

控制与决策

Control and Decision

基于多尺度3D-CNN-CBAM的空气质量指数时空预测

刘金培, 罗瑞, 陈华友, 周礼刚

引用本文:

刘金培, 罗瑞, 陈华友, 等. 基于多尺度3D-CNN-CBAM的空气质量指数时空预测[J]. *控制与决策*, 2025, 40(2): 404-412.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2024.0105>

您可能感兴趣的其他文章

Articles you may be interested in

[基于FWADE-ELM的短时交通流预测方法](#)

Short-term traffic flow forecasting based on hybrid FWADE-ELM
控制与决策. 2021, 36(4): 925-932 <https://doi.org/10.13195/j.kzyjc.2019.1103>

[基于FWADE-ELM的短时交通流预测方法](#)

Short-term traffic flow forecasting based on hybrid FWADE-ELM
控制与决策. 2021, 36(4): 925-932 <https://doi.org/10.13195/j.kzyjc.2019.1103>

[一种基于深度学习的时间序列预测方法](#)

A time series prediction method based on deep learning
控制与决策. 2021, 36(3): 645-652 <https://doi.org/10.13195/j.kzyjc.2019.0809>

[基于生成对抗网络的大规模路网交通流预测算法](#)

Traffic flow forecasting algorithm for large-scale road network based on GAN
控制与决策. 2021, 36(12): 2937-2945 <https://doi.org/10.13195/j.kzyjc.2020.0333>

[基于卷积长短期记忆神经网络的城市轨道交通短时客流预测](#)

Metro short-term traffic flow prediction with ConvLSTM
控制与决策. 2021, 36(11): 2760-2770 <https://doi.org/10.13195/j.kzyjc.2020.0501>

基于多尺度3D-CNN-CBAM的空气质量指数时空预测

刘金培^{1†}, 罗 瑞², 陈华友², 周礼刚³

(1. 安徽大学 商学院, 合肥 230601; 2. 安徽大学 大数据与统计学院, 合肥 230601;
3. 安徽大学 数学科学学院, 合肥 230601)

摘要: 精确地把握空气质量指数(AQI)的实时动态演变规律对大气污染防治和城市公共卫生治理至关重要. 因此,通过构建三维空间张量,将AQI特征信息由时间维度扩展至时空维度,并提出一种基于多尺度三维卷积注意力机制的时空预测网络模型,以提高AQI预测精度. 预测方法首先对相关影响因素数据进行有效筛选. 其次,将AQI数据及其影响因素分解为不同模态下的子序列. 进而,基于时间、空间地理位置和影响因素3个维度,构建三维空间张量,以反映AQI数据的时空特征演变. 然后,设计三维卷积注意力机制网络模型对子序列进行预测,以有效提取AQI与其影响因素之间的关键时空关联性特征. 通过学习局部AQI序列特征的重要程度,该模型能够对空间时域信息赋予不同权重,以增强关键信息的影响力. 将所提出的方法应用于3大城市群2019年~2024年的日度AQI预测,结果表明,该方法适用于具有时空属性的AQI预测,与现有方法相比具有更高的预测精度和适用性.

关键词: 时空预测; 空气质量指数; 卷积神经网络; 注意力机制; 三维空间张量; 多元经验模态分解

中图分类号: Q212

文献标志码: A

DOI: 10.13195/j.kzyj.2024.0105

引用格式: 刘金培, 罗瑞, 陈华友, 等. 基于多尺度3D-CNN-CBAM的空气质量指数时空预测[J]. 控制与决策, 2025, 40(2): 404-412.

Spatio-temporal forecasting of air quality index based on multi-scale 3D-CNN-CBAM

LIU Jin-pei^{1†}, LUO Rui², CHEN Hua-you², ZHOU Li-gang³

(1. College of Business, Anhui University, Hefei 230601, China; 2. College of Big Data and Statistics, Anhui University, Hefei 230601, China; 3. College of Mathematical Sciences, Anhui University, Hefei 230601, China)

Abstract: The accurate understanding of the real-time dynamic evolution patterns of the air quality index (AQI) is crucial for air pollution control and urban public health governance. Therefore, we extend the AQI feature information from the temporal dimension to the spatio-temporal dimension by constructing a three-dimensional space tensor. Furthermore, a spatio-temporal forecasting network model based on the multi-scale three-dimensional-convolutional neural networks-convolutional block attention mechanism (3D-CNN-CBAM) is proposed to improve the AQI prediction accuracy. First, the effective screening is performed on the influencing factors data. Second, the AQI and its influencing factors are decomposed into subsequences with different modes. Then, based on the three aspects of time, spatial geographic location, and influencing factors, a three-dimensional spatial tensor is constructed to reflect the spatio-temporal characteristic evolution of AQI data. Third, a 3D-CNN-CBAM network model is designed to predict the subsequences, which can effectively extract the crucial spatio-temporal correlational features between the AQI and its influencing factors. By learning the importance of local AQI sequence features, the model can assign different weights to spatio-temporal information, thereby enhancing the influence of critical information and reducing the interference of redundant information. The proposed method is applied to the daily AQI prediction in the three major urban agglomerations from 2019 to 2024. The results show that the proposed method is suitable for predicting the AQI with spatio-temporal attributes and exhibits higher forecasting accuracy and applicability compared to existing methods.

Keywords: spatio-temporal forecasting; air quality index; convolutional neural network; attention mechanism; three-dimensional space tensor; multivariate empirical mode decomposition

收稿日期: 2024-01-23; 录用日期: 2024-06-02.

基金项目: 国家自然科学基金项目(72071001, 72371001, 72171002, 72471001, 72271002); 安徽省高校优秀青年人才重点项目(gxyqZD2022001); 安徽省自然科学基金项目(2408085Y035); 安徽省高校杰出青年基金项目(2023AH020009); 安徽省高校优秀青年基金项目(2023AH030006).

