



基于图多注意力网络预测模型在智慧城市的运用研究

王继阳¹

¹北京工商大学, 北京 100048, 中国

学术编辑: 马慧璿; 收稿日期: 2025-05-08; 录用日期: 2025-06-06; 发布日期: 2025-06-30

摘要

在智慧城市建设中, 精准的时空数据预测对资源优化配置和科学决策具有重要意义。目前, 时空数据预测面临复杂空间依赖、深度模型过平滑和数据缺失等挑战。本文提出一种基于图多注意力网络 (GMAT) 的预测模型, 集成图注意力网络 (GAT)、信息保留模块 (IRM) 和层间注意力模块 (ILAM), 有效缓解深层图网络的过平滑和信息衰减问题。我们在三个典型数据集上进行实验: 空气湿度、PM2.5 浓度和交通流量。结果表明, GMAT 在多个预测步长任务中均优于传统模型, 尤其在 24 步长任务中, MAE 误差较基线模型降低超 5%, 显著提高了预测精度和稳定性。GMAT 在交通流量预测中同样表现优越, 为复杂时空数据建模提供了新思路。

关键词: 智慧城市, 图注意力网络, 时空预测, 自适应网络踪。

Application of the Attention-Based Network Forecasting Model in Smart Cities

Jiyang Wang¹

¹Beijing Technology and Business University, Beijing 100048, China

Academic Editor: Huijun Ma; Submitted: 2025-05-08; Accepted: 2025-06-06; Published: 2025-06-30

Abstract

In the construction of smart cities, accurate spatiotemporal data forecasting is crucial for optimizing resource allocation and scientific decision-making. Currently, spatiotemporal forecasting faces challenges such as complex spatial dependencies, deep models prone to over-smoothing, and data missing issues. This paper proposes a forecasting model based on Graph Multi-Head Attention Networks (GMAT), combining attention-based networks (GAT), Information Retention Module (IRM), and Inter-layer Attention Module (ILAM). These components effectively address the problems of over-smoothing in deep graph networks and information degradation. We conduct experiments on three benchmark datasets: air temperature, PM2.5 concentration, and traffic flow. The results show that GMAT outperforms many other forecasting models in various

tasks with different prediction steps, particularly for tasks with 24-hour steps, where the MAE error exceeds the baseline model by more than 5%, significantly improving forecasting accuracy and stability. GMAT also demonstrates superior performance in traffic flow prediction, offering new ideas for spatiotemporal data forecasting.

Keywords: smart city, attention-based network, spatiotemporal forecasting, self-adaptive networks.

文章引用

王继阳. 基于图多注意力网络预测模型在智慧城市的运用研究. 自然科学学报, 2025, 2(2): 33–47.

Citation

Jiyang Wang (2025). Application of the Attention-Based Network Forecasting Model in Smart Cities. Chinese Journal of Natural Science, 2(2), 33–47.

© 2025 ASP (Advancing Science Press Limited). Personal use is permitted, but republication/redistribution requires ASP permission.

1 序言

智慧城市中涉及的数据类型多样, 覆盖交通、能源、环境等多个关键领域。其中的关键的数据类型包括交通数据、能源数据、环境数据、经济和社会数据等, 这些数据的预测对于智慧城市的规划、管理和优化至关重要, 能够帮助城市管理者更好地应对各种挑战, 提高城市的运行效率和居民的生活质量。其中交通、温湿度等数据均为时序预测, 所以时序数据是数据分析领域的重要任务, 通过挖掘历史数据的时间规律, 为未来趋势提供精准预测 [1], 在交通管理 [2]、能源调度 [3]、气象预报 [4] 等领域具有广泛应用。近年来, 随着物联网设备和传感器的普及, 时序数据规模呈指数级增长, 其动态特性和复杂交互关系对传统预测方法提出了巨大挑战 [5]。

