

GeoPriFormer: 地理先验嵌入的降水空间插值方法

王晓川¹, 刘青青¹, 王晨¹, 牟恒辰¹, 廖要明², 刘瑞军³

(1. 北京工商大学计算机与人工智能学院, 北京 100048;

2. 中国气象局国家气候中心, 北京 100081; 3. 北京航空航天大学软件学院, 北京 100191)

摘要: 目前, 关于降水空间插值的深度学习方法仅依赖站点之间的位置关系, 忽略了区域内特征的有效表示以及复杂特征依赖关系, 尤其对降水与高程之间的关系考虑不足。为此, 提出地理先验嵌入的降水空间插值方法 GeoPriFormer。该方法以 Transformer 作为主干网络, 通过引入地理先验数据来增强特征表示能力, 从而提高降雨空间插值的精度和可靠性。一方面, 引入高程-多头注意力子模块以提高模型对复杂地形影响的理解和适应能力; 另一方面, 使用拉普拉斯方法来学习地理坐标的上下文感知向量编码, 以增强模型对地点关系和区域特性的理解, 最终形成一个嵌入地理先验的特征表示。在河南、京津冀和德国的巴登-符腾堡州(BW)数据集上进行对比实验, 结果表明, GeoPriFormer 均优于基线模型。以京津冀数据集为例, 均方根误差(RMSE)降低 1.6%, 平均绝对误差(MAE)降低 5.1%, 纳什效率系数(NSE)提升 1.56%, 优于当前主流方法。

关键词: 降水空间插值; Transformer 模型; 地理先验; 高程-多头注意力子模块; 拉普拉斯方法

中图分类号: TP391.4

文献标志码: A

DOI: 10.19678/j.issn.1000-3428.0070260

GeoPriFormer: A Precipitation Spatial Interpolation Method with Geographic Priors Embedding

WANG Xiaochuan¹, LIU Qingqing¹, WANG Chen¹, MU Hengchen¹, LIAO Yaoming², LIU Ruijun³

(1. School of Computer Science and Artificial Intelligence, Beijing Technology and Business University, Beijing 100048, China;

2. National Climate Centre, China Meteorological Administration, Beijing 100081, China;

3. School of Software, Beihang University, Beijing 100191, China)

【Abstract】 Current deep learning methods for precipitation spatial interpolation rely primarily on the spatial relationships between stations and often overlook the effective representation of regional features and their complex dependencies. In particular, this approach does not consider the relationship between precipitation and elevation. To address this issue, GeoPriFormer is proposed as a spatial interpolation method for precipitation that incorporates geographic priors. This method uses a Transformer as the backbone network and enhances feature representation by integrating geographic prior data. This integration improves the accuracy and reliability of precipitation spatial interpolation. An elevation-based multi-head attention submodule is introduced to better understand and adapt to the effects of complex terrain. Additionally, a Laplacian method learns the context-aware vector encoding of geographic coordinates, enhancing the model's understanding of spatial relationships and regional characteristics. Consequently, the feature representation is embedded with geographic priors. Comparative experiments conducted on the Henan, Beijing-Tianjin-Hebei, and Baden-Württemberg (BW) datasets show that GeoPriFormer outperforms the baseline models. For example, in the Beijing-Tianjin-Hebei dataset, the Root Mean Squared Error (RMSE) is reduced by 1.6%, the Mean Absolute Error (MAE) decreases by 5.1%, and the Nash-Sutcliffe's Efficiency (NSE) increases by 1.56%, indicating an improvement over the current dominant approaches.

【Key words】 precipitation spatial interpolation; Transformer model; geographic prior; elevation-based multi-head attention submodule; Laplacian method

0 引言

降水数据作为地球科学和气候研究中的关键数据, 在预测天气变化、应对极端气象事件和水资源管

理等方面具有重要作用^[1-3]。然而, 传统降水量观测方法受限于固定点测量, 难以准确反映大范围内的降水情况。这种局限性导致在进行气象和水资源管理时存在一定的不确定性^[4]。随着空间插值方法的

基金项目: 新一代人工智能国家科技重大专项(2022ZD0119502)。

作者简介: 王晓川, 男, 副教授、博士, 主研方向为计算机图形学、图像处理、质量度量; 刘青青, 硕士研究生; 王晨, 讲师、博士; 牟恒辰, 硕士研究生; 廖要明、刘瑞军(通信作者), 教授、博士。