[†]通讯作者. E-mail: liujinpei2012@163.com.

0 引言

随着中国工业化和城市化的快速发展,大气污染问题日益突出,严重影响了公众的正常生活^[1],同时也阻碍了我国的绿色可持续发展^[2]. 在环境恶化的情况下,公众和政府越来越关注环境保护部门所发布的各地区未来空气质量指数(AQI)的动态变化. 作为一种衡量城市大气环境质量的重要指标,AQI能够统一对空气质量进行综合评价和定量描述. 若对未来AQI的变化趋势评估不准确,则政府和公众将采取过度或不足的防护措施,从而导致空气污染防治成本或健康问题增加. 因此,AQI的准确预测对于政府和公众具有重要意义^[3]. 对于政府而言,能够为制定科学合理的环境管理政策和空气质量等级预警制度提供重要依据. 基于公众的视角,有助于其及时了解空气质量状况,从而降低健康风险.

AQI预测方法主要分为3类:数值模拟方法、基于历史数据的预测方法和基于多元数据的混合模型. 数值模拟方法是在气象学原理的基础上,通过数学方程模拟空气污染物的扩散、转化以及消散的过程^[4]. 由于方程中参数的选取存在不确定性,导致预测结果也会存在一定的偏差. 基于历史数据的预测方法则通过统计回归或机器学习拟合空气污染物的变化趋势,主要包括差分自回归移动平均^[5]、多元线性回归^[6]和支持向量回归(SVR)^[7]等. 近年来,随着人工智能和深度学习理论的快速发展,门控循环单元(GRU)^[8]、时域卷积网络^[9]、嵌套长短期记忆模型^[10]、卷积神经网络(CNN)^[11]等均被应用于AQI预测. 然而,此类方法虽然能有效提取历史数据的相关特征,但未考虑气象和空气污染物等因素的实时影响,具有模型灵敏度较低的缺点,对高随机性的AQI数据,其拟合效果存在滞后性问题.

基于多元数据的混合模型考虑到AQI与其影响因素之间的因果关系,将影响因素融入预测模型中,提高了预测方法的灵敏度. Wang等^[3]提出了一种新的空气质量指数预测方法,将气象因素作为多变量相关性向量机模型的输入变量,对北京、天津、上海和重庆的AQI数据进行预测;方晓萍等^[12]将基于粒子群优化算法和万有引力算法的混合优化算法与长短期记忆模型相结合,并将空气污染物和气象因素作为辅助变量,对长江经济带城市未来7天的AQI进行预测;Xiao等^[13]将分解集成方法与人工神经网络相结合,建立了一种自适应的空气污染物浓度预测模型,以从数据预处理、影响因素分析和自适应预测3个方面提高预测性能;Samal等^[14]构建了一种基于深度

学习的预测模型,对空气污染物浓度值进行了有效预测,并揭示了浓度值与气象因素之间的相关性. 上述研究表明,基于多元数据的混合模型考虑了本地AQI相关因素的实时影响,能够在一定程度上刻画AQI数据的细节波动. 然而,AQI同时受到本地及其邻近地区相关因素的影响. 同时,气象和空气污染物等影响因素是典型的地理空间数据,具有空间异质性和空间依赖性^[15]. 因此,本文基于本地和邻近地区的AQI及其影响因素数据,构建三维空间张量,从而将目标城市的AQI特征信息由时间维度扩展至时空维度. 在现有预测模型中,3D-CNN不局限于时间序列和平面矩阵的影响,能够有效提取三维空间张量的数据特征. 然而,传统CNN通常利用固定权重的卷积核,难以有效提取关键的空间时域信息.

综上所述,现有AQI预测研究存在以下3方面的问题:1)在预测领域中,传统CNN模型在提取多尺度信息方面存在缺点,难以有效地学习复杂AQI序列中的不同尺度波动频率模式特征;2)传统CNN模型通常利用固定权重的卷积核,对于具有不同重要性程度的影响因素变量信息,难以进行有效识别和提取,从而导致关键信息的损失;3)已有的预测研究大多仅考虑本地的AQI数据及其影响因素,没有考虑邻近地区的相关信息,忽视了AQI的空间关联属性. 因此,如何设计可变权重的3D-CNN模型,并提出多尺度时空预测方法以实现AQI的高精度预测,是一个亟待解决的关键科学问题.

针对以上问题,本文提出基于多尺度三维卷积注意力机制(3D-CNN-CBAM)网络的AQI时空预测方法. 首先,综合考虑本地与邻近地区的AQI及其影响因素,并基于两地之间的空间域权重,利用互信息(MI)对影响因素进行时空筛选. 其次,利用多元经验模态分解(MEMD)方法对原始序列进行分解,以将AQI序列中的多尺度波动频率模式分解为更具规律性的模态,并利用样本熵(SE)将子序列分别重构为高频序列、低频序列和趋势项. 然后,基于各地AQI及其影响因素的子序列,构建三维空间张量,以有效反映其时空关联性. 进而,通过引入卷积块注意力模块(CBAM)对3D-CNN进行改进,设计3D-CNN-CBAM网络,以有效提取三维空间张量的关键时空信息. CBAM通过训练学习,能够对前层网络所提取的信息特征进行赋权,从而增强有价值信息的影响力,降低冗余信息在网络中的作用. 最后,利用3D-CNN-CBAM模型对子序列进行预测,并集成得到最

终预测结果.

