

# 考虑风速空间异质性的 LSTM-AM 雾天能见度预测模型

王小建<sup>1</sup>, 林智婕<sup>1,\*</sup>, 马飞<sup>1</sup>, 苏彤<sup>1</sup>, 白元旦<sup>1</sup>, 郭庆元<sup>2</sup>, 黄凯<sup>3</sup>

1. 长安大学经济与管理学院, 陕西, 西安 710064

2. 西安市气象局, 陕西, 西安 710016

3. 西安市交通信息中心, 陕西, 西安 710018

**摘要:** 针对现有方法在雾天能见度预测时对风速空间异质性考虑不足导致预测准确性和稳定性不高的问题, 本文构建了考虑风速空间异质性的长短期记忆神经网络-注意力机制(LSTM-AM)雾天能见度预测模型。利用半变异函数对风速不同空间位置的变化特征进行量化, 融合邻近点空间分布及风速差异信息, 采用风向夹角和变异值对风速空间异质性特征进行加权, 实现对风速空间异质性的有效提取; 利用 AM 机制能加强对关键信息关注的优势对 LSTM 方法进行改进, 以有效捕捉和反映关键时刻气象因子对雾天能见度的影响, 增强模型对重要时序信息关注的能力和模型预测的准确性, 实现风速空间异质性下对雾天能见度的预测。研究表明, 本文模型  $R^2$  提升 10%-20%, RMSE 下降 25%-40%, MAE 下降 26.3%-39.1%, 具有较高的雾天能见度预测精度。

**关键词:** 空间异质性; 半变异函数; 长短期记忆神经网络; 注意力机制; 雾天能见度

**文章编号:** 中图分类号:P456 文献标识码:A

doi:10.3878/j.issn.1006-9585.2024.24101

## LSTM-AM Fog visibility prediction model accounting for spatial heterogeneity of wind speed

WANG Xiao-jian<sup>1</sup>, LIN Zhi-jie<sup>1,\*</sup>, MA Fei<sup>1</sup>, SU Tong<sup>1</sup>, BAI Yuan-dan<sup>1</sup>, GUO Qing-yuan<sup>2</sup>, HUANG Kai<sup>3</sup>

1. School of Economics and Management, Chang'an University, Xi'an 710064, China

2. Xi'an Meteorological Bureau, Xi'an 710016, China

3. Xi'an Traffic Information Center, Xi'an 710018, China

**Abstract:** To address the issue of insufficient consideration of the spatial heterogeneity of wind speed in existing methods for fog visibility prediction, which leads to low accuracy and stability, this paper constructs a Long Short-Term Memory Neural Network with Attention Mechanism (LSTM-AM) model for fog visibility prediction that takes into account the spatial heterogeneity of wind speed. The model quantifies the variation characteristics of wind speed at different spatial locations using a semi-variogram, integrating the spatial distribution of neighboring points and differences in wind speed. It employs wind direction angles and variation values to weight the features of wind speed spatial heterogeneity, effectively extracting these characteristics. Additionally, the Attention Mechanism (AM) enhances the LSTM method by improving its focus on key information, enabling the model to effectively capture and reflect the impact of critical meteorological factors on fog visibility. This enhances the model's ability to pay attention to important temporal information and improves the accuracy of predictions under conditions of wind speed spatial heterogeneity. The results indicate that

**收稿日期:** 2024-07-09; **收修定稿:** 2024-12-04

**作者简介:** 王小建 (1968-), 男, 副教授, 博士, 研究方向为交通运输服务科学与工程. E-mail: wangxj@chd.edu.cn

**通讯作者:** 林智婕 (2000-), 女, 研究生. 研究方向为交通气象与安全. E-mail: linzj@chd.edu.cn

**基金项目:** 国家自然科学基金项目(72104034, 72104037); 陕西省教育厅 2021 年度重点科学研究计划项目(21JIP007); 陕西省交通运输厅交通科技项目(23-12K); 陕西省社会科学基金项目(2024R009);

**Funded by** National Natural Science Foundation of China (Grant 72104034, 72104037), Key Scientific Research Plan Project of Shaanxi Provincial Department of Education in 2021 (Grant 21JIP007), Shaanxi Provincial Department of Transportation Science and Technology Project (Grant 23-12K); Shaanxi Provincial Social Science Foundation Project (Grant 2024R009);

the proposed model improves  $R^2$  by 10%-20%, reduces RMSE by 25%-40%, and decreases MAE by 26.3%-39.1%, demonstrating high accuracy and stability in fog visibility prediction.

**Keywords:** Spatial Heterogeneity; Semi-variogram; Long Short-Term Memory Neural Network; Attention Mechanism; Fog visibility

## 1 引言

能见度作为衡量大气透明度的重要指标，对交通运输安全具有较大的影响。已有研究表明，因雾等低能见度天气所造成的交通事故大约占总事故的 25%(刘旗洋等, 2022; 邱新法等, 2018)。风速作为影响雾天能见度的重要因素之一，由于其空间异质性的对雾的形成和消散作用，会对雾天能见度产生显著影响。Knerr et al.(2021)通过对雾形成的因素进行分析，认为由于地形和局部气候条件差异会导致风速在空间分布上呈现显著的异质性特征，并通过调节局部温度、湿度分布和大气稳定性而对邻域能见度变化产生影响，进而增大对雾天能见度预测的难度。Castellani et al. (2017)采用数值模拟和实验数据对复杂地形的风速空间异质性进行分析，认为复杂地形会使风速的空间异质性特征表现得更为显著，从而加剧了雾天能见度预测的复杂性。Cuxart et al.(2012)通过风速对雾的影响研究表明风速空间异质性会显著影响大气稳定性和局部湿度条件，进而加快雾的形成与发展，从而降低了雾天能见度。Bergot et al.(2015)通过大涡模拟对雾的形成和演变研究，认为风速存在空间异质性，并对雾的形成时间、高度分布和能见度变化产生显著影响，特别是在复杂地形环境中，物体的阻挡和引导作用会进一步增强风速的空间异质性。上述研究表明风速空间异质性的存在并能对雾天能见度产生影响，但现有研究未对风速空间异质性的特征量化和提取进行进一步研究，使得在开展雾天能见度预测时无法量化风速空间异质性的影响，导致对雾天能见度预测的误差较大。