收稿日期: 2024-08-16

修回日期: 2024-11-04

E-mail: liuruijun@buaa.edu.cn

不断发展,通过综合分析多个观测点的数据,能够更准确地估算大范围内的降水分布^[5-6]。

鉴于此,一系列降水空间插值方法被提出,依据所使用的先验可分为确定性方法、地质统计学方法与机器学习方法。其中,确定性方法假设空间上相距越近的点具有相似特征的可能性越大,反之则越小,基于此,先验将离散点尺度转换为连续面尺度数据。典型方法有反距离加权方法^[7-8](IDW)、薄板样条插值方法^[9](TPS)、三角不规则方法^[10](TIN)等。地质统计学方法假设降水数据的空间相关性可以通过随机过程描述,基于此,先验利用变异函数量化空间相关性。典型方法包括普通克里金^[11](OK)等。该方法考虑了预测变量的空间自相关性,利用邻近点的信息估计目标属性值,且距离目标点越近的邻近点在插值中的权重越大,远离目标点的邻近点则权重较小。然而,尽管该方法考虑了解释变量的影响,但仍然会受一系列因素的制约,例如降雨类型、降雨与辅助变量的相关性、气象站的密度等。机器学习方法假设数据样本中蕴含的模式和结构可以被算法所学习,并且这些模式和结构能够推广到未见过的数据。典型方法包括人工神经网络^[12](ANN)、随机森林^[13-14](RF)等。该方法依赖于输入和输出之间的样本训练所建立的灰盒或黑盒关系,尽管能够较为准确地建立两者间的非线性关系,但过于依赖各种预设参数。

近年来,深度学习的发展为降水空间插值提供了新的途径。地面站点观测数据可以自然地建模为空间图结构上的信号。其中,图神经网络^[15-16](GNN)通过考虑数据点之间的空间邻近性或物理连接,训练邻近点与目标点之间的关联,从而捕捉复杂的局部空间模式。因此,GNN 在空间插值领域得到了广泛的应用^[17-18]。APPLEBY 等^[19]提出 KCN (Kriging Convolutional Networks)网络,通过预先定义和调查未观察到的节点周围的 K 个最近邻,用可学习的权值对邻居的标签进行平均,来估计目标节点的数值。WU 等^[20]提出 IGNNK (Inductive Graph Neural Networks for spatiotemporal Kriging)网络,通过生成随机子图并学习空间相关性来重构它们的信号,尤其是在未观察到的节点上表现良好。

上述方法利用 GNN 捕捉数据中复杂关系和依赖关系的固有能力和能力,但仍依赖于两个假设:其一,观测数据点服从高斯过程;其二,这些数据点在空间上是静态的,不随时间发生显著变化。然而,这些假设在观测点稀疏的区域或复杂地形中并不适用。此

外,基于 GNN 的方法在捕捉远程站点之间的关系时存在不足,导致空间关系信息的丢失。KLEMMER 等^[21]通过随机选择 K 个最近邻点并引入模块化位置编码组件,学习地理坐标的上下文感知嵌入,从而增强模型对特定位置对象类别发生概率的捕捉能力。然而,该方法需要手动设计特性来构建,随着时空相互依赖建模的复杂性不断增加,预先设定明确特征的空间相关性变得不可行。同时,该方法忽略了真实场景下的环境因素,例如复杂地形对降雨估计的影响,导致预测结果的偏差和不准确。LI 等^[22]提出了基于 Transformer 架构的 SpaFormer 网络,通过自注意力机制在空间维度上进行全局建模,克服了传统 GNN 方法在捕捉远程站点关系时的不足。然而,该方法忽略了一些关键的环境变量,导致模型无法准确捕捉到空间数据的真实动态和复杂性。

针对上述问题,提出地理先验嵌入的降水空间插值方法 GeoPriFormer。该方法利用深度神经网络将观测值、空间相对位置和地理先验对应的向量联合嵌入一个公共的高维特征空间中,通过使用不同注意力机制定量地捕获历史数据中的空间相关性,从而实现高精度的降雨空间插值。具体贡献如下:

1)针对当前模型未能充分学习地理要素与降水相关性的问题,提出高程-多头注意力子模块,建模空间层面复杂的相关性。利用多头注意力机制,学习待测点和已知点的高程信息相关性。

2)利用拉普拉斯内核机理,计算待测点位置信息和已知点位置信息的注意力分数,增强模型对于空间位置关系的学习能力。

3)在河南、京津冀和德国的巴登-符腾堡州(BW)数据集上进行对比实验分析,结果表明,提出的方法优于基线模型。

1 本文方法

1.1 模型总体框架

GeoPriFormer 网络框架如图 1 所示(彩色效果见《计算机工程》官网 HTML 版,下同),主要分为输入嵌入模块(IEM)、空间相对位置嵌入模块(SRPEM)、地理先验嵌入模块(GEM)和预测模块(PM)。IEM 主要用于将处理后的数值型降雨观测数据,通过一个两层的全连接层转换为适用于模型的嵌入向量。SRPEM 为观测站点间的空间相对位置生成嵌入向量。GEM 将高程和经纬度的地理信息转换为嵌入向量,主要由高程-多头注意力子模块