本研究的主要贡献如下: 1) 提出一种基于多尺度三维卷积注意力机制网络的AQI时空预测方法, 以提高AQI预测结果的精确度. 通过将多尺度分解融入深度学习模型, 该方法能够将AQI序列中不同频率的波动分量进行逐级分解, 得到多个具有特定含义的简单模态, 使深度学习模型在不同尺度上提取其内部影响因素信息与潜在规律. 2) 设计3D-CNN-CBAM模型, 以对AQI数据的非线性波动进行有效拟合. 通过学习局部AQI数据特征的重要程度, 该模型能够对空间时域信息赋予不同权重, 增强关键信息的影响力, 减少冗余信息干扰. 3) 基于时间、空间地理位置

和影响因素3个维度, 构建三维空间张量, 以有效反映AQI与其影响因素之间的时空关联性特征. 区别于传统一维时序和二维矩阵, 三维空间张量基于空间地理位置, 对具有时间戳的气象因素和空气污染物数据进行有序组合, 以揭示AQI数据的时空演变规律.

1 模型构建

AQI的变化受本地和邻近地区温度、湿度、风速、降雨量等气象因素以及其他空气污染物的影响, 具有时空关联性、非线性和非平稳性等特点. 首先, 本节提出基于多尺度三维卷积注意力机制网络的AQI时空预测方法框架, 如图1所示. 然后, 对预测方法框架中的具体模型和步骤流程进行详细说明.

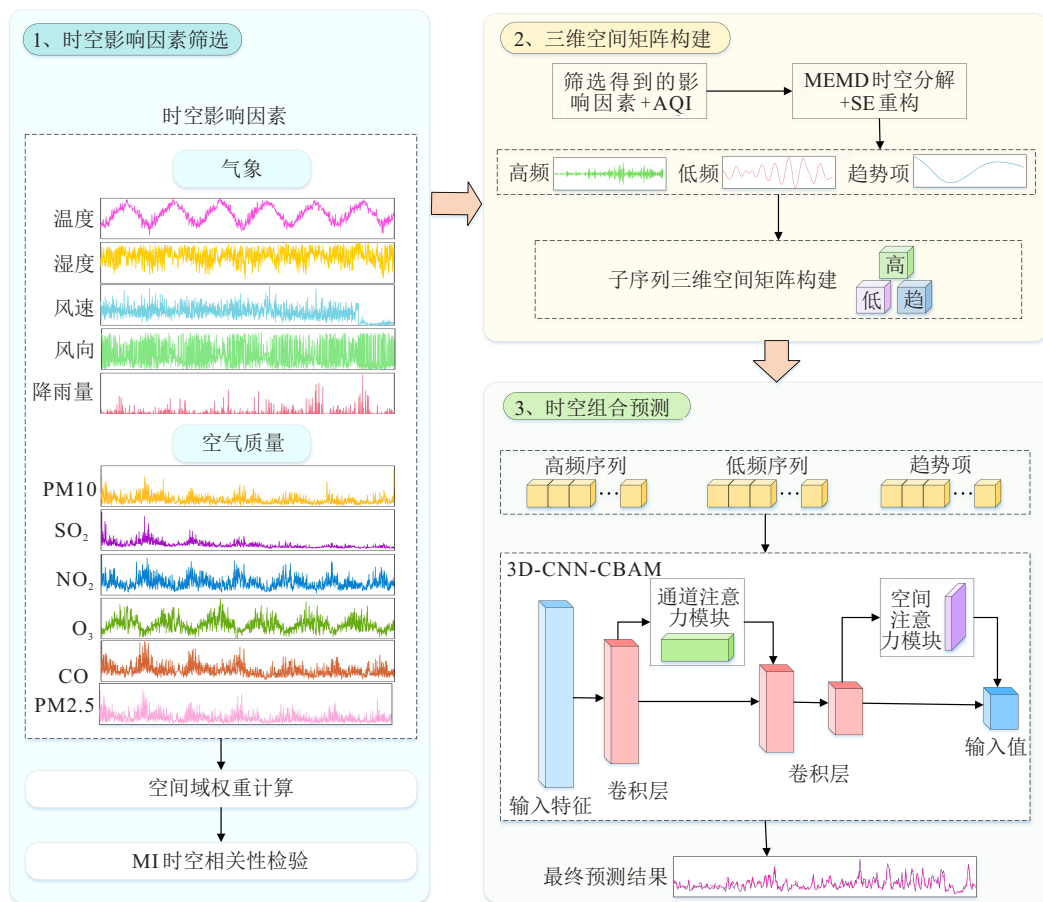


图1 AQI时空预测方法框架

AQI时空预测方法包括3个阶段. 第1阶段为时空影响因素筛选. 首先, 收集本地和邻近地区空气污染物和气象因素数据; 然后, 根据目标地区与邻近地区之间的地理距离, 计算空间域权重; 进而, 将相应城市的AQI及其影响因素数据与空间域权重相乘, 以反映地理分布对AQI变化的影响; 最后, 利用MI方法进行相关性检验, 剔除与其相关性低的因素, 以减少冗余信息的干扰. 第2阶段为三维空间张量构建. 首先, 利用MEMD方法对AQI数据以及筛选得到的影响因

素序列分别进行分解, 分解后的子序列呈现出更强的尺度波动规律性; 其次, 利用SE方法对若干子序列进行重构处理, 分别得到其对应的高频序列、低频序列和趋势项; 然后, 基于空间地理位置, 将各地的AQI、空气污染物和气象因子子序列进行组合, 进而构建三维空间张量数据, 以有效反映本地和邻近地区的AQI的时空演变; 第3阶段为时空组合预测. 基于三维空间张量数据的时空属性, 设计3D-CNN-CBAM网络模型对三维张量形式的高频序列、低频序列和趋势

项进行预测,以提取其时空特征;然后,将预测值进行集成处理,得到目标地AQI的最终预测结果;最后,为了验证预测方法的准确性和有效性,本文利用4种误差评价指标对预测结果进行对比分析.

