预测与真实能见度的变化情况较为贴近,特别是中间时刻的起伏期与其他模型相比,能够更好地预测趋势变化情况。由此可见,本文所提算法可以较好地对

浓雾短临趋势进行有效预测。

## 6 结 论

本文将一定区域内的气象站点抽象为图结构的节点,提出了一种融合时空特征的浓雾短临趋势预测算法,通过 GAT 和端到端学习的邻接矩阵,构造聚合函数,实现空间特征的提取,提升了模型的表征能力,针对浓雾生消时间分布规律,对 LSTM 做出相应的优化调整,实现时空特征的特征级融合,并输出能见度预测值,通过一定流程得到浓雾短临趋势预测的结果。结果表明与基线模型相比,本文算法具有更好的预测表现。然而,目前本文的浓雾短临趋势预测仅针对单气象站点分别开展,尚未从整体的角度对整个区域内的浓雾短临趋势进行预测,例如浓雾传播扩展的过程等;此外,后续可以进一步引入基于动态图的方法来提升预测表现。

## 参考文献

- [1] 李慧晶,余芳,李洪梅,等.四川不同等级雾的时空分布及其生消时间[J].高原山地气象研究,2021,41(2):88-93.
- [2] 李婷,谭志强,葛森,等.2018年8月22日宁夏北部局地浓雾天气形成机制分析[J].气象与环境学报,2022,38(1):8-14.
- [3] 周须文,时青格,贾俊妹,等.低能见度雾的分级预报方法研究[J].热带气象学报,2014,30(1):161-166.
- [4] 杨小兵,杨再均,韩晖,等.基于重要指示变量和特征的高速公路浓雾短临预测研究[J].公路交通科技,2021,38(6):120-128.
- [5] SHUKLA A, AGNIHOTRI G, SINGH A. Analysis of fog and inversion characteristics and prediction of fog and associated meteorological parameters using NWP model over sub-urban Bangalore[J]. Journal of Earth System Science, 2022, 131(4), DOI: 10.1007/s12040-022-01967-1.
- [6] LAKRA K, AVISHEK K. A review on factors influencing fog formation, classification, forecasting, detection and impacts[J]. Rendiconti Lincei. Scienze Fisiche e Naturali, 2022, 33(1): 319-353.
- [7] 苗开超,韩婷婷,王传辉,等.基于LSTM网络的大雾临近预报模型及应用[J].计算机系统应用,2019,28(5):215-219.
- [8] 方楠,谢国权,阮小建,等.长短期记忆神经网络(LSTM)模型在低能见度预报中的应用[J].气象与环境学报,2022,38(5):34-41.
- [9] MENG Y, QI F, ZUO H, et al. Multi-step LSTM prediction model for visibility prediction [C]. 2020 International Joint Conference on Neural Networks(IJCNN), 2020: 1-8.
- [10] KAMANGIR H, COLLINS W, TISSOT P, et al. FogNet: A multiscale 3D CNN with double-branch dense block and attention mechanism for fog prediction [J]. Machine Learning with Applications, 2021, 5, DOI: 10.1016/j.mlwa.2021.100038.
- [11] KIM J, KIM S H, SEO H W, et al. Meteorological characteristics of fog events in Korean smart cities and machine learning based visibility estimation [J]. Atmospheric Research, 2022, 275: 106239.
- [12] 周建平,张蕾,王传辉,等.大雾临近预报中高密度能见度数据应用[J].气象科技,2019,47(5):866-871.
- [13] 周扬.上海市能见度时空特征及预测研究[D].上海:华东师范大学,2020.
- [14] 贺玺.大气能见度影响因素分析及预测[D].北京:北京工业大学,2020.
- [15] VELICKOVIC P, CUCURULL G, CASANOVA A, et al. Graph attention networks[C]. Proceedings of the International Conference on Learning Representations (ICLR), 2018, DOI: 10.48550/arXiv.1710.10903.
- [16] 孙丹,朱彬,杜吴鹏.我国大陆地区浓雾发生频数的时空分布研究[J].热带气象学报,2008,24(5):497-501.
- [17] 邵禹晨,张雪蓉,王博妮,等.一次中国东部大范围强浓雾的传播与扩展机制分析[J].气象,2019,45(4):496-510.
- [18] 马栋林,马司周,王伟杰.基于图卷积网络和门控循环单元的多站点气温预测模型[J].计算机应用,2022,42(1):287-293.
- [19] 胡鹤轩,隋华超,胡强,等.基于图注意力网络与双阶注意力机制的径流预报模型[J].计算机应用,2022,42(5):1607-1615.
- [20] WILSON T, TAN P N, LUO L. A low rank weighted graph convolutional approach to weather prediction[C]. 2018 IEEE International Conference on Data Mining(ICDM), 2018: 627-636.
- [21] 徐冰冰,岑科廷,黄俊杰,等.图卷积神经网络综述[J].计算机学报,2020,43(5):755-780.
- [22] 邢红涛,郭江龙,刘书安,等.基于CNN-LSTM混合神经网络模型的NO<sub>x</sub>排放预测[J].电子测量技术,2022,45(2):98-103.
- [23] 杨仁昊.无锡地区高速公路能见度时空变化特征及其预测研究[D].南京:南京信息工程大学,2022.

## 作者简介

应嘉顺,硕士研究生,主要研究方向为深度学习、智能信息处理。

E-mail:yingjiashun\_1998@shu.edu.cn

张金艺(通信作者),研究员,主要研究方向为人工智能、图像处理。

E-mail:zhangjinyi@shu.edu.cn

陈琪,工程师,主要研究方向为智能图像识别、信号处理。

E-mail:chenqi@sansitech.com