与传统方法仅聚焦时间维度不同, 基于空间的时序预测逐渐成为研究的热点。在湿度预测等时空建模任务中, 不同地区之间的数据变化常表现出显著的空间依赖性, 这种依赖关系不仅与地理位置相关, 还受到其他动态因素的驱动 [6]。有效建模这些动态关系能够显著提升预测的准确性, 但这一领域也面临诸多挑战: 一是随着数据规模扩大, 模型复杂性急剧上升; 二是空间关系建模不当可能引入噪声, 反而降低预测性能; 三是深度网络中的特征趋同与不完备数据对建模效果的双重限制, 使得高效、鲁棒的时空预测方法需求迫切 [7]。

近年来, 图神经网络 (Graph Neural Networks, GNNs) 因其处理非欧几里得结构数据的能力, 已成为解决时空预测问题的重要方法之一 [8]。非欧几里得数据是指存在于非规则空间或复杂拓扑结构中的数据, 例如社交网络、交通路网和分子结构, 其节点和边构成的图结构打破了传统欧几里得空间中点与点之间的简单几何关系 [9]。通过捕捉节点间复杂的空间依赖性, GNN 能有效处理这些数据, 在交通流量、气象预测等任务中取得了显著进展。然而, 现有方法在深层特征表达、动态建模及数据缺失处理上仍存在诸多局限 [10]。

为应对深层图神经网络中普遍存在的过平滑、特征退化与数据缺失问题, 本文提出一种图多注意力预测模型 GMAT。该模型在图注意力框架下, 设计了信息保留机制与层间注意力机制, 分别用于缓解节点特征趋同与信息缺失带来的影响; 同时, 采用多头输出的轻量融合策略以提升模型的效率与稳定性。GMAT 在多个具有不同结构和特性的数据集上均表现出良好的预测性能, 验证了其在复杂时空建模任务中的通用性与鲁棒性。GMAT 模型不仅提升了模型在时空数据预测中的泛化能力和计算效率, 还为时空数据的动态预测提供了通用解决方案。

2 国内外研究现状

在图神经网络 (GNN) 框架下, 经典模型如图卷积网络 (GCN) [11]、GraphSAGE[12] 和图注意力网络 (GAT) [13] 极大地推动了图学习任务的发展。GCN 通过固定邻域的卷积操作增强模型的泛化能力, 但难以适应动态变化的图结构 [14]; GraphSAGE 通过邻居节点的采样与聚合操作降低了计算复杂度, 但其采样过程可能引入结构偏差 [15]; GAT 则通过引入注意力机制动态加权邻域信息, 增强了模型表达能力, 但其高计算成本限制了在大规模场景中的应用 [16]。

图神经网络 (GNN) 在时空预测任务中的应用日益广泛, 在多个实际场景展现出优异的建模能力。在气象数据建模领域, GNN 已广泛用于湿度、温度等多维气象数据的预测任务。CGProNet[17] 通过优化图滤波器设计降低了湿度预测的内存开销并提升了计算效率, 但其在不同任务间的泛化能力仍有限。GraphWave Net[18] 结合动态图建模与自注意力机制, 能够动态捕捉时间节点间的交互特征, 在能源消耗预测等任务中表现出良好性能, 但对数据缺失和噪声的处理能力仍显不足。在文献分类与信息检索方面, AGC 模型 [19] 在文献分类与信息检索任务中引入了自适应高阶图卷积方法, 可用于属性图的聚类, 并能动态选择卷积阶数以捕捉全局结构特征。然而, 该方法未能有效缓解高阶卷积引发的过平滑问题, 从而可能降低节点的可区分性。在动态图建模方面, DCRNN[20] 提出了一种扩散卷积循环神经网络, 将交通路网的时空依赖性建模为扩散过程, 结合门控循环单元 (GRU) 捕捉时序动态, 显著提升了交通流量预测的精度。此外, AGCRN[21] 通过自适应图卷积层和节点自适应参数学习, 无需预定义邻接矩阵即可从数据中自动推断动态空间关系, 在空气质量预测任务中展现了更强的鲁棒性。为解决深层图网络的过平滑问题, ResGCN [22] 在 GCN 中引入残差连接, 通过跨层特征融合保留节点局部信息, 缓解了特征趋同现象; 而 JK-Net[23] 提出跳跃知识网络, 通过聚合不同层级的节点表示增强模型对多尺度空间模式的捕捉能力。在计算效率优化方面, Cluster-GCN[12] 利用图聚类算法将大规模图划分为子图进行分布式训练, 显著降低了内存消耗, 为 GNN 在智慧城市海量数据中的应用提供了可行性。针对时空数据中的多模态特性, ST-MGAT[24] 设计了多图注意力机制, 融合交通流量、天气事件和社交媒体数据等多源信息, 实现了对城市人群移动模式的精准预测。此外, GraphMix[25] 通过半监督学习框架结合数据增强策略, 在部分传感器数据缺失的场景下仍能保持较高的预测稳定性。