雾天能见度预测方法可分为数值模式、数理统计方法和机器学习方法。数值模式利用液态水含量、粒径和雾滴数浓度等变量构建物理方程，以反映雾形成和演变的动力学和热力学过程(王雪娇等, 2023; Tapiador et al., 2019)，但由于物理方程构建的复杂性、相关物理变量的高可变性，以及初始场设定的准确性等问题，增大了数值模式进行雾天能见度预测模型求解的复杂性、预测结果的不稳定性和准确性。数理统计方法通过构建能见度与气象因子（露点温度、相对湿度、风速等）之间的多元回归方程，进行雾天能见度预测(施炯炯等, 2017; 周开鹏等, 2020)，但由于该方法在确定模型结构和参数估计时需要前提假设（变量间的线性关系、数据的正态分布等）或依赖主观经验，无法准确反映能见度与气象因子之间的复杂非线性关系，进而影响了预测的准确性。机器学习方法是以任意小的误差近似任意连续函数，根据大量气象观测数据学习雾天能见度与气象因子的变化规律，有效解决了能见度与气象因子之间的复杂非线性映射问题，因而可提升预测模型的准确性和适用性(Castillo-Botón et al., 2022; 陈锦鹏等, 2023; Durán-Rosal et al., 2018)。长短期记忆神经网络(Long Short Term Memory Network, LSTM)作为一种常用的机器学习方法，因其独特的门结构能够有效解决能见度与气象因子之间的长期依赖关系问题，被广泛应用于雾天能见度预测研究中(Guerreiro et al., 2021; Kai-chao et al., 2020)，但由于 LSTM 在处理能见度长时间序列数据时，未能有效地关注到序列数据中的重要信息，尤其是在雾发生高峰时段，相关气象因子变化频繁，无法捕捉关键时刻气象因子的变化，势必会对雾天能见度预测的准确性造成影响(方楠等, 2022; 刘青豪等, 2022)。因此，如何对 LSTM 进行改进，以加强其对序列数据重要信息关注的能力，是应用该方法进行雾天能见度预测并提高预测模型准确性和稳定性的关键问题。

基于此，本文构建考虑风速空间异质性的 LSTM-AM 雾天能见度预测模型。基于变异函数理论，建立风速半变异函数模型，利用邻近点变异值加权目标点风速序列，融合邻近空间位置和风速属性相似信息，实现对风速空间异质性特征的提取；采用注意力机制（Attention Mechanism, AM）对 LSTM 进行改进，以加强模型关注不同时刻气象因子变化对雾天能见度影响的能力，提高模型对关键时刻气象因子变化的关注度，实现对风速空间异质性下雾天能见度的预测，并分别采用绝对系数、均方根误差和平均绝对误差指标对本文模型的准确性和稳定性进行评价。

## 2 数据与方法

### 2.1 数据来源及研究区域

为验证模型预测效果，本文采用美国国家海洋和大气管理局(National Oceanic and Atmospheric Administration, NOAA)采集的美国华盛顿州 34 个气象监测基站 2022 年 1 月 1 日至 2022 年 12 月 31 日雾天监测数据作为数据来源（<https://www.noaa.gov/>）。研究区域华盛顿州位于美国西北部，临近太平洋，地形以山地为主，受到潮湿的海洋气流的影响，山脉地形有助于气流上升，使得湿空气更容易冷却凝结成雾，雾天出现频率较高，如图 1 所示。监测数据包含露点温度、风速、相对湿度等雾天能见度预测常用变量(杨小兵等，2021；Guerreiro et al., 2021；Castillo-Botón et al., 2022；李军等，2020；陈婧等，2019；孟蕾等，2010；Fabbian et al., 2007)，这些变量较全面反映了雾天能见度变化的基本条件。由于原始数据存在不一致的时间间隔且间隔较短，为了解决时间分辨率的不一致性，采用插值法将时间分辨率调整至最小间隔为 4 分钟，生成连续且均匀的时间序列。为区分由于重污染等其他因素导致的低能见度场景，根据 Menut et al.(2014)的研究，利用相对湿度和风速对雾天能见度相关数据进行筛选，如式（1）所示：

$$X = \bar{X} \pm \sigma \quad (1)$$

式中， $X$ 为相对湿度和风速的条件阈值， $\bar{X}$ 为相对湿度或风速的平均值， $\sigma$ 为相对湿度和风速的标准差。在研究中将雾天能见度定义为，在满足式（1）雾发生条件下，水平方向能见距离小于 1 km 的场景。经验证，满足雾发生条件为相对湿度大于 73%和风速小于 9 m/s，可筛选出 95%有效雾天能见度数据。




图 1 基站地形及空间分布特征

Fig.1 Topographical and Spatial Distribution Characteristics of Stations

### 2.2 雾的总体分布描述

依据数据来源，以满足式（1）的雾事件趋势判断的时间为起始点，当天气状态为雾状态时记为一次雾事件，对各个基站进行统计分析，得到各基站雾事件频数分布，如图 2 所示。西部基站 3、19、22、23、27、28、29、30，分别发生 323、264、224、217、222、155、201、160 次雾事件，相比之下，位于东部地区的基站 5、6、7、8、9、10、11、12、13 的雾事件频数分别为 19、35、13、37、52、42、27、