1.1 时空影响因素筛选

基于空间地理位置的分布,根据各邻近地区与目标地区之间的空间距离差异,计算各地对应的空间域权重.考虑到邻近地区的气象因素和空气污染物对目标地区AQI的影响随着空间距离的增加而减弱,若第*i*个地区到目标地的距离为*d_i*,令 $w_i = \min_{k=1,2,\dots,n} \{d_k\} / d_i, i = 1, 2, \dots, n$,则得到空间域权重 $w = (w_1, w_2, \dots, w_n)^T$.进而,对空间相关影响因素进行筛选,以滤除无效信息.考虑到目标城市AQI与各影响因素之间存在线性和非线性关系,利用MI方

法进行相关性检验.

1.2 基于多尺度分解的三维空间张量构建

考虑到气象因素和空气污染物的高随机性和波动性等特点,利用MEMD和SE方法对各序列进行分解重构处理,以降低其复杂程度.另外,由于传统一维时序和二维矩阵的数据结构均难以有效体现变量之间的空间关联性,本文进一步将分解后的子序列依次构建为三维空间张量,以有效反映本地和邻近地区AQI及其影响因素的时空演变.具体构建过程如下:针对分解得到的AQI、空气污染物和气象因素数据所对应的*t*个时间节点的共*m*个高频子序列,将其组合为*t* × *m*的张量.然后,根据本地与邻近地区的空间地理距离,对本地和邻近地区共*n*个地点分别对应的*n*个*t* × *m*张量进行有序组合,得到高频数据对应的*n* × *t* × *m*三维空间张量数据,如图2所示.

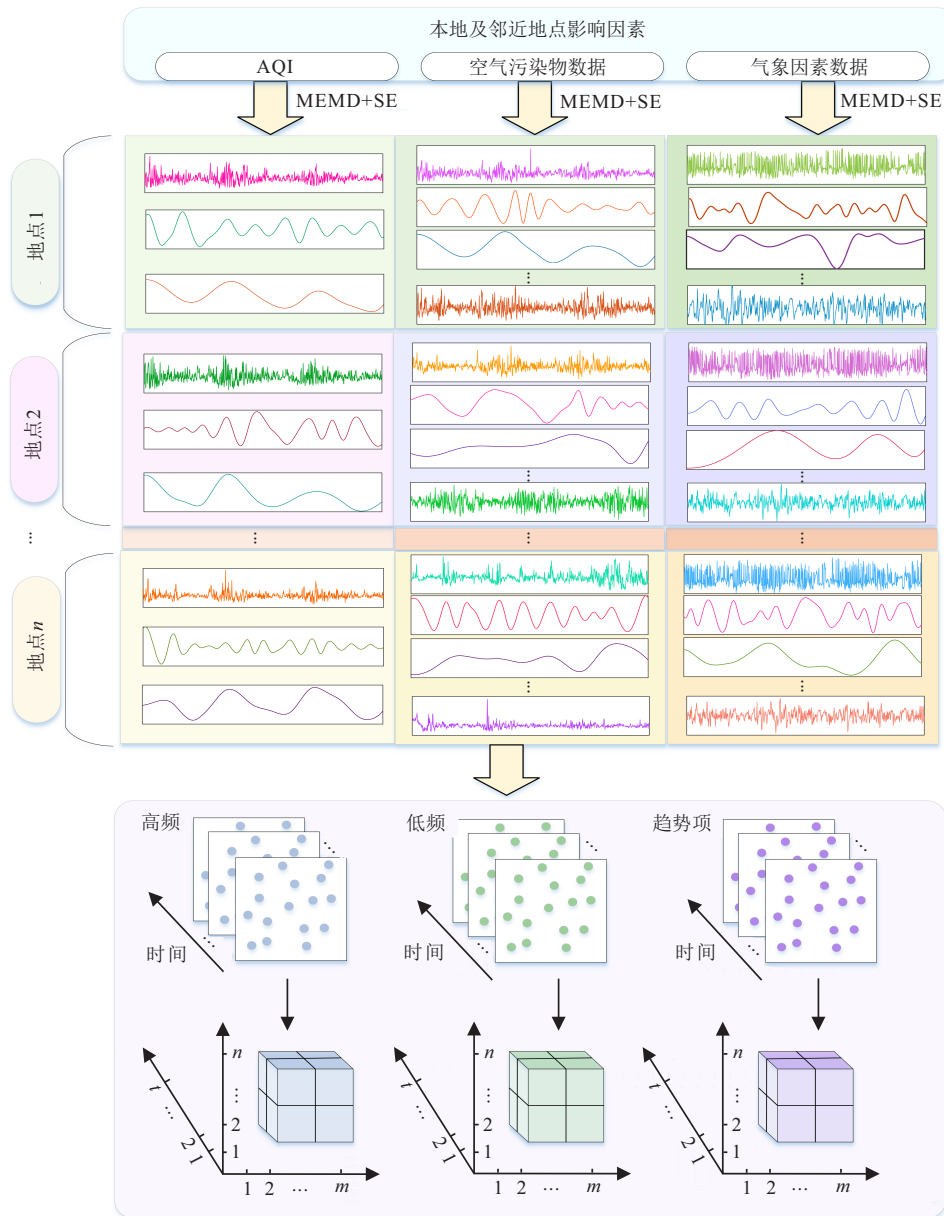


图2 三维空间张量的构建

同理,本文可以得到低频序列和趋势项分别对应的三维空间张量数据.在图2中: $1 \sim m$ 为影响因素; $1 \sim n$ 为地点; $1 \sim t$ 为时间.

1.3 三维卷积注意力机制网络

本文考虑了AQI的时空演化特征,将3D-CNN与CBAM相结合,设计3D-CNN-CBAM网络模型.该模型兼具3D-CNN在高维空间特征提取领域的优势,以及注意力机制对深度学习模型性能提升的特性.利用3D-CNN网络提取AQI与其影响因素在高维空间的联系,并学习这些输入特征在时序维度的关系.同时,嵌入CBAM注意力机制来衡量输入特征信息的重要程度,以提高模型的拟合能力.模型的整体结构如图3所示,其由输入层、3D-CNN层、CBAM层、全连接层与输出层5个层级叠加构成,各层级具体情况如下所述:

1)输入层.在输入层中,根据目标地与邻近地区的AQI数据、空气污染物以及气象因素变量,本文将构建的 $n \times t \times m$ 三维空间张量数据作为预测网络的初始输入特征,以充分考虑目标地AQI与其影响因素之间的时空关联性.