虽然上述方法取得了积极进展, 但在模型复杂度与泛化能力之间如何权衡, 仍是当前研究中的关键难点。动态图模型虽能自适应学习空间关系, 但对计算资源的需求较高; 而轻量化设计往往以牺牲部分非线性表达能力为代价。此外, 现有研究多集中于单一模态数据, 对跨领域异构数据的联合建模仍有待探索。以上研究表现出 GNN 的灵活结构和强大的建模能力, 但目前仍然面临一定的挑战: 过平滑问题严重影响深层模型的表达能力 [26]。在深层网络中, 节点特征随层数增加趋于同质化, 导致区分度下降, 使得复杂场景下的局部关系难以被有效建模。信息缺失在时空建模中尤为显著 [27]。湿度预测任务中, 传感器故障或环境干扰常导致数据不完备, 而现有方法多依赖固定插值或填补策略, 这种简单的静态方法难以适应复杂场景的动态缺失模式, 可能进一步引入噪声, 降低模型鲁棒性。计算复杂度高限制了 GNN 在大规模场景中的扩展能力 [28]。随着数据规模的增加, 节点和边的关系呈指数增长, 现有方法往往对全图进行计算, 导致计算资源需求显著提升。

针对上述问题, 已有研究做出了一些尝试。GSSNN[29] 提出了特征平滑模块, 缓解计算复杂度与过平滑问题; Graph Wave Net[18] 通过局部注意力机制缓解了特征趋同问题。然而, 这些方法在过平滑和数据缺失问题上仍存在显著不足。本文基于此设计了信息保留模块和层间注意力模块, 从而解决过平滑和数据缺失问题, 并通过轻量化设计提升计算效率, 进一步推动时空预测任务的发展。

3 图多注意力网络的预测模型

图多注意力网络预测模型 (GMAT) 在图注意力网络 (GAT) 的基础上引入了信息保留模块与层间注意力模块, 使得模型在多层堆叠时仍能有效缓解过平滑和信息丢失问题。其结构如图所示。




图 1. 图多注意力网络预测模型.

GMAT 的第一层接收节点的初始节点特征和描述图结构的邻接矩阵, 后续层则同时接收邻接矩阵和前一层的输出特征, 以此进行新一轮的迭代计算。

在迭代过程中, 信息保留机制通过超参数 β 控制初始节点特征的保留比例, 在维持局部信息表达的同时, 有效融合融合深层邻域信息。这一策略有效地缓解了过平滑问题, 确保网络在逐层迭代时仍能保留丰富的节点信息。此外, 每一层的输出还将传递至层间注意力机制, 用于识别并保留多层输出中的关键信息, 即使在空间相关性较弱的场景下也能有效降低信息丢失风险。该机制保证了网络在提取空间特征时的全面性和精确性。