和地理坐标-拉普拉斯注意力子模块组成。PM 负责从插值 Transformer 模块(ITM)生成的节点表示

中推导目标位置的最终预测结果。下面分别介绍上述 4 个模块。




图 1 GeoPriFormer 网络框架

Fig.1 GeoPriFormer network framework

1.2 输入嵌入模块

因为降雨观测数据是用连续数值记录而非离散的词汇,所以面向传统语言模型的线性嵌入方法并不适用于处理降水观测数据。此外,降水观测数据的零值会映射到零嵌入向量,导致在后续的自注意力计算中引起零交互。具体来说,当嵌入向量为零时,它与其他嵌入向量的交互效果也是零,在自注意力机制中,这些零嵌入向量不会对计算结果产生任何贡献,且会导致信息丢失,并不利于降水数据处理,而标准化的零值代表了某一区域的平均降雨水平。为解决上述问题,本文使用两层全连接网络(TwoLayerFCN)将降水观测数据转换为嵌入向量,具体表示如下:

$$e_1 = F_1(P_1; \mathbf{W}_1, \mathbf{b}_1) \quad (1)$$

$$e_2 = F_2(e_1; \mathbf{W}_2, \mathbf{b}_2) \quad (2)$$

式中: P_1 为观测站点 s_1 处的降水值; $\mathbf{W}_i$ 是可学习矩阵; $\mathbf{b}_i$ 为第 i 层可学习偏置向量; F_i 为第 i 层的 FCN; e_1 为经过第一层线性变换的结果; e_2 为经过第二层线性变换处理后的最终嵌入向量。在每一层中,增加参数数量和偏置向量,提高了表示容量并避免了零嵌入问题。

1.3 空间相对位置嵌入模块

空间相对位置嵌入模块的目标是生成空间相对位置的嵌入向量,表示观测站点间的空间相对位置,具体表示如下:

$$r_{ij} = [d, \theta_1] \quad (3)$$

$$r_{ji} = [d, \theta_2] \quad (4)$$

$$c_{ij}^1 = \text{ReLU}(F_1(r_{ij}^1; \mathbf{W}'_1, \mathbf{b}'_1)) \quad (5)$$

$$c_{ij}^2 = F_2(c_{ij}^1; \mathbf{W}'_2, \mathbf{b}'_2) \quad (6)$$

式中: r_{ij} 为观测站点 s_i 和 s_j 之间的空间相对位置; d 和 θ 分别为观测站点之间的距离和方位角; $\mathbf{W}'_i$ 为可学习矩阵; $\mathbf{b}'_i$ 为偏置向量; c_{ij} 是经过 TwoLayerFCN

得到的嵌入向量。

相对位置嵌入将相对位置信息引入自注意力机制中,同样采用与输入嵌入模块类似的方法生成空间相对位置嵌入,使用距离和方位角两个值来表示二维空间中位置之间的相对位置,然后通过 TwoLayerFCN 生成嵌入向量。

1.4 地理先验嵌入模块

地理先验嵌入模块的目标是根据输入特征增强模型的特征表示能力,使得模型能够更准确地捕捉和表达地理先验与降水之间的复杂关系。该模块将地理先验信息转换为嵌入向量,以表示特定位置的地理特征。这些地理特征与历史降水数据一同输入模型,通过多头注意力机制和拉普拉斯注意力机制,动态捕捉地理先验与降水数据之间的空间依赖关系。具体而言,多头注意力机制根据地理特征和目标点的相对位置,为不同降水数据分配权重,从而捕捉地形等地理信息对降水空间分布的影响。同时,拉普拉斯注意力通过局部空间关系,进一步强化了地理坐标与降水数据的空间相关性。接下来,将详细介绍高程-多头注意力子模块和地理坐标-拉普拉斯注意力子模块的应用。

1.4.1 高程-多头注意力子模块

多头注意力机制是一种允许模型通过多个并行的注意力头同时关注不同表示子空间信息的技术,每个头学习特定的投影矩阵来处理查询(query)、键(key)和值(value),从而实现对信息的全面捕捉。

为了建模并提取每个站点降雨数据与高程的相关性,提出带掩码的高程-多头注意力子模块,如图 2 所示。

在提取输入降雨数据中每个站点序列的高程相关性时,多头注意力机制通过其查询、键和值的组件发挥关键作用。设观测点降水为 P ,生成的嵌入向




图 2 多头注意力机制

Fig.2 Multi-head attention mechanism

量为 E_p , 即所有观测值特征聚合后的输入嵌入。设观测点的高程为 H , 生成的嵌入向量为 E_h , 掩码点的高程 H_m 生成的嵌入向量为 E_m , 设为高程特征嵌入。首先, 分别提取出掩码点和已知点的高程特征, 并将这些属性分别投影为查询向量 q 和键向量 k 。值向量 v 由已知点的观测降水向量 E_p 和已知点的高程向量 E_h 连接 (concatenate) 得到, 如式 (7) 所示:

$$v = \text{concat}(E_p, E_h) \quad (7)$$

通过 TwoLayerFCN 将输入特征向量 E_p 、 E_h 和 E_m 变换为隐藏层表示的查询 Q 、键 K 和值 V 。然后, 经过线性变换计算出查询 Q 、键 K 和值 V , 公式如下:

$$Q = E_m W^q \quad (8)$$

$$K = E_h W^k \quad (9)$$

$$V = \text{concat}(E_p, E_h) W^v \quad (10)$$

式中: W^q 、 W^k 和 W^v 分别是相应变换的参数矩阵。注意力机制中第 i 个节点的输出 A_i 公式如下:

$$A_i = \sum_{j=1}^n \alpha_{ij} v_j \in \mathbb{R}^{d_k} \quad (11)$$

$$\alpha_{ij} = \frac{\exp(g_{ij})}{\sum_{k=1}^n \exp(g_{ik})} \quad (12)$$

$$g_{ij} = \frac{\text{sum}(q_i \odot k_j \odot c_{ij})}{\sqrt{d_k}} \quad (13)$$

式中: α_{ij} 是第 i 个节点对第 j 个节点使用 Softmax 函数归一化的注意力权重; g_{ij} 是节点 i 到节点 j 的注意力得分; 因子 $\sqrt{d_k}$ 发挥调节作用, 使得点积不会太大。

多头注意力机制通过连接所有头的输出向量并应用一个线性变换得到。为学习地理高程嵌入的复

杂空间相关性, 分别采用多头注意力学习不同的交互作用。最后, 通过一个投影将不同头的输出连接起来, 该投影的作用是整合和精炼每个头捕获的信息, 形成一个连贯的表示, 如式 (14) 所示:

$$Z_i = \text{concat}(A_i^{(1)}, A_i^{(2)}, \dots, A_i^{(h)}) W^O \quad (14)$$

式中: $\text{concat}(\cdot)$ 表示拼接不同自注意力层的输出矩阵; W^O 是用于将不同头的输出合并成一个统一的输出向量的参数矩阵; $A_i^{(h)}$ 是第 h 个头的输出。

1.4.2 地理坐标-拉普拉斯注意力子模块

为了更有效地学习空间依赖关系, 提出地理坐标-拉普拉斯注意力子模块, 将地理坐标作为输入特征的一部分, 通过计算目标位置和上下文位置之间的地理坐标距离, 并基于这些距离计算注意力权重, 从而生成目标位置的表示。该子模块如图 3 所示。




图 3 地理坐标-拉普拉斯注意力子模块

Fig.3 Geographic coordinate-Laplacian attention submodule

拉普拉斯注意力^[23]是一种特殊形式的注意力, 它利用拉普拉斯算子 (Laplacian Operator) 的特性, 对输入特征进行加权, 强调具有特定空间关系的特征。根据键和查询之间的空间距离提供注意力, 这启发了计算注意力权重时使用它来学习地理坐标、目标降水和掩码点地理坐标之间的关系。

TwoLayerFCN 分别处理已知点地理坐标 s 和掩码点地理坐标 s_* , 生成查询向量 Q 和键向量 K 。将已知点的降水量 P 和已知点地理坐标 s 结合, 复合输入通过 TwoLayerFCN, 生成值向量 V 。每个目标坐标 s_i 和掩码点地理坐标 s_* 的距离使用 L1 范数 (绝对值之和) 计算注意力权重, 通过 Softmax 函数对这些距离的负值进行指数归一化, 从而得到权重矩阵 W_{ij} 。将权重矩阵与掩码点地理坐标的特征相乘并求和, 得到目标地理坐标的表示 W^* , 再进行线性投影, 得到最终的高维特征表示 W_i^* 。 W_i^* 的计算过程如下:

$$W_{ij} = \text{Softmax}((- \|s_* - s_i\|_1)_{i=1}) \quad (15)$$

$$W^* = \text{Laplace}(s_i, p, s_*) = W_{ij} \cdot s_* \quad (16)$$

$$W_i^* = \text{linear}(W^*) \quad (17)$$

1.5 预测模块

在训练过程中,采用一种类似于掩码语言模型 (MLM) 的掩码和恢复训练方法,随机掩码序列中的部分节点,并用已知节点的平均值替代掩盖节点的输入值,以训练模型预测这些掩盖节点的降雨量值。通过这种自适应的模型交互和信息聚合,GeoPriFormer 能够生成空间上下文感知的特征表示,从而在目标位置上准确估计降雨值。