43、53。可见各基站的年雾频数具有较大差异，这是由于西部基站受太平洋的影响，为雾的形成提供充沛的水汽条件，从而导致西部基站的雾频数显著多于东部基站。




图 2 各基站雾事件频数分布图

Fig.2 Fog Event Frequency Distribution Map of Each Station

为反映雾天持续时长及其日变化特征，以连续记录为雾状态的时段计算雾的持续时长，对各个基站的雾的日均持续时长进行统计分析，如图 3 所示。由图 3 可见，23-次日 5 时的雾持续时间较长，尤其是 23 时开始的雾，平均可以持续 8 小时，由于地表温度降低，空气中的水汽容易凝结，有利于雾的形成和维持。随着太阳升起，温度逐渐升高，雾开始消散，其中，6 时开始的雾，平均持续时间为 3 小时，这与日出后温度上升、雾逐渐消散的自然现象相符；7-18 时的雾持续时间相对较短，由于气温的快速上升和风力的增加，加快雾的消散，持续时间平均为 2 小时。




图 3 雾的日均持续时长

Fig.3 Average Daily Duration of Fog Events

2.3 方法和模型

2.3.1 风速空间异质性特征提取

半变异函数可通过计算空间数据点之间的协方差，以反映数据随距离变化的相关性特征，并拟合特定模型来表征空间异质性，是分析变量空间异质性的重要工具(段平等，2015；魏凤英等，2002；万丽，2006)。为此，本文利用半变异函数量化预测目标点在不同空间滞后距离下的风速差异，得到空间滞后距离对应的平均风速差异，并对风速空间异质性与空间滞后距离的变化关系进行分析，如式（2）所示：

$$\gamma(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} [Z(x_i) - Z(x_i + h)]^2 \tag{2}$$

式中， $\gamma(h)$ 为风速半变异值； $h$ 为空间滞后步距； $N(h)$ 为在空间滞后距离  $h$  内样本点的对数； $Z(x_i)$ 表示在  $x$  位置的第  $i$  个风速值； $Z(x_i + h)$ 表示与空间位置  $x$  相距  $h$  处的第  $i$  个风速值。

式（2）得到的 $y(h)$ 仅表示风速本身的变异特征和空间分布特征，且常规考虑空间异质性方法一般采用距离进行定权(颜金彪等，2020)，由于风速的空间异质性不仅和距离相关，还受到风向的影响。风向的变化可能导致风速在不同方向上表现出不同的异质性。为了提取风速空间异质性量化特征，需通过融合空间位置信息、邻域风速和风向属性相似信息对风速空间异质性特征进行提取，如图4所示。




图4 风速空间异质性特征提取

Fig.4 Extraction of Spatial Heterogeneity Characteristics of Wind Speed

步骤如下：

（1）利用线性插值计算出其他站点在目标点时间的风速估计值，确保与目标点具有相同时刻的风速值，如式（3）所示。

$$X_{t,i} = X_{t_{i,1}} + \frac{(t - t_{i,1}) \cdot (X_{t_{i,2}} - X_{t_{i,1}})}{t_{i,2} - t_{i,1}} \quad (3)$$

式中， $X_{t,i}$ 为邻近点 $i$ 在目标点时间 $t$ 处的风速估计值； $t$ 为目标点时间； $X_{t_{i,1}}$ 、 $X_{t_{i,2}}$ 分别是邻近点 $i$ 在时间点 $t_{i,1}$ 、 $t_{i,2}$ 的风速观测值。

（2）利用半变异函数确定以目标点为中心的变程范围，筛选出在变程范围内的点，记为邻近点。其中，变程范围是指半变异函数建模确定的空间数据点之间保持显著空间相关性的最大距离。在该范围内，邻近点的风速变化对目标点具有显著的异质性影响，而超过该距离的对目标的空间异质性影响可忽略不计(陈昭等，2019)。

（3）计算邻近点风速对目标点影响的起止时间，并提取该时间范围内对应的站点观测风速时间序列作为对目标站点风速的空间异质性影响。

（4）为引入风向变化对风速空间异质性的影响，利用风向夹角作为权重影响因子。同时，为避免风向夹角突变引起的权重急剧变化，利用高斯函数计算每个邻近点相对于目标点的空间异质性权重，如式（4）所示，权重的变化随着风向夹角的增加而平滑的减小。

$$\omega_i = \gamma(h) e^{-\frac{(\theta_i - \mu)^2}{2\sigma^2}} \quad (4)$$

式中,  $\omega_i$  是邻近点  $i$  的权重,  $\theta_i$  表示与目标点风向的夹角,  $\mu$  为风向夹角的均值,  $\sigma$  为标准差, 控制权重随夹角变化的速率。

(5) 对邻近点的风速时间序列进行加权平均, 与目标点的风速序列融合为时空特征矩阵, 作为预测模型在目标点的样本源, 如式 (5) 所示。

$$X_t = \frac{\sum_{i=1}^n \omega_i X_{t,i}}{\sum_{i=1}^n \omega_i} \quad (5)$$

式中,  $X_t$  为考虑空间异质性的风速变量;  $X_{t,i}$  是邻近点  $i$  在时间  $t$  处的风速,  $n$  是变程范围内邻近点的总数。

可见, 利用风速半变异函数模型, 可对风速在不同空间位置的特征进行量化, 通过计算以目标点为中心的邻近点变异值, 并利用邻近点的风速、风向差异信息对目标点进行加权计算, 实现对风速空间异质性特征的有效提取。