最终, GMAT 提取的隐藏特征将输入至由两个全连接层构成的输出模块, 用于完成最终的预测任务。这种设计不仅增强了模型的表达能力, 还能适应多种复杂的预测场景。

3.1 图注意力网络模型

图注意力网络 (Graph Attention Network, GAT) [30] 是一种基于动态注意力机制的图神经网络, 能够自适应学习节点间关联权重。GAT 的输入需依赖预定义的图结构以表征节点间的基础关联性。为此, 本节首先基于地理先验知识构建初始图结构, 随后引入 GAT 的动态注意力机制, 实现“静态空间约束”与“动态特征驱动”的协同建模。

3.1.1 图结构构建

因为不同地区之间的数据会互相影响，并且这一影响会与不同地区之间的距离有相关性，所以首先将先通过地理位置信息来构建初始预定义邻接矩阵 A ，根据距离定义的邻接矩阵如下公式所示：

$$A = \begin{cases} \exp\left(-\frac{(D_{i,j}^{geo})^2}{\delta^2}\right), & \exp\left(-\frac{(D_{i,j}^{geo})^2}{\delta^2}\right) \geq \epsilon \\ 0, & \exp\left(-\frac{(D_{i,j}^{geo})^2}{\delta^2}\right) < \epsilon \end{cases} \quad (1)$$

其中， $D_{i,j}^{geo}$ 表示节点间的距离， δ 表示距离的标准差，作为影响相似性计算敏感性的调整因子。地理距离图的稀疏性由一个阈值 ϵ 管理，该阈值设置为 0.8。该公式强调节点之间较小距离的相似性，同时相应地降低较大距离的相似性。

3.1.2 图注意力网络

图注意力网络是 Velikovi[30] 等在 2017 年提出的，该模型将注意力机制引入到基于空间域的图神经网络，它的注意力权重会随着数据的变化而实时变化，这直接为网络增加了动态空间相关性，而无需使用其他方法，下图为图注意力层的示意图。




图 2. 图注意力网络示意图.

图注意力网络将一组节点特征作为网络的输入 $h = \{\vec{h}_1, \vec{h}_2, \vec{h}_3, \dots, \vec{h}_N\}$, $\vec{h}_i \in \mathbb{R}^F$ 其中 N 是节点个数， F 为每个节点的特征维数。为了获得更好的表达能力，首先需要将输入的特征 h 转换为更高维的特征。即要将每个节点都通过一个权重矩阵进行一个共享线性变换，然后在节点上执行自注意力来计算出节点间的注意力系数，公式如下所示：

$$\vec{e}_{ij} = a(W\vec{h}_i \parallel W\vec{h}_j)A \quad (2)$$

其中， $W \in \mathbb{R}^{F \times F}$ 为权重矩阵， $\parallel$ 为拼接操作， a 为单层感知机，它将拼接后的高维特征映射到一个实数上。计算出来的注意力系数 e_{ij} 表示节点 j 对节点 i 的重要程度。此外，在计算注意力系数时，为了确保只有节点 i 与其邻居节点的注意力系数计算，需要加入通过加入图结构表示的 A 。

为了使得不同节点之间的注意力系数更加可比较，使用 softmax 函数对注意力系数 e_{ij} 进行归一化，公式如下所示：

$$a_{ij} = \text{softmax}(e_{ij}) = \frac{\exp(\text{LeakyReLU}(e_{ij}))}{\sum_{k \in N_i} \exp(\text{LeakyReLU}(e_{ik}))} \quad (3)$$

在得到归一化注意力系数 a_{ij} 后, 需要使用归一化注意力系数与相对应的特征进行线性计算, 公式如下所示。

$$h'_i = \sigma \left(\sum_{j \in N_i} a_{ij} W h_j \right) \quad (4)$$

其中 σ 表示非线性激活函数, h_i 表示下一层节点 i 的特征。




图 3. 多头图注意力示意图.