ITM 由多层堆叠组成,每一层包括屏蔽注意力机制和前馈网络,通过结合前述 4 个模块的输出,该模块生成一个综合性特征向量,作为 PM 的输入。PM 基于 ITM 生成的节点表示向量 x_i ,通过 TwoLayerFCN 进行处理,推导出最终的估计结果。该网络的隐藏单元为 $[d_e, 1]$,得到节点的最终预测结果 $\hat{x}_i$,如下式所示:

$$x_i = \text{concat}(e_i, c_{ij}, Z_i, W_i^*) \quad (18)$$

$$\hat{x}_i = (x_i W_p^{(1)} + b_p^{(1)}) W_p^{(2)} + b_p^{(2)} \quad (19)$$

式中: x_i 为观测值、空间相对位置和地理先验联合嵌入向量; $W_p^{(i)}$ 为可学习矩阵; b_p^i 为可学习偏差。

2 实验结果与分析

2.1 数据集

1) 河南和京津冀数据集。

河南和京津冀数据集均来自 ZHU 等^[24]发布的地面气象站基准数据集 Weather2K。河南省是我国主要的粮食生产区之一,在国家粮食安全中占有重要地位。该省地形复杂,以平原和山地为主,地势自西向东倾斜,海拔范围为 80~2 398 m,地势以及气象站点分布如图 4 所示。京津冀位于我国华北地区的核心区域,地处华北平原北部,东邻渤海,西靠太行山,地貌复杂,海拔范围为 -57~2 849 m。由于地形的变化,这些地区经常遭受区域降雨引起的自然灾害,地势以及气象站点位置如图 5 所示。

在河南和京津冀数据集中,分别选取了 87 和 160 个气象站点,降雨数据的精度为 0.1 mm。该数据集的时间跨度为 2017—2020 年。选取 80% 的气象站点数据作为训练集,其余 20% 作为测试集。从 Google Earth Engine(GEE)中下载了河南和京津冀区域的高程数据,空间分辨率为 30 m。

2) BW 数据集。

BW 数据集是公开的,可通过德国气象局 (DWD) 的气候数据中心 (CDC) 访问。该数据集包含 132 个气象站点,降雨数据精度为 0.1 mm,时间跨度为 2012—2014 年。随机选取 80% 的站点数据作为训练集,剩余 20% 作为测试集。




图 4 河南区域气象站点高程及分布情况

Fig.4 Elevation and distribution of meteorological stations in the Henan region




图 5 京津冀区域气象站点高程及分布情况

Fig.5 Elevation and distribution of meteorological stations in the Beijing-Tianjin-Hebei region

数据集详细信息如表 1 所示。

表 1 数据集详细信息

Table 1 Dataset details

数据集	时间跨度	时间 间隔	气象 站点	训练集	测试集
BW	2012—2014 年	1 h	132	106	26
河南	2017—2020 年	1 d	87	69	18
京津冀	2017—2020 年	1 d	160	128	32

2.2 实验环境

本文实验环境如表 2 所示。

表 2 实验环境

Table 2 Experimental environment

实验环境	环境配置
CPU	13th Gen Intel® Core™ i7-13650HX 2.60 GHz
GPU	NVIDIA GeForce RTX 4060 Laptop GPU
深度学习框架	PyTorch 2.2.0
CUDA	CUDA 12.1

2.3 实验参数及评价指标

表 3 列出了河南、京津冀和 BW 数据集的训练细节以及 GeoPriFormer 模型的超参数设置。在训练过程中,采用自适应矩估计方法^[25](Adam)作为优化器来训练网络参数,优化器的参数设置为 $\beta_1=0.9, \beta_2=0.98, \epsilon=10^{-9}$ 。采用预热策略^[26]调整学习率(Learning rate),预热步数为 1 200,批量大小(Batch Size)为 64,对于每个训练轮次(Epoch),每个序列掩码 10 次,以生成不同的空间模式来增强数据集,掩码比率设置为 20%。

表 3 最优超参数

Table 3 The optimal hyperparameters

数据集	训练超参数		模型超参数		
	Batch Size	Learning rate	Num_Head	Embedding	Epoch
河南	64	0.03	2	16	150
京津冀	64	0.03	2	16	150
BW	64	0.05	4	128	100

本文采用均方根误差(RMSE, E_{RMSE})、平均绝对误差(MAE, E_{MAE})、纳什效率系数(NSE, C_{NSE})作为评价插值性能的指标。其中,NSE 是衡量水文模型性能的指标,其值域范围为 $(-\infty, 1)$ 。NSE 指数越接近 1,表示模型预测效果越佳,与实际观测数据的吻合程度越高。以上指标的计算方法如下

所示:

$$E_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{P}_i - P_i)^2} \quad (20)$$

$$E_{\text{MAE}} = \frac{1}{n} \sum_{i=1}^n |\hat{P}_i - P_i| \quad (21)$$

$$C_{\text{NSE}} = 1 - \frac{\sum_{i=1}^n (P_i - \bar{P})^2}{\sum_{i=1}^n (P_i - \hat{P}_i)^2} \quad (22)$$