2)3D-CNN层.3D-CNN作为特征提取器,能够对三维空间张量数据进行卷积和池化操作,以挖掘AQI与其多元影响因素变量之间的深层时空数据特征.本文构建了包含3个卷积模块的3D-CNN层,卷积模块的主要作用是增强原始三维空间张量的数据特征.每个卷积模块通常设置多层卷积核,每个卷积核均与上一层的输出进行卷积计算,即通过滑动窗口不断进行相邻区域的扫描,由此得到映射后的特征图.3个卷积模块的卷积核尺寸均为 $3 \times 3 \times 3$,卷积滑

动步长均设为1,卷积填充方式为Same填充,激活函数为ReLU函数.

3)CBAM层.CBAM层结合了通道注意力机制和空间注意力机制两阶段模块.对于一阶段模块,从地点(通道)维度 n 依次计算相应的注意力权重三维张量 $n \times 1 \times 1$.对于二阶段模块,沿着影响因素(空间)维度 $t \times m$ 依次生成相应的注意力权重三维张量 $1 \times t \times m$.然后,将上述两个独立的注意力权重张量分别与经过卷积处理的三维空间张量相乘,以自适应地学习输入特征中需要关注的关键特征区域.通过两阶段的特征优化处理,网络模型能够有效地提取目的地AQI与其影响因素之间的关键时空关联性信息.

经过3D-CNN层和CBAM层处理,三维空间张量输入值的变化情况如下:第1次卷积运算后,三维空间张量转化成尺寸为 $k \times g_1 \times t \times m$ 的特征张量.进而,将特征张量传递至CBAM通道注意力机制模块,对邻近地点进行注意力权重赋值,并保持其原有的尺寸.然后,将赋权后的特征张量依次输入至第2个和第3个卷积模块,分别得到尺寸为 $k \times g_2 \times t \times m$ 和 $k \times g_3 \times t \times m$ 的特征张量,进一步将其传入CBAM空间注意力机制模块,对影响因素进行注意力赋权处理.其中, k 为卷积网络训练的批次大小, g_1, g_2, g_3 为各层卷积网络的输出通道数.

4)全连接层和输出层.在全连接层中,卷积模块与注意力机制模块所提取的高维特征被转换为一个全局特征向量.该特征向量包含全部输入三维空间张量的综合时空信息,能实现回归拟合效果的提升.然后,将全局特征向量作为输出层的输入值,对其进行非线性回归变换,从而得到目的地AQI的输出值.

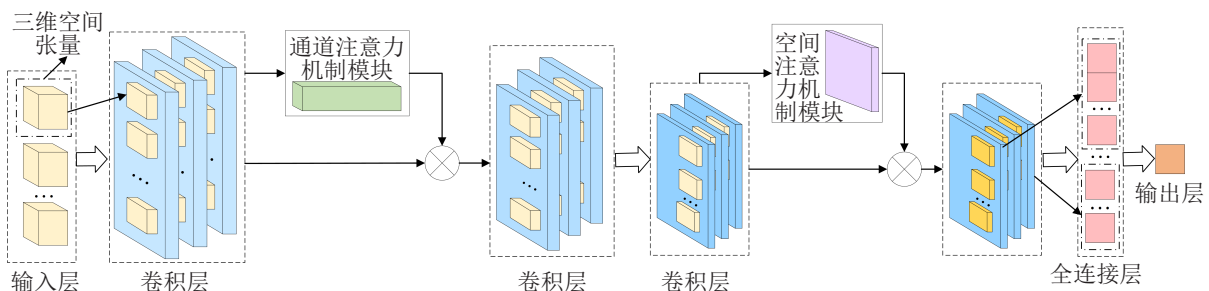


图3 3D-CNN-CBAM网络模型

2 实证分析

2.1 数据预处理

长江三角洲城市群、京津冀城市群和珠江三角洲城市群是中国经济的重要引擎.因此,本文选择三大城市群作为研究区域,以期为其可持续发展政策的制定提供依据.本文收集了2019年1月1日~2023年8月21日期间长三角区域各城市的日度AQI、空

气污染物和气象因素数据,共计503118个数据,以作为长江三角洲城市群数据集.同时,分别收集了2019年1月1日~2024年3月31日期间京津冀区域和珠三角区域各城市的日度AQI、空气污染物和气象因素数据,共计273559个数据和189387个数据,以作为京津冀城市群数据集和珠江三角洲城市群数据集.其中,数据集的前80%作为训练集,后20%作为测试

集^[9]. AQI和空气污染物数据来源于中国环境监测总站和各省市区环境监测中心,气象因素数据则来源于国家气象科学数据。

根据上海市、北京市和广州市分别与其他26个、12个和8个城市之间的空间地理距离,计算得到各城市的空间域权重.进而,将各城市的影响因素数据分别与其对应的空间域权重相乘,以考虑地理分布对AQI数据波动的影响.然后,利用MI进行相关性检验,以检验AQI与各影响因素之间的线性和非线性相关性.本文选取0.5作为临界值^[16],即保留信息熵值大于0.5的影响因素。


2.2 多尺度时空预测过程

在数据预处理的基础上,本文利用MEMD方法分别对上海市、北京市和广州市AQI以及筛选得到的影响因素进行分解,以得到其对应的子序列.进而,利用SE方法计算各子序列的样本熵值.其中,阈值 $r = 0.2$ ^[17].依据样本熵值,将各子序列分别重构为高频率列、低频序列和趋势项。