### 2.3.2 LSTM 及改进

#### (1) LSTM

LSTM 作为一种处理时间序列的特殊循环神经网络, 其通过对输入时间序列进行编码和解码, 利用隐藏层参数在序列之间传递得到的历史信息, 并引入门结构来控制信息的流动, 从而能够有效捕捉雾天能见度与气象因子长期依赖关系。LSTM 结构包含遗忘门、输入门、记忆单元和输出门四个主要组成部分, 其中, 遗忘门控制记忆单元信息的遗忘或保留; 输入门控制输入信息的过程; 输出门控制最终的输出状态, 根据当前时刻的输入和上一时刻的隐藏状态, 选择性的输出当前时刻的状态, 从而实现信息的传递和筛选(马景奕等, 2021)。计算过程如下:

$$i_t = \varphi_i(W_i[X_t, h_{t-1}] + b_i) \quad (6)$$

$$f_t = \varphi_f(W_f[X_t, h_{t-1}] + b_f) \quad (7)$$

$$\tilde{c}_t = \tanh(W_c[X_t, h_{t-1}] + b_c) \quad (8)$$

$$c_t = \tilde{c}_t \cdot i_t + c_{t-1} \cdot f_t \quad (9)$$

$$o_t = \varphi_o(W_o[X_t, h_{t-1}] + b_o) \quad (10)$$

$$h_t = \tanh(c_t) \cdot o_t \quad (11)$$

式中,  $i_t$ 、 $f_t$ 、 $o_t$  分别为输入门、遗忘门和输出门,  $\varphi_i$ 、 $\varphi_f$ 、 $\varphi_o$  为 Sigmoid 函数,  $\tanh$  表示双曲正切函数,  $W_i$ 、 $W_f$ 、 $W_c$ 、 $W_o$  为可学习的权重矩阵,  $X_t$  表示当前时刻的输入,  $h_{t-1}$  表示上一时刻的输出,  $b_i$ 、 $b_f$ 、 $b_c$ 、 $b_o$  为偏置向量,  $\tilde{c}_t$  为新的候选值;  $c_{t-1}$  为上一时刻的记忆单元,  $h_t$  为最终输出状态。

从上述过程可以看出, LSTM 的信息传递依赖于神经元之间的连接, 其中每个神经元都需要对前一时刻的信息进行处理并生成新的信息。但 LSTM 在处理雾天能见度的长时间序列时, 该信息处理机制容易导致模型对关键时段的气象因子短期变化在信息传递过程中被削弱或丢失, 捕捉关键时刻气象因子变化的能力受限, 从而对雾天能见度预测结果的准确性和稳定性造成较大的影响。

#### (2) 改进 LSTM

AM 作为一种有效聚焦于关键信息的技术，能够根据当前输入和上下文信息自适应地调整输入序列中各个元素的权重，从而提高模型对关键信息的关注度，减少信息的丢失和模糊(王继东等，2022)。故本文利用 AM 对 LSTM 进行改进，以解决关键时刻气象因子变化信息的丢失和模糊问题和提升模型对关键信息关注度的能力。将 LSTM 输出门的每个时刻状态作为隐藏状态集合  $H(h_1, h_2, \dots, h_t)$ ，并将  $H$  作为 AM 的输入，计算出  $t'$  时刻隐藏状态对  $t$  时刻输出序列的重要程度  $e_{t'}$ ：

$$e_{t'} = \tanh(W_h[h_{t-1}, h] + b_h) \quad (12)$$

式中， $W_h$  为权重矩阵， $h_{t-1}$  表示上一时刻序列的隐藏状态， $h_{t'}$  表示  $t'$  时刻的隐藏状态， $b_h$  为偏置向量。

为得到  $t'$  时刻的重要程度占所有时刻重要程度的比重  $\alpha_{t'}$ ，使得所有时间点的重要性之和为 1，对  $e_{t'}$  进行归一化处理：

$$\alpha_{t'} = \frac{\exp(e_{t'})}{\sum_{t'=1}^T \exp(e_{t'})} \quad (13)$$

为确保模型在处理序列数据时，能够合理地分配关注度到每个时间点的信息上，并且使得这些关注度在整个序列中保持一致性和平衡性，利用归一化后的重要性权重和对应的隐藏状态来计算总权重因子  $r_t$ ：

$$r_t = \sum_{t'=1}^T h_{t'} \alpha_{t'} \quad (14)$$

对  $r_t$ 、上一时间步的目标序列输出及隐藏状态输出进行解码，求得  $t$  时刻的输出值  $y_t$ ：

$$y_t = LSTM(r_t, a_{t-1}, c_{t-1}) \quad (15)$$

可见，通过采用 AM 对 LSTM 进行改进，利用 AM 识别并赋予能见度时间序列中关键时刻较高的权重，可有效捕捉和利用关键时刻气象因子的变化信息，克服了 LSTM 在处理能见度长时间序列信息的丢失和模糊的不足，可提高对雾天能见度预测的准确性。

### 2.3.3 考虑风速空间异质性的 LSTM-AM 雾天能见度预测模型

基于上述分析，本文构建了考虑风速空间异质性的 LSTM-AM 雾天能见度预测模型，如图 5 所示。




图 5 考虑风速空间异质性的 LSTM-AM 雾天能见度预测模型

Fig.5 LSTM-AM Fog Visibility Prediction Model Considering Spatial Heterogeneity of wind speed