式中: n 为数据点的数量; P_i 为观测真值; $\hat{P}_i$ 为估计值; $\bar{P}$ 为所有观测值的平均值。

2.4 对比实验与结果分析

2.4.1 与不同插值方法对比分析

为验证本文提出的 GeoPriFormer 模型在降雨插值任务中对地理先验的有效性,在河南、京津冀和 BW 3 个数据集上进行实验,采用 RMSE、MAE 和 NSE 作为评价指标,评估模型的效果。不同方法在降水插值任务中的表现如表 4 所示(表现最佳和次佳的结果分别以粗体和下划线形式标出,“ $\uparrow$ ”表示数值越高越好,“ $\downarrow$ ”表示数值越低越好,下同)。将本文方法与 TIN、IDW、TPS 和 OK 4 种传统插值方法以及 KCN、IGNNK 和 SpaFormer 3 种图神经网络方法进行对比,其他方法的性能均由原作者提供的公开代码和参数获得。

表 4 对比实验结果

Table 4 Comparison experiment results

方法	河南数据集			京津冀数据集			BW 数据集		
	RMSE $\downarrow$	MAE $\downarrow$	NSE $\uparrow$	RMSE $\downarrow$	MAE $\downarrow$	NSE $\uparrow$	RMSE $\downarrow$	MAE $\downarrow$	NSE $\uparrow$
TIN ^[10]	7.621 7	5.566 2	0.572 6	5.636 5	1.782 8	0.656 5	1.098 5	0.349 4	0.400 8
IDW ^[7]	7.825 7	2.915 3	0.549 4	5.506 8	2.045 8	0.672 1	1.049 3	0.391 7	0.453 3
TPS ^[9]	7.833 0	2.648 3	0.548 6	5.867 7	1.934 8	0.627 8	1.098 5	0.353 7	0.400 8
OK ^[11]	7.607 0	2.653 7	0.574 2	5.758 6	2.054 2	0.641 5	1.082 0	0.370 1	0.418 5
KCN ^[19]	7.209 1	2.531 8	0.609 4	5.572 8	2.061 8	<u>0.688 7</u>	1.046 8	0.381 9	0.455 9
IGNNK ^[20]	7.998 3	2.745 8	0.486 8	6.664 7	2.372 7	0.528 1	1.142 9	0.601 8	0.351 4
SpaFormer ^[22]	<u>6.612 6</u>	<u>2.492 0</u>	<u>0.678 3</u>	<u>5.419 9</u>	1.976 9	0.682 4	<u>0.988 9</u>	<u>0.344 1</u>	<u>0.514 3</u>
GeoPriFormer	6.558 2	2.488 7	0.683 5	5.328 4	<u>1.876 6</u>	0.693 1	0.983 9	0.336 9	0.519 2

根据表 4 的实验结果,本文提出的 GeoPriFormer 算法在处理降水量的空间插值任务中展现了显著的效果。在河南和京津冀数据集上,该方法的 RMSE 较传统插值方法降低了 2.23%~8.27%,与 KCN、IGNNK、SpaFormer 等先进方法相比, RMSE 降低了 0.82%~25.07%。在 BW 数据集上,该方法的 RMSE 较传统插值方法降低了

6.15%~10.77%,与 KCN、IGNNK、SpaFormer 等先进方法相比, RMSE 降低了 0.82%~10.14%。从具体数据来看,基于地理先验的模型在插值精度方面显著优于传统方法和基于 GNN 的模型。这表明,融入地理先验的 Transformer 模型能够更好地捕捉和利用高程、坐标与降水量之间的复杂空间关系。这一机制的引入,使模型能够动态地

关注不同地理位置的特征,有效提升插值精度。提出的方法在河南、京津冀和 BW 数据集上的对比实验证明了其在处理不同数据集上的有效性和鲁棒性。

使用不同插值模型对京津冀地区 2017 年 6 月 6 日降水量进行可视化分析,如图 6 所示,GeoPriFormer 方法相较于其他基线模型与观测站真实数据吻合度最高。




图 6 2017 年 6 月 6 日京津冀区域日累计降水量空间分布图

Fig.6 Spatial distribution map of daily cumulative precipitation in the Beijing-Tianjin-Hebei region on June 6, 2017

为了进一步比较这些模型的性能,将观测站真实数据与插值结果以散点图的形式展示在图 7 中。使用决定系数(R^2)衡量模型对数据的拟合优度,GeoPriFormer 方法在处理京津冀数据集的降水插值时 R^2 值最高,说明地理先验嵌入对提高模型精度有显著作用。

2.4.2 消融实验

为验证本文模型的有效性,通过消融实验来验证加入的高程-多头注意力子模块和地理坐标-拉普拉斯注意力子模块的优化性能。在实验设置中,将 IEM 和 SRPEM 作为基础网络,分别对高程-多头注意力子模块和地理坐标-拉普拉斯注意力子