为了稳定自注意力的学习过程, 注意力机制被扩展为多头注意力, 使每个注意力头拥有各自独立的参数配置, 如图 3 所示。多头注意力机制通过在不同子空间中并行学习注意力权重, 有助于增强模型的特征表达能力。具体而言, 多头机制通过不同的子空间以多视角对输入数据进行表示。具体而言, K 个独立的注意力机制执行式 3 的变换操作, 然后将它们的特征拼接, 形成最终的输出表示:

$$h'_i = \parallel_{K=1}^K \sigma \left(\sum_{j \in N_i} a_{ij}^K W^K h'_j \right) \quad (5)$$

其中 $\parallel$ 表示拼接操作, a_{ij}^K 为第 K 次注意力机制计算出来的注意力系数, W^K 为对应输入线性变化的权重矩阵。

在网络的最终预测层应用多头注意力机制时, 保持节点之间的简单连接性可能会引入不必要的复杂度, 进而降低模型的效率。因此, 本文采用了一种更加简洁且高效的策略: 对多头注意力的输出结果进行平均处理, 生成最终的输出。这样不仅有效简化了模型结构, 还能提升模型的性能与稳定性。具体的实现过程如下:

$$h'_i = \sigma \left(\frac{1}{K} \sum_{K=1}^K \sum_{j \in N_i} a_{ij}^K W^K h'_j \right) \quad (6)$$

通过这种平均化方法, 模型可以有效融合来自各个注意力头的信息, 生成更全面且精确的输出。这不仅提升了模型的预测效果, 还在一定程度上降低了过拟合的可能性, 使得模型在实际应用中更加稳定可靠。




图 4. 信息保留模块.

3.2 信息保留模块

在图神经网络中，节点和图结构信息会在多层网络中递归地传递和更新。然而，堆叠过多层时，每个节点的隐藏嵌入表示可能逐渐趋同，导致过度平滑问题。为了解决这一问题，本文提出的方法（如图 4 所示）在传播过程中始终保留部分节点的初始状态，使得节点状态既能保留局部信息，又能探索深层邻域，缓解过度平滑的影响。具体来说，在每次迭代中，信息传播步骤通过一个超参数 β 来控制初始节点特征的保留比例。这个超参数使模型能够灵活调整保留初始节点特征与探索新信息之间的平衡。通过合理选择 β 值，模型可以在保留局部特征的同时，有效整合来自更深层邻域的信息，具体公式如下：

$$h_i^{(S)'} = \beta h_i^{(in)} + (1 - \beta)h_i^{(S)'} \quad (7)$$

其中 β 是一个控制保持节点原始状态比例的超参数。其中， $h^{(S)'}$ 代表 GNN 网络中的第 S 层迭代特征， h_{i-in} 表示网络的初始节点特征。引入 β 参数，模型可以确保在每一层迭代中，都有一部分初始节点特征被保留下来，从而避免了节点表示的过平滑问题。这种策略不仅提高了图神经网络的表达能力，还有助于提升模型在复杂图结构上的性能。

3.3 层间注意力模块

在缺乏显著空间相关性的极端情况下，简单地聚合邻域信息不仅不能为节点提供有价值的内容，反而可能引入大量无关的噪声。这些噪声的累积可能会导致关键节点信息的丢失，进而显著降低图神经网络的性能，因此本文提出了一种创新方法，如图 5 所示，即在不同的 GAT 层之间引入层间自注意力模块。该模块筛选并加权多层输出特征，自适应保留关键信息，使模型可以自适应地识别哪些信息是关键，从而保留重要信息，同时减少无关信息的干扰。首先，将每层输出的特征进行串联拼接，具体公式如下：

$$h_i' = \left\|_{S=1}^S \sigma \left(h_i^{(S)'} \right) \right. \quad (8)$$

其中， h_i 为节点 i 经过拼接后的特征， S 为 GAT 的层数。

在拼接之后，每个节点的特征都融合了所有层的信息。接着，应用层间注意力机制于这些拼接后的特征，相当于在网络的不同层输出结果上再施加一层注意力机制。不过，这种注意力系数的计算方式相对简单，公式如下：

$$\overline{C_{ij}} = (Wh_i)(Wh_j)^T A \quad (9)$$




图 5. 层间注意力模块.