本文构建三维空间张量,利用3D-CNN-CBAM模型,以提取其时空特征.关于三维空间张量构建部分:首先,将2.1节中筛选得到的9种上海市AQI影响因素作为相关性属性.然后,本文基于前3个时间段的数据信息,对当期AQI数据进行预测,由此得到以3为周期的时间属性^[18].进而,将其组合为 3×9 维张量.最后,本文主要考虑长江三角洲城市群中27个主要城市的影响因素对上海市AQI数据的空间影响.因此,根据各城市与上海市的空间地理距离,构建得到 $3 \times 9 \times 27$ 三维空间张量,以考虑其空间属性.同理,可以得到京津冀城市群数据集的三维空间张量和珠江三角洲城市群数据集的三维空间张量。

本文利用3D-CNN-CBAM模型对三维空间张量形式的上海市、北京市和广州市AQI高频率列、低频序列和趋势项进行预测,以获取其时空尺度特征.其中,参数设置为3次卷积操作^[19],卷积核的大小均为 $3 \times 3 \times 3$,第1层卷积层中包含16个卷积核,其余两层卷积层均包含32个卷积核,迭代次数设置为150.最后,将各子序列的预测值进行集成处理,得到上海市、北京市和广州市AQI的最终预测结果,如图4所示。


在图4中:折线图展示了实际值与预测值之间的一致性水平.由图4可知,对于上海市、北京市和广州市AQI,其预测值与实际值高度拟合,表明本文方法能够有效地提取AQI数据的复杂时空特征,从而准确地刻画AQI数据的实际波动信息.因此,本文方法具有较高的预测精度,适用于AQI时空预测.基于本文



(a) 上海市AQI预测效果对比



(b) 北京市AQI预测效果对比



(c) 广州市AQI预测效果对比

图4 预测效果对比

方法的AQI预测结果,一方面有助于空气质量预警系统发布更精准的预警信息,从而促进公众及时采取防护措施,以降低健康风险;另一方面,AQI预测结果能够为环境管理和政策制定提供数据支持,以促进区域经济的绿色可持续发展。

2.3 预测效果对比分析

本文利用4种误差评价指标,即平均绝对误差(MAE)、平均相对方差(AVR)、均方根误差(RMSE)和加权绝对百分比误差(WAPE)作为实验结果的评价标准,对5组实验进行对比分析,以验证本文所提出预测方法的有效性.3组数据集的对比结果如表1所示。

1) 基准模型对比.在本文方法的基础上,利用8种基准模型分别对上海市AQI、北京市AQI和广州市AQI进行预测,以检验3D-CNN-CBAM模型的预测性能.基准模型分别为:CNN模型、GRU模型、极端梯度提升(XGboost)模型、无核的二次曲面支持向量回归(QSSVR)模型、SVR模型、长短期记忆(LSTM)模型、三次指数平滑法(Holt)以及广义自回归条件异方差(Garch)模型.对比结果如表1中1~5、12~19以及25~32所示,可知MI-MEMD-3D-CNN-CBAM方法在4种误差评价指标上均表现出最优的预测精度,说明3D-CNN-CBAM模型能够有效提取AQI序列的复杂时空数据特征.另外,在8种不同的AQI序列预测对比方法中,相较于其他6种基于机器学习方

表1 预测方法误差评价指标对比

数据集	方法序号	预测方法	MAE	AVR	WAPE	RMSE
长江三角洲城市群	1	MI-MEMD-CNN	4.438 9	0.049 9	6.980 9	6.220 8
	2	MI-MEMD-GRU	13.678 1	0.417 0	21.510 8	17.976 9
	3	MI-MEMD-XGBoost	5.225 4	0.058 0	8.217 7	6.706 4
	4	MI-MEMD-Garch	29.074 0	2.003 9	45.723 2	39.406 1
	5	MI-MEMD-Holt	165.067 1	45.102 9	259.592 4	186.953 1
	6	MEMD-3D-CNN-CBAM	6.437 4	0.068 8	10.123 7	7.301 7
	7	MI-3D-CNN-CBAM	4.740 7	0.056 5	7.455 4	6.619 0
	8	MI-MEMD-3D-CNN-CA	4.197 8	0.035 9	6.601 7	5.273 2
	9	MI-MEMD-3D-CNN-SA	4.464 8	0.038 6	7.021 6	5.472 4
	10	CEEMDAN-FE-LSTM	42.787 7	3.261 1	67.290 0	50.270 4
	11	MI-MEMD-3D-CNN-CBAM(本文方法)	3.902 0	0.027 6	6.136 4	4.627 9
京津冀城市群	12	MI-MEMD-CNN	34.033 6	0.984 3	42.907 5	51.998 2
	13	MI-MEMD-GRU	30.929 6	0.983 2	38.994 1	51.970 5
	14	MI-MEMD-XGBoost	28.321 6	0.816 7	35.706 1	47.364 9
	15	MI-MEMD-QSSVR	28.287 9	0.830 2	35.663 6	47.755 2
	16	MI-MEMD-SVR	28.294 6	0.830 1	35.672 1	47.753 8
	17	MI-MEMD-LSTM	31.776 1	0.811 1	40.061 4	47.202 3
	18	MI-MEMD-Holt	297.589 1	38.702 8	375.182 3	326.066 8
	19	MI-MEMD-Garch	42.285 5	1.123 0	53.311 0	55.543 2
	20	MEMD-3D-CNN-CBAM	28.524 2	0.835 4	35.961 6	47.904 8
	21	MI-3D-CNN-CBAM	28.292 9	0.829 5	35.669 9	47.734 6
	22	MI-MEMD-3D-CNN-CA	28.604 9	0.853 2	36.063 3	48.412 5
	23	MI-MEMD-3D-CNN-SA	28.391 2	0.837 8	35.793 9	47.975 0
	24	MI-MEMD-3D-CNN-CBAM(本文方法)	27.953 2	0.773 0	35.241 8	46.081 7
	珠江三角洲城市群	25	MI-MEMD-CNN	16.321 9	0.857 7	28.292 7
26		MI-MEMD-GRU	20.420 6	1.153 6	35.397 6	27.737 7
27		MI-MEMD-XGBoost	16.299 7	0.851 3	28.254 3	23.827 7
28		MI-MEMD-QSSVR	16.294 4	0.854 1	28.245 0	23.867 6
29		MI-MEMD-SVR	16.293 2	0.854 1	28.243 1	23.867 1
30		MI-MEMD-LSTM	19.380 0	1.087 7	33.593 7	26.934 3
31		MI-MEMD-Holt	41.084 4	3.081 4	71.216 7	45.334 2
32		MI-MEMD-Garch	20.094 0	1.001 9	34.831 5	25.849 7
33		MEMD-3D-CNN-CBAM	16.332 9	0.854 7	28.311 8	23.875 6
34		MI-3D-CNN-CBAM	16.266 0	0.851 2	28.195 9	23.826 4
35		MI-MEMD-3D-CNN-CA	16.356 5	0.858 7	28.352 8	23.931 9
36		MI-MEMD-3D-CNN-SA	16.287 9	0.854 4	28.233 8	23.871 0
37		MI-MEMD-3D-CNN-CBAM(本文方法)	15.972 8	0.821 0	27.687 7	23.400 8