由图 5 可见，利用半变异函数对风速不同空间位置的变化特征进行量化，融合邻近点空间分布及风速差异信息，实现对风速空间异质性特征的提取；将风速空间异质性特征、相对湿度、温度等气象因子作为模型输入变量，以反映雾天能见度变化的基本条件；利用 AM 对 LSTM 改进，赋予雾天能见度时间序列中关键时刻较高的权重，以增强模型对关键时刻气象因子变化的关注度；根据损失函数的梯度信息对模型的参数进行迭代更新，通过优化器减小学习率以优化学习速率和模型的收敛速度，构建了考虑风速空间异质性的雾天能见度预测模型，可实现对雾天能见度的预测。

### 3 结果分析

#### 3.1 评价指标

采用决定系数 ( $R^2$ )、均方根误差 (RMSE) 和平均绝对误差 (MAE) 对本文模型的预测效果进行评价。

(1) 决定系数 ( $R^2$ )。  $R^2$  是衡量模型解释力的统计量，反映模型预测值与实际观测值之间的差异比例，  $R^2$  值越大表示模型捕捉到雾天能见度变化趋势的能力越好；

(2) 均方根误差 (RMSE)。 RMSE 作为衡量模型预测准确性的常用指标，反映模型预测值与实际观测值之间差异的标准差，值越小表示模型预测越准确；

(3) 平均绝对误差 (MAE)。 MAE 是衡量预测精度的指标，与 RMSE 相比， MAE 对异常值的敏感度较低，有助于评估模型在不同情况下的稳定性和可靠性。如式 (16) - (18) 所示：

$$R^2 = 1 - \frac{\sum_{t=1}^N (x_t - x'_t)^2}{\sum_{t=1}^N (x_t - \bar{x})^2} \quad (16)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^N (x_t - x'_t)^2} \quad (17)$$

$$MAE = \frac{1}{N} \sum_{t=1}^N |x_t - x'_t| \quad (18)$$

式中， $x_t$ 为 $t$ 时刻观测值， $\bar{x}$ 为观测样本的平均值， $x'_t$ 为 $t$ 时刻预测值， $N$ 为观测样本时间序列长度。

### 3.2 模型训练参数

为确保预测的可靠性和模型的泛化能力，将数据基于时间序列顺序划分为训练集和测试集进行实验，其中训练集的比例为 70%，用于对模型进行训练，以学习数据中的模式和趋势；其余 30%为测试集，用于对模型进行测试，评估模型的性能。

基于神经网络的模型训练依赖调整内部神经元间的连接权重及偏置，由于 RMSE 对较大的预测误差给予了更大的惩罚，有助于模型在训练过程中更加关注于减少极端误差的发生，特别是在能见度预测中，这种极端误差可能对应于能见度极低的雾天条件，因此模型训练过程采用 RMSE 作为损失函数。在训练模型时，对样本序列长度、隐藏层神经元数等关键参数采用网格搜索方法，确定最优参数组合。其中，针对模型的输入，为适应不同的输入数据起始点，以 1 小时为最小滑动窗口的起始点，并逐步扩大至 2 小时、3 小时等形成不同大小的滑动窗口，当完成对未来 1 小时的能见度预测时，滑动窗口向下滑动，进行后续时间点的预测。

### 3.3 风速空间异质性特征提取

为捕捉风速在不同空间位置的差异，利用 GS+软件建立风速半变异函数模型，由于离散、有限的监测站点获取的样本数量有限，使用样本均值计算半变异函数，根据式（2）计算出风速半变异函数如式（19）所示。

$$\gamma_h = \begin{cases} 0.01, & h = 0 \\ 0.01 + 2.061 \left( \frac{2h}{33800} - \frac{h^3}{2 * 33800^3} \right), & 0 < h \leq 33.80 \\ 2.071, & h > 33.80 \end{cases} \quad (19)$$

由式（19）可知，模型变程为 33.80 km，表明在 33.80 km 范围内其他基站的风速对目标点能见度有影响，通过计算其他基站与目标点的距离筛选出范围内 7 个邻近点，距离分别为 31.73 km、9.08 km、26.09 km、26.95 km、28.02 km、4.06 km、15.83 km，进一步计算出其变异值分别为 0.1387、1.1107、1.3182、1.3287、1.3417、0.1049、0.1193，表明风速空间异质性在不同空间滞后距离下显著存在。根据式（2）-（5）可得到考虑空间异质性的风速，如图 6 所示：




图 6 风速与雾天能见度关系对比图

Fig.6 Wind Speed and Visibility Comparison Chart.

从图 6 可以看出，考虑空间异质性的风速与雾天能见度的相关性明显增强。其中，考虑空间异质性的风速与能见度的  $R^2$  为 0.8372，比原始风速拟合的  $R^2$  提高了 43.61%，表明其更能反映雾天能见度的变化规律。当雾天能见度小于 1 km 时，考虑空间异质性的风速处于 2~4 m/s 范围内，说明相比于静风环境，对于雾需要一定的风速维持，即微风更有利于雾的形成，从而降低能见度。可见，风速的空间异质性对雾天能见度预测具有重要影响，在进行雾天能见度预测时考虑风速空间异质性可有效提高雾天能见度预测的准确性。

### 3.4 预测结果分析

#### (1) 准确性分析

为分析风速空间异质性对雾天能见度预测准确性的影响，本文对比了考虑风速空间异质性与未考虑风速空间异质性的模型预测结果，如表 1 所示。在拟合优度方面，考虑风速空间异质性的预测模型比未考虑风速空间异质性的预测模型分别提高了 8.20%、10.86%；在预测误差方面，考虑风速空间异质性的预测模型在 RMSE 指标上降低了 7.8%、16.88%，MAE 指标降低了 36.88%、53.15%，表明考虑风速空间异质性可有效提高雾天能见度预测的准确性。