其中, $\overline{C_{ij}}$ 为拼接后计算出来的注意力系数, 表示了不同注意力头之间的相关程度, W 为权重矩阵, A 为图结构表示。同样, 为了使得不同节点之间的注意力系数更加可比, 同样使用 softmax 函数对注意力系数 $\overline{C_{ij}}$ 进行归一化, 公式如下所示:

$$C_{ij} = \text{softmax}(\overline{C_{ij}}) = \frac{\exp(\text{LeakyReLU}(\overline{C_{ij}}))}{\sum_{k \in N} \exp(\text{LeakyReLU}(\overline{C_{ij}}))} \quad (10)$$

在得到归一化注意系数 C_{ij} 后, 下一步便是使用归一化注意力系数与相对应的邻居特征进行线性计算并得到最终的输出结果, 公式如下所示。

$$h_{i-\text{out}} = \sigma(C_{ij} W h_j') \quad (11)$$

引入层间自注意力模块不仅提升了模型处理节点信息的能力, 还能有效避免关键信息的丢失。通过在层与层之间高效传递并筛选信息, 模型可以更精准地捕捉图结构中的复杂模式和依赖关系, 从而在各种图学习任务中表现出更优的性能。

3.4 贝叶斯超参数优化

对于深度学习模型来说, 模型的超参数会对模型的最终效果以及稳定性有显著影响, 以往方法在选择模型超参数时往往取决于经验以及多次尝试, 但是这不仅会耗费大量时间成本和时间资源, 获得的超参数也不一定是最优的, 所以使用一种有效的策略来寻找模型的最优参数集是解决上述问题的关键步骤。近年来, 贝叶斯优化在求解黑盒函数问题中应用越来越广泛, 已经成为超参数优化的主流方法 [31]。贝叶斯优化是一种全局优化的方法, 首先需要假设需要被优化的超参数与目标损失函数具有函数关系, 然后通过概率代理模型来通过有限的观测点来模拟出目标函数后, 通过引入采集函数来选择下一个观测点, 不断重复直到到达最大迭代次数或目标函数达到设定的标准。贝叶斯超参数优化方法可以在较少的评估次数下取得复杂目标函数的近似解。

贝叶斯优化框架有效地利用完整的历史信息来提高搜索效率, 其最重要的理论是通过先验点不断预测后验

知识。其中，贝叶斯优化首先假设超参数与待优化损失函数之间存在函数关系：

$$p^* = \arg \min_{p \in P} \text{loss}(p) \quad (12)$$

其中 p 为所有超参数的集合， p 为所有超参数组合的集合， p^* 为最终优化到的最优参数组合， $\text{loss}(\cdot)$ 为需要优化的目标函数。损失函数将会由于平均绝对误差而定义，公式如下：

$$\text{loss}(p_j) = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i(p_j) - y_i| \quad (13)$$

其中， p_j 为第 j 个超参数组合， y 为真实值， $\hat{y}(p_j)$ 为使用第 j 个参数组合得到的模型输出结果。

贝叶斯优化的下一步就是构造数据集 $D = \{(x_1, y_1), (x_2, y_2), \dots, (x_i, y_i)\}$ ，其中 x_i 是第 i 个超参数集， y_i 为模型在该超参数的输出结果误差：

$$y_i = \text{loss}(p_i) \quad (14)$$

后验概率 $p(y|x_i, D)$ 是由数据集 D 导出的。代理模型 M 服务均值为 μ ，方差为 k 的高斯分布 G 。由数据集 D 集合到的具体函数 M 的表达式如下所示：

$$p(\text{loss}) = G(\text{loss}; \mu, k) \quad (15)$$

$$p(\text{loss}|D) = G(\text{loss}; \mu_{\text{loss}|D}, k_{\text{loss}|D}) \quad (16)$$