法的预测结果,MI-MEMD-Holt和MI-MEMD-Garch方法的预测误差较高.由此可见,Holt模型和Garch模型不适用于AQI序列的时空预测,原因在于这两种模型主要刻画序列的线性特征,而AQI序列具有非线性和非平稳性特征,因而难以达到预期的拟合效果.

2)与不进行MI相关性检验的对比.在本文方法的基础上,不进行MI相关性检验,即不考虑上海市AQI、北京市AQI和广州市AQI分别与长江三角洲

区域、京津冀区域和珠江三角洲区域主要城市空气污染物和气象因素的线性和非线性相关性,直接将所有相关影响因素加入时空预测模型,记为MEMD-3D-CNN-CBAM方法.对比结果如表1中6、20和33所示,3种方法的4种预测误差评价指标均高于本模型,这说明利用MI方法进行相关性检验,能够分别筛选出与上海市AQI、北京市AQI和广州市AQI相关度较高的因素,从而减少冗余信息对拟合过程的干扰,

提高模型的预测精度。

3) 与不进行多尺度分解的对比。基于本文方法, 不考虑多尺度分解方法, 直接利用3D-CNN-CBAM模型提取三维张量的时空特征, 记为MI-3D-CNN-CBAM方法。对比结果如表1中7、21和34所示, 3种方法的预测精度均低于本文方法, 表明MEMD方法能够将非线性和非平稳性的复杂序列分解为规律性更明显, 平稳性更强的子序列和趋势项, 以实现不同尺度数据特征的有效提取。

4) 与利用通道或空间注意力机制的对比。基于本文方法, 对分解重构后具有不同尺度特征的子序列仅利用结合通道或空间注意力机制的模型进行预测, 分别记为MI-MEMD-3D-CNN-CA方法和MI-MEMD-3D-CNN-SA方法。对比结果如表1中8、9、22、23、35和36所示。相较于上述方法, 本文方法实现了更优的预测效果, 表明通过从城市和影响因素两个维度对时空特征进行赋权处理, 本文方法能够有效提取上海市AQI、北京市AQI和广州市AQI的关键时空信息, 从而实现预测精度的提升。

5) 与已有预测方法的对比。本文将所提出的方法与其他预测AQI数据的文献中的CEEMDAN-FE-LSTM方法^[20]进行比较分析。对比结果如表1中10所示, 本文方法的预测效果要明显高于CEEMDAN-FE-LSTM方法, 由此可见, 本文方法具有更高的预测精度。

3 结论

AQI数值变化同时受到本地和邻近地区等相关因素影响, 具有时空异质性和混沌性等特征。对其进行及时准确的预测有助于公众积极预防和政府治理体系的制定。然而, 现有预测研究忽视了气象因素和空气污染物的空间关联属性, 并且传统3D-CNN模型难以有效识别时空特征中的关键信息。因此, 本文提出时空数据驱动下基于多尺度3D-CNN-CBAM的AQI时空预测方法。首先, 利用MI对影响因素进行筛选; 然后, 利用MEMD和SE方法将各原始序列分解重构为高频序列、低频序列和趋势项; 进而, 构建子序列的三维空间张量; 最后, 设计3D-CNN-CBAM网络模型对各子序列进行预测, 并集成得到目的地AQI的最终预测结果。

研究表明, 本文的预测方法对于同时具有时间和空间双重属性的序列具有较高的预测精度和良好的适用性, 并且具有以下3方面的优势: 1) 本文将多尺度分解方法与深度学习模型相结合, 以降低时空数据的随机性和混沌性, 得到更具规律性的子序列,

进一步提高了模型的预测性能。2) 3D-CNN-CBAM网络模型通过学习AQI序列区域时空特征的重要程度, 能够有效地提取关键的空间时域信息, 从而缓解传统CNN模型存在的长期记忆能力受限问题。相比于传统CNN模型, 该模型表现出更优的预测性能, 为具有时空异质性序列的非线性拟合提供了一种新的视角。3) 本文由点延伸至空间, 基于本地和邻近地区的AQI及其影响因素, 构建三维空间张量, 以有效反映气象因素和空气污染物的时空变化, 从而为AQI预测提供更有价值的空间时效信息。

本研究的重点在于建立基于三维空间张量的3D-CNN-CBAM预测模型, 以反映气象因素和空气污染物的时空演变。在未来研究中, 可以进一步考虑AQI波动区间提供的不确定信息, 以及对原始数据进行的降噪优化处理等。另外, 本文研究也为预测其他具有时空性质的实际问题提供了新的思路。

参考文献(References)