图 7 对京津冀数据集的插值结果与观测站真实值比较的散点图

Fig. 7 Scatter plot comparing the interpolation results of the Beijing-Tianjin-Hebei dataset with the actual values from observation stations

模块进行消融测试。不同改进策略下的实验结果对比如表 5 所示。

由表 5 可知,4 个模型在河南、京津冀与 BW 数据集上的表现表明,随着网络结构逐步引入地理先验信息,模型的性能得到提升。由基础网络向 GeoPriFormer 的演变过程表明了各项优化措施有效地增强了模型的适应能力。具体来说,高程-多头注意力子模块能够有效捕捉不同高程与降水数据之间的相关性信息,帮助模型学习更复杂的空间特征,从而提升了降雨插值的精确度;而地理坐标-拉普拉斯注意力能够捕捉空间结构的局部连续性和边界特

征,进一步增强模型对复杂空间结构的理解。综上所述,本文通过引入高程-多头注意力和地理坐标-拉普拉斯注意力 2 个子模块,特别是在地形复杂的区域,提高了降雨插值的精度,验证了模型在处理不同地理场景下的有效性。

3 结束语

本文提出一种地理先验嵌入的降水空间插值方法 GeoPriFormer,并通过大量实验验证了其在不同区域的泛化能力和优越性能。通过结合高程-多头注意力模块和地理坐标-拉普拉斯模块,

表 5 不同改进策略的实验结果

Table 5 Experimental results of different improvement strategies

方法	河南数据集			京津冀数据集			BW 数据集		
	RMSE↓	MAE↓	NSE↑	RMSE↓	MAE↓	NSE↑	RMSE↓	MAE↓	NSE↑
基础网络	6.612 6	2.492 0	0.678 3	5.419 9	1.976 9	0.682 4	0.988 9	0.344 1	0.514 3
基础+高程	6.586 9	2.448 2	0.680 8	5.383 9	1.861 8	0.686 6	0.985 2	0.340 6	0.515 6
基础+地理坐标	6.610 1	2.534 1	0.678 5	5.410 6	1.896 2	0.683 5	0.988 0	0.342 6	0.513 9
GeoPriFormer	6.558 2	2.488 7	0.683 5	5.328 4	1.876 6	0.693 1	0.983 9	0.336 9	0.519 2

GeoPriFormer 能够更好地理解和适应复杂地形的影响,从而显著提升模型的精度和可靠性。未来的研究可以进一步优化 GeoPriFormer 的结构,考虑引入时间序列信息,提升对动态降雨模式的插值能力。

参考文献

[1] MA M H, WANG H X, JIA P F, et al. Application of the GPM-IMERG products in flash flood warning: a case study in Yunnan, China[J]. Remote Sensing, 2020, 12(12): 1954.

[2] DONAT M G, LOWRY A L, ALEXANDER L V, et al. Addendum: more extreme precipitation in the world's dry and wet regions[J]. Nature Climate Change, 2017, 7(2): 154-158.

[3] 黄杰, 张永宏, 马光义, 等. 改进 U-Net 的风云四号卫星降水估计算法研究[J]. 计算机工程与应用, 2023, 59(11): 285-293.

HUANG J, ZHANG Y H, MA G Y, et al. Research on precipitation estimation algorithm from Fengyun-4 satellite based on improved U-Net[J]. Computer Engineering and Applications, 2023, 59(11): 285-293. (in Chinese)

[4] 王雪梅, 郭良, 翟晓燕. 降雨时空不确定性对小流域洪峰模拟的影响评估[J]. 人民黄河, 2024, 46(4): 49-54.

WANG X M, GUO L, ZHAI X Y. Assessing the impact of rainfall spatial-temporal uncertainty on flood peak simulation in small mountainous catchment[J]. Yellow River, 2024, 46(4): 49-54. (in Chinese)

[5] ZHU A X, LU G N, LIU J, et al. Spatial prediction based on third law of geography[J]. Annals of GIS, 2018, 24(4): 225-240.

[6] HADI S J, TOMBUL M. Comparison of spatial interpolation methods of precipitation and temperature using multiple integration periods[J]. Journal of the Indian Society of Remote Sensing, 2018, 46(7): 1187-1199.

[7] WORKNEH H T, CHEN X L, MA Y M, et al. Comparison of IDW, Kriging and orographic based linear interpolations of rainfall in six rainfall regimes of Ethiopia[J]. Journal of Hydrology: Regional Studies, 2024, 52: 101696.

[8] 高真, 叶学义, 周天琪, 等. 基于反距离加权插值的水声数据可视化算法[J]. 计算机工程, 2015, 41(9): 266-270, 275.