为评估本文模型预测的准确性，将本文模型与 LSTM 模型的预测结果进行对比，与 LSTM 模型相比，在拟合优度上，本文模型提高了 18.65%；在预测误差上，本文模型在 RMSE、MAE 指标上分别降低了 16.89%、53.15%，表明本文模型对雾天能见度与气象因子复杂关系的学习和规律捕捉效果更佳，具有更高的准确性。

表 1 模型预测结果评价指标

Table1 Model Prediction Result Evaluation Metrics

| 类型         | LSTM 模型 |        |        | LSTM-AM 模型 |        |        |
|------------|---------|--------|--------|------------|--------|--------|
|            | $R^2$   | RMSE   | MAE    | $R^2$      | RMSE   | MAE    |
| 考虑风速空间异质性  | 0.8250  | 0.5419 | 0.0568 | 0.9295     | 0.3106 | 0.0245 |
| 未考虑风速空间异质性 | 0.7430  | 0.5880 | 0.0900 | 0.8209     | 0.3737 | 0.0523 |

#### (2) 稳定性分析

为验证模型预测的稳定性，将本文模型与 LSTM 逐小时预测结果进行对比，如图 7 所示。




图 7 逐小时模型评价指标对比图

Fig.7 Hourly Model Evaluation Metrics Comparison Chart

由图 7 可以看出, 本文模型的评价指标曲线波动幅度比 LSTM 模型较小。在拟合优度上, 两个模型的  $R^2$  均呈 U 型变化趋势, 由于 12:00-16:00 雾天的能见度变化较大, LSTM 模型难以学习快速变化的趋势, 拟合优度呈下降趋势, 其中, 在 13:00 达到最低点, LSTM 模型的  $R^2$  为 0.6040, 而本文模型的  $R^2$  为 0.7318, 提升了 12.78%。16:00-19:00 能见度变化较稳定, 拟合优度呈上升趋势, 且两个模型的拟合优度均保持在 0.87 左右。20:00-次日 11:00 能见度变化稳定在 0~2 km 范围内, 是雾天频发时段, 本文模型由于考虑了风速空间异质性及 AM 使得拟合优度保持在 0.8 以上, 相较 LSTM 模型提升了 10%~20%。

在逐小时预测误差上, 受到能见度日变化的影响, 两个模型在 RMSE、MAE 指标上均呈倒 U 型变化趋势。其中, 由于 12:00-16:00 能见度变化较大, 相较其他时间段, 两个模型的 RMSE、MAE 指标曲线均保持较高的水平, 但与 LSTM 模型相比, 本文模型在 RMSE、MAE 指标上分别降低了 17%~23%、7%~22%, 说明本文模型学习雾天能见度变化的能力较强, 具有较高的准确性。但模型在对 11:00-13:00 预测时,  $R^2$  呈下降趋势, RMSE、MAE 指标呈上升趋势, 各个指标与 LSTM 模型非常相近。从能见度值来看, 该时段的平均能见度值为 4 km, 由式 (17) - (18) 可知, RMSE、MAE 随能见度的增大而增大; 另外在该时段内风速较大, 使得风速的空间异质性特征对模型的预测贡献较小。可见, 该模型在雾天能见度小于 4 km 条件下预测效果较好, 当超过这一能见度时模型的适用性会降低。16:00-19:00 雾天能见度相对稳定的时段, 两个模型均能够准确地预测, RMSE、MAE 指标保持较为稳定的水平。20:00-次日 11:00 能见度变化不大, 但相关气象因子变化较快, 由于本文模型增加了风速空间异质性及 AM 对关键时刻气象因子的学习, 使得模型在 RMSE、MAE 指标上分别能稳定在 0.6 和 0.4 以内, 说明本文模型在训练时对关键时刻特征的抓取效果较强, 具有较强的稳定性。

综上所述, 本文模型在  $R^2$ 、RMSE、MAE 指标上相较 LSTM 模型均有显著改善, 且对逐小时雾天能见度预测保持较为稳定的精度, 表明本文预测模型具有较高的准确性与稳定性。

## 4 结论

本文构建了考虑风速空间异质性的 LSTM-AM 雾天能见度预测模型, 结论如下:

- (1) 利用半变异函数能够表征和分析变量空间异质性的特性, 采用半变异函数对风速在不同空

间位置的特征进行量化,通过计算以目标点为中心的邻近点变异值,并利用邻近点的风速、风向差异信息对目标点进行加权计算,实现对风速空间异质性特征的有效提取。

(2) 利用 AM 能加强对关键信息关注的优势对 LSTM 方法进行改进,将融合空间异质性的风速、相对湿度、露点温度等变量作为模型输入序列,并对不同时刻气象因子变化信息赋权处理,以有效捕捉和反映关键时刻气象因子变化对雾天能见度的影响,增强了模型对不同时刻气象因子变化对雾天能见度影响的能力,构建 LSTM-AM 雾天能见度预测模型,实现风速空间异质性下对雾天能见度进行预测。

(3) 实验结果表明, LSTM-AM 模型对风速空间异质性下雾天能见度预测具有较高的准确性和稳定性,与 LSTM 模型相比,  $R^2$  提升 10%-20%, RMSE 下降 25%-40%, MAE 下降 26.3%-39.1%, 为风速空间异质性下的雾天能见度预测研究提供了重要参考。