- [1] Zhang Q, He K, Huo H. Cleaning China's air[J]. *Nature*, 2012, 484(7393): 161-162.
- [2] 廖海斌, 袁理, 龚颖巍. 基于多尺度时空图神经网络的污染物浓度预测[J]. *控制与决策*, 2024, 39(4): 1396-1402.
(Liao H B, Yuan L, Gong H W. Pollutant concentration forecast based on multiscale spatiotemporal graph neural network[J]. *Control and Decision*, 2024, 39(4): 1396-1402.)
- [3] Wang Z C, Gao R B, Wang P, et al. A new perspective on air quality index time series forecasting: A ternary interval decomposition ensemble learning paradigm[J]. *Technological Forecasting and Social Change*, 2023, 191: 122504.
- [4] Shang Z G, Deng T, He J Q, et al. A novel model for hourly PM_{2.5} concentration prediction based on CART and EELM[J]. *Science of the Total Environment*, 2019, 651: 3043-3052.
- [5] Kaur J, Singh S, Parmar K S. Forecasting of AQI (PM_{2.5}) for the three most polluted cities in India during COVID-19 by hybrid Daubechies discrete wavelet decomposition and autoregressive (Db-DWD-ARIMA) model[J]. *Environmental Science and Pollution Research*, 2023, 30(45): 101035-101052.
- [6] Mao W J, Wang W L, Jiao L M, et al. Modeling air quality prediction using a deep learning approach: Method optimization and evaluation[J]. *Sustainable Cities and Society*, 2021, 65: 102567.
- [7] Zhao Z X, Wu J R, Cai F J, et al. A statistical learning framework for spatial-temporal feature selection and

- application to air quality index forecasting[J]. *Ecological Indicators*, 2022, 144: 109416.
- [8] Hu K, Che J X. A reduced-form ensemble of short-term air quality forecasting with the sparrow search algorithm and decomposition error correction[J]. *Environmental Science and Pollution Research International*, 2023, 30(16): 48508-48531.
- [9] Su M S, Liu H, Yu C Q, et al. A novel AQI forecasting method based on fusing temporal correlation forecasting with spatial correlation forecasting[J]. *Atmospheric Pollution Research*, 2023, 14(4): 101717.
- [10] Jin N, Zeng Y K, Yan K, et al. Multivariate air quality forecasting with nested long short term memory neural network[J]. *IEEE Transactions on Industrial Informatics*, 2021, 17(12): 8514-8522.
- [11] Li T Y, Hua M, Wu X. A hybrid CNN-LSTM model for forecasting particulate matter (PM2.5)[J]. *IEEE Access*, 2020, 8: 26933-26940.
- [12] 方晓萍, 陈秀鑫, 褚琦, 等. 基于PSOGSA-LSTM模型的长江经济带空气质量指数预测研究[J]. *数理统计与管理*, 2023, 42(1): 14-25.
(Fang X P, Chen X L, Chu Q, et al. A study on forecast of air quality index in the Yangtze River economic zone based on PSOGSA-LSTM model[J]. *Journal of Applied Statistics and Management*, 2023, 42(1): 14-25.)
- [13] Xiao Y J, Wang X K, Wang J Q, et al. An adaptive decomposition and ensemble model for short-term air pollutant concentration forecast using ICEEMDAN-ICA[J]. *Technological Forecasting and Social Change*, 2021, 166: 120655.
- [14] Samal K K R, Panda A K, Babu K S, et al. An improved pollution forecasting model with meteorological impact using multiple imputation and fine-tuning approach[J]. *Sustainable Cities and Society*, 2021, 70: 102923.
- [15] 刘金培, 陈丽娟, 汪漂, 等. 基于MEMD和空间层次聚类的PM2.5三角模糊序列多因子组合预测[J]. *控制与决策*, 2023, 38(2): 537-545.
(Liu J P, Chen L J, Wang P, et al. Multi-factor combination prediction of PM2.5 triangular fuzzy series based on MEMD and spatial hierarchical clustering[J]. *Control and Decision*, 2023, 38(2): 537-545.)
- [16] Pak U, Ma J, Ryu U, et al. Deep learning-based PM2.5 prediction considering the spatiotemporal correlations: A case study of Beijing, China[J]. *Science of the Total Environment*, 2020, 699: 133561.
- [17] Jiang L Y, Tao Z F, Zhu J M, et al. Exploiting PSO-SVM and sample entropy in BEMD for the prediction of interval-valued time series and its application to daily PM2.5 concentration forecasting[J]. *Applied Intelligence*, 2023, 53(7): 7599-7613.
- [18] Jeong J I, Park R J. Can climate indices forecast daily variations of wintertime PM2.5 concentrations in East Asia?[J]. *Science of the Total Environment*, 2023, 881: 163505.
- [19] Wang Z C, Chen H Y, Zhu J M, et al. Daily PM2.5 and PM10 forecasting using linear and nonlinear modeling framework based on robust local mean decomposition and moving window ensemble strategy[J]. *Applied Soft Computing*, 2022, 114: 108110.
- [20] Wu Z K, Zhao W Q, Lv Y Q. An ensemble LSTM-based AQI forecasting model with decomposition-reconstruction technique via CEEMDAN and fuzzy entropy[J]. *Air Quality, Atmosphere & Health*, 2022, 15(12): 2299-2311.

作者简介

刘金培(1984—), 男, 教授, 博士, 主要研究方向为预测与决策分析, E-mail: liujinpei2012@163.com;

罗瑞(1996—), 女, 博士生, 主要研究方向为预测与决策分析, E-mail: lr5012@126.com;

陈华友(1969—), 男, 教授, 博士, 主要研究方向为预测与决策分析, E-mail: huayouc@126.com;

周礼刚(1980—), 男, 教授, 博士, 主要研究方向为统计预测与决策、数据融合, E-mail: shuiqiaozlg@126.com.