GAO Z, YE X Y, ZHOU T Q, et al. Visualization algorithm of underwater acoustic data based on inverse distance weight interpolation[J]. Computer Engineering, 2015, 41(9): 266-270, 275. (in Chinese)

[9] ACHITE M, CERIBASI G, WALEGA A, et al. Analysis of monthly average precipitation of Wadi Ouahrane Basin in Algeria by using the ITRA, ITPAM, and TPS methods[J]. Environmental Monitoring and Assessment, 2023, 195(5): 606.

[10] IBRAHIM P O, STERNBERG H, SAMAILA-IJA H A, et al. Modelling topo-bathymetric surface using a Triangulation Irregular Network (TIN) of Tunga Dam in Nigeria[J]. Applied Geomatics, 2023, 15(1): 281-293.

[11] JALILI P F, MODARRES R. Geostatistical and deterministic methods for rainfall interpolation in the Zayandeh Rud basin, Iran [J]. Hydrological Sciences Journal, 2020, 65(16): 2678-2692.

[12] ADHIKARY S K, MUTTIL N, YILMAZ A G. Cokriging for enhanced spatial interpolation of rainfall in two Australian catchments [J]. Hydrological Processes, 2017, 31(12): 2143-2161.

[13] 廖希, 周萍, 周思洋, 等. 基于机器学习的城市环境跨频段跨场景路径损耗预测方法[J]. 重庆邮电大学学报(自然科学版), 2024, 36(6):1099-1109.

LIAO X, ZHOU P, ZHOU S Y, et al. Cross-frequency band and cross-scenario path loss prediction method in urban environments based on machine learning [J]. Journal of Chongqing University of Posts and Telecommunications (Natural Science Edition), 2024, 36(6): 1099-1109. (in Chinese)

[14] SEKULIĆ A, KILIBARDA M, PROTIĆ D, et al. A high-resolution daily gridded meteorological dataset for Serbia made by random forest spatial interpolation [J]. Scientific Data, 2021, 8: 123.

[15] 语涵, 孙未未, 卢霖统. 融合 GNN 和注意力增强 LSTM 的轨迹相似度计算方法 [J]. 小型微型计算机系统, 2024, 45(11): 2561-2568.

WANG Y H, SUN W W, LU L T. Trajectory similarity computation based on GNNs and attention mechanism with LSTM[J]. Journal of Chinese Computer Systems, 2024, 45(11): 2561-2568. (in Chinese)

[16] AINI N N, IRIANY A, NUGROHO W H. Comparison of Kriging and neural network methods in interpolation of rainfall[C]//Proceedings of the 9th International Symposium on Innovative Bioproduction Indonesia on Biotechnology and Bioengineering 2022: Strengthening Bioeconomy Through Applied Biotechnology, Bioengineering, and Biodiversity. New York, USA: AIP Publishing, 2023: 030021.

[17] YAO S Q, HUANG B. Spatiotemporal interpolation using graph neural network [J]. Annals of the American Association of Geographers, 2023, 113(8): 1856-1877.

[18] LI J, SHEN Y, CHEN L, et al. Rainfall spatial interpolation with graph neural networks[C]//Proceedings of International Conference on Database Systems for Advanced Applications. Berlin, Germany: Springer, 2023: 175-191.

[19] APPLEBY G, LIU L F, LIU L P. Kriging convolutional networks [J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(4): 3187-3194.

[20] WU Y K, ZHUANG D Y, LABBE A, et al. Inductive graph neural networks for spatiotemporal Kriging[J]. Proceedings

- of the AAAI Conference on Artificial Intelligence, 2021, 35(5): 4478-4485.
- [21] KLEMMER K, SAFIR N S, NEILL D B. Positional encoder graph neural networks for geographic data [C]//Proceedings of International Conference on Artificial Intelligence and Statistics. [S. l.]: PMLR, 2023: 1379-1389.
- [22] LI J, SHEN Y Y, CHEN L, et al. SSIN: self-supervised learning for rainfall spatial interpolation[J]. Proceedings of the ACM on Management of Data, 2023, 1(2): 1-21.
- [23] KIM H, MNIH A, SCHWARZ J, et al. Attentive neural processes[EB/OL]. [2024-07-02]. <https://arxiv.org/abs/1901.05761>.
- [24] ZHU X, XIONG Y T, WU M, et al. Weather2K: a multivariate spatio-temporal benchmark dataset for meteorological forecasting based on real-time observation data from ground weather stations [EB/OL]. [2024-07-02]. <https://arxiv.org/abs/2302.10493>.
- [25] KINGMA D P, BA J. Adam: a method for stochastic optimization[EB/OL]. [2024-07-02]. <https://arxiv.org/abs/1412.6980>.
- [26] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [C] // Proceedings of the 31st Annual Conference on Neural Information Processing Systems. Long Beach, USA: Curran Associates, Inc., 2017: 6000-6010.

文字编辑 金胡考

栏目编辑 赖玉玲