**致谢:** 感谢美国国家海洋和大气管理局 (<https://www.noaa.gov/>) 为本文研究所提供的数据支持;感谢参考文献及其作者为本文所提供的研究借鉴。

## 参考文献(References)

- 刘旗洋, 乔枫雪, 陈博, 等. 2022. 不同场景下的交通能见度估算模型的应用[J]. 大气科学学报, 45(02): 179-190. Liu Qiyang, Qiao Fengxue, Chen Bo, et al. 2022. Analysis of the application of traffic visibility estimation models in different scenarios[J]. Transactions of Atmospheric Sciences, 45(02):179-190. doi: 10.13878/j.cnki.dqkxxb.20210731001.
- 邱新法, 叶栋水, 曾燕, 等. 2018. 基于视频的雾天能见度实时监测方法研究[J]. 安全与环境学报, 18(04):1413-1418. Qiu Xinfu, Ye Dongshui, Zeng Yan, et al. 2018. On the real-time monitoring method for the fog-cloud visibility based on the video frequency[J]. Journal of Safety and Environment, 18(04):1413-1418. doi: 10.13637/j.issn.1009-6094.2018.04.031.
- Isabel Knerr, Katja Trachte, Sebastian Egli, et al. 2021. Fog - low stratus (FLS) regimes on Corsica with wind and PBLH as key drivers[J]. Atmospheric Research, 261:105731. doi:10.1016/j.atmosres.2021.105731.
- Castellani F, Astolfi D, Mana M, et al. 2017. Investigation of terrain and wake effects on the performance of wind farms in complex terrain using numerical and experimental data[J]. Wind Energy, 20(7): 1277-1289. doi:10.1002/we.2094.
- J. Cuxart, M. A. Jiménez. 2012. Deep Radiation Fog in a Wide Closed Valley: Study by Numerical Modeling and Remote Sensing[J]. Pure and Applied Geophysics, 169(5-6):1-16. doi:10.1007/s00024-011-0365-4.
- Bergot T, Escobar J, Masson V. 2015. Effect of small-scale surface heterogeneities and buildings on radiation fog: Large-eddy simulation study at Paris-Charles de Gaulle airport[J]. Quarterly Journal of the Royal Meteorological Society, 141(686):285-298. doi:10.1002/qj.2358.
- 王雪娇, 杨旭, 孙玫玲, 等. 2023. 天津地区雾霾低能见度短临预报预警方法研究[J]. 环境科学学报, 43(04):93-101. Wang Xuejiao, Yang Xu, Sun Meiling, et al. 2023. Research on method of short-impending prediction and early warning for foghaze in Tianjin[J]. Acta Scientiae Circumstantiae, 43(04):93-101. doi: 10.13671/j.hjkxxb.2022.0309.
- Tapiador F J, Sanchez J L. 2019. Garcia-Ortega E. Empirical values and assumptions in the microphysics of numerical models[J]. Atmospheric research, 215:214-238. doi:10.1016/j.atmosres.2018.09.010.
- 施炯炯, 张庆国, 张浩, 等. 2017. 合肥市大气能见度变化特征及其影响因素[J]. 应用生态学报, 28(02):485-492. Shi Minmin, Zhang Qingguo, Zhang Hao, et al. 2017. Characteristics of atmospheric visibility change and its influence factors in Hefei City, Anhui, China[J]. Chinese Journal of Applied Ecology, 28(02):485-492. doi:10.13287/j.1001-9332.201702.029.
- 周开鹏, 黄萌, 樊旭, 等. 2020. 基于逐步回归和神经网络的北京市能见度预报对比[J]. 兰州大学学报(自然科学版), 56(04):522-526. Zhou Kaipeng, Huang Meng, Fan Xu, et al. 2020. Visibility forecast based on the neural network and multiple stepwise regression in Beijing[J]. Journal of Lanzhou University(Natural Sciences), 56(04):522-526. doi:10.13885/j.issn.0455-2059.2020.04.013.
- C. Castillo-Botón, D. Casillas-Pérez, Casanova-Mateo C, et al. 2022. Machine learning regression and classification methods for fog events prediction[J]. Atmospheric Research, 272:106157. doi:10.1016/j.atmosres.2022.106157.
- 陈锦鹏, 林辉, 吴雪菲, 等. 2023. 基于集成学习的沿海低能见度天气分类预报方法[J]. 热带气象学报, 2023, 39(05):680-688. Chen Jinpeng, Lin Hui, Wu Xuefei, et al. CLASSIFICATION FORECAST METHOD OF COSTAL LOW VISIBILITY WEATHER BASED ON ENSEMBLE LEARNING[J]. Journal of Tropical Meteorology, 39(05):680-688. doi:10.16032/j.issn.1004-4965.2023.059.

- Durán-Rosal A.M, Fernández J.C, Casanova-Mateo C, et al. 2018. Efficient Fog Prediction with Multi-objective Evolutionary Neural Networks[J]. Applied Soft Computing, 70:347-358. doi:10.1016/j.asoc.2018.05.035.
- Guerreiro, P.M.P.; Cruz, G. 2021. Diagnosis and Assessment of Pre-Fog in the Mainland Portuguese International Airports: Statistical and Neural Network Models Comparison[C]. Environmental Sciences Proceedings. doi:10.3390/ecas2021-10697.
- Kai-chao Miao, Ting-ting Han, Ye-qing Yao, et al. 2020. Application of LSTM for short term fog forecasting based on meteorological elements [J]. Neurocomputing, 408:285-291. doi:10.1016/j.neucom.2019.12.129.
- 方楠, 谢国权, 阮小建, 等. 2022. 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, 38(05):34-41. Fang Nan, Xie Guoquan, Ruan Xiaojian, et al. 2022. Application of long short-term memory neural network (LSTM) model in low visibility forecast[J]. Journal of Meteorology and Environment, 38(05):34-41. doi:10.3969/j.issn.1673-503X.2022.05.004.
- 刘青豪, 刘慧敏, 张永红, 等. 2022. 顾及空间异质性的大范围地面沉降时空预测[J]. 遥感学报, 26(07):1315-1325. Liu Qinghao, Liu Huimin, Zhang Yonghong, et al. 2022. A spatio-temporal prediction method of large-scale ground subsidence considering spatial heterogeneity[J]. National Remote Sensing Bulletin, 26(07):1315-1325. doi:10.11834/jrs.20211445.
- 杨小兵, 杨再均, 韩晖. 2021. 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, 38(06):120-128. Yang Xiaobing, Yang Zaijun, Han Hui. 2021. Study on Short-term Prediction of Dense Fog on Expressway Based on Important indicator Variables and Characteristics[J]. Journal of Highway and Transportation Research and Development, 38(06):120-128. doi:10.3969/j.issn.1002-0268.2021.06.016.
- 李军, 王京丽, 屈坤. 2020. 相对湿度和 PM<sub>2.5</sub> 浓度对乌鲁木齐市冬季能见度的影响[J]. 中国环境科学, 2020, 40(08):3322-3331. Li Jun, Wang Jingli, Qu Kun. 2020. Impacts of relative humidity and PM<sub>2.5</sub> concentration on atmospheric visibility during winter in Urumqi Urban Area[J]. China Environmental Science, 40(08):3322-3331. doi:10.3969/j.issn.1000-6923.2020.08.009.
- 陈婧, 马志强, 胡天洁, 等. 2019. 华北背景地区大气能见度变化特征及影响因素分析[J]. 气候与环境研究, 24 (2): 277-288. Chen Jing, Ma Zhiqiang, Hu Tianjie, et al. 2019. Variation characteristics of atmospheric visibility and its influence factors in the background area of North China [J]. Climatic and Environmental Research (in Chinese), 24 (2): 277-288. doi:10.3878/j.issn.1006-9585.2018.18085.
- 孟蕾, 周奇越, 牛生杰, 等. 2010. 降水对雾中能能见度参数化的影响[J]. 大气科学学报, 33(06):731-737. Meng Lei, Zhou Qiyue, Niu Shengjie, et al. 2010. Effect of Rainfall on Parameterization of Fog Visibility[J]. Transactions of Atmospheric Sciences, 33(06):731-737. doi:10.3969/j.issn.1674-7097.2010.06.012.
- Fabbian D, de Dear R, Lelleyett S. 2007. Application of Artificial Neural Network Forecasts to Predict Fog at Canberra International Airport[J]. Weather& Forecasting, 22(2):372-381. doi:10.1175/WAF980.1.
- Menut L, Mailler S, Dupont J C, et al. 2014. Predictability of the Meteorological Conditions Favourable to Radiative Fog Formation During the 2011 ParisFog Campaign[J]. Boundary-Layer Meteorology, 150(2):277-297. doi:10.1007/s10546-013-9875-1.
- 段平, 盛业华, 张思阳, 等. 2015. 顾及异向性的局部径向基函数三维空间插值[J]. 武汉大学学报(信息科学版), 40(05):632-637. Duan Ping, Sheng Yehua, Zhang Siyang, et al. 2015. A 3D Local RBF Spatial Interpolation Considering Anisotropy[J]. Geomatics and Information Science of Wuhan University, 40(05):632-637. doi:10.13203/j.whugis20130422.
- 魏凤英, 曹鸿兴. 2002. 地统计学分析技术及其在气象中的适用性[J]. 气象, 28(12):3-5+23. Wei F Y, Cao H X. 2002. Geostatistics and Its Application to Meteorological Studies[J]. Meteorological Monthly, 28(12):3-5+23. doi:10.7519/j.issn.1000-0526.2002.12.001.
- 万丽. 2006. 基于变异函数的空间异质性定量分析[J]. 统计与决策, 04:26-27. Wang Li. 2006. Quantitative Analysis of Spatial Heterogeneity Based on the Variogram Function[J]. Statistics & Decision, 04:26-27. doi:10.3969/j.issn.1002-6487.2006.04.009.
- 颜金彪, 段晓旗, 郑文武, 等. 2020. 顾及空间异质性的自适应 IDW 插值算法[J]. 武汉大学学报(信息科学版), 45(01):97-104. Yan Jinbiao, Duan Xiaoqi, Zheng Wenwu, et al. 2020. An Adaptive IDW Algorithm Involving Spatial Heterogeneity[J]. Geomatics and Information Science of Wuhan University, 45(01):97-104. doi:10.13203/j.whugis20180213.
- 陈昭, 罗小波, 高阳华, 等. 2019. 基于半变异函数的重庆市地表温度空间异质性建模及多尺度特征分析[J]. 地球信息科学学报, 21(07):1051-1060. Chen Shao, Luo Xiaobo, Gao Yanghua, et al. 2019. Modeling and Multi-Scale Analysis of the Spatial Heterogeneity of Land Surface Temperature in chongqing based on Semi-Variogram[J]. Journal of Geo-information Science, 21(07):1051-1060. doi:10.12082/dqxxkx.2019.180611.
- 马景奕, 刘维成, 闫文君. 2021. 基于深度学习的气象要素预测方法[J]. 热带气象学报, 37(02):186-193. Ma Jingyi, Liu Weicheng, Yan Wenjun. 2021. METEOROLOGICAL ELEMENTS FORECASTING METHOD BASED ON DEEPLARNING[J]. Journal of Tropical Meteorology, 37(02):186-193. doi:10.16032/j.issn.1004-4965.2021.018.
- 王继东, 杜冲. 2022. 基于 Attention-BiLSTM 神经网络和气象数据修正的短期负荷预测模型[J]. 电力自动化设备, 42(04):172-177+224. Wang Jidong, Du Chong. 2022. Short-term load prediction model based on Attention-BiLSTM neural network and meteorological data correction[J]. Electric Power Automation Equipment, 42(04):172-177+224. doi:10.16081/j.epae.202112017.