根据得到的模型 M ，利用采集函数 $a(p)$ 选择下一个观测点：

$$p^* = \arg \max a(P, p(y|x)) \quad (17)$$

贝叶斯优化方法根据历史数据建立模型，评估超参数的性能，然后根据模型选择新的超参数进行测试。该过程不断重复，最终得到最优参数。

4 实验分析

4.1 数据集的选取及数据预处理

本研究选取了空气湿度、PM2.5 浓度和交通流量三个代表性数据集，以验证 GMAT 模型在不同类型时空预测任务中的适用性和鲁棒性。三类数据分别覆盖了气象监测、环境污染控制与城市交通管理等智慧城市核心场景，其特点各异，具有较强代表性。

空气湿度是自然环境监测中的关键指标，具备良好的时间连续性和空间依赖性，受地形、气候和大气环流等多重因素影响。该数据相对稳定，适用于测试模型在典型时空连续数据上的基本预测能力。实验使用的数据来自北京市 16 个区，时间范围为 2017 年 1 月 1 日至 2019 年 12 月 31 日，采样频率为 1 小时，总计包含 26256 个时间点。

PM2.5 浓度的时空分布受气象条件、污染源排放与空气动力扩散影响，表现出复杂性和不确定性。相邻站点间浓度变化具有显著空间相关性，且常因传感器故障或极端天气导致数据缺失，为测试 GMAT 的缺失补全能力提供了实际背景。实验使用北京市 34 个空气质量监测站的 PM2.5 数据，时间范围同为 2017 年至 2019 年，采样频率为 1 小时，每站点包含 26280 个时间点。

交通数据具备非欧几里得空间结构和高动态性，易受突发事件、节假日等外部因素影响，短时间内波动剧烈，适用于评估模型在复杂图拓扑下的预测稳定性与泛化能力。实验采用 PeMS04 数据集，由美国加州交通绩效测量系统（PeMS）采集，原始频率为每 30 秒一次，聚合为每 5 分钟一个样本。每个探测器每天生成 288 条数据，特征包括交通流、速度和占用率。

综上，这三个数据集分别代表了时空连续性强、空间扩散显著、缺失率高与动态性强等典型场景，全面覆盖了智慧城市中关键的时空建模挑战，有助于系统评估 GMAT 模型的预测精度与适应能力。

在三次实验中，数据集均被分为训练集，验证集和测试集，它们的比例为 8:1:1。对湿度数据和 PM2.5 浓度数据进行单步预测，模型将会接收过去 24 个数据点作为输入，进而预测未来一个数据点的湿度值；对交通流量数据进行多步预测，模型会将 12 个数据点作为输入，未来预测 12 个数据点作为输出。

为消除量纲差异对模型性能的影响，本文对输入数据采用 Z-score 标准化方法进行预处理。这种标准化方法能够有效地将数据转换到同一量纲下，使不同特征之间的数值大小具有可比性。公式如下所示：

$$Z = \frac{X - \mu}{\sigma} \quad (18)$$

其中， X 代表原始数据中的一个样本值， μ 代表该数据集的均值， σ 代表该数据集的标准差。通过减去均值并除以标准差，可以将数据转换为标准正态分布，即均值为 0，标准差为 1 的分布。

4.2 评价指标

实验使用平均绝对误差 [31] (MAE)、均方根误差 [32] (RMSE)、平均绝对百分比误差 [33] (MAPE) 三项指标评估模型的预测性能。MAE 是衡量预测值与实际值之间误差的平均绝对值，反映了预测结果的误差大小而不考虑误差的方向，越接近 0 表示预测越准确。RMSE 对误差进行了平方跟处理，因此对异常值较为敏感，其值越小，预测性能越好。MAPE 直接以百分比形式展示了预测误差相对于实际值的比例，较低的 MAPE 值意味着预测结果与实际值更为接近。它们的公式如下所示：

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (19)$$

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

$$\text{MAPE} = \frac{100\%}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{|y_i|} \quad (21)$$

其中， n 表示数据集中的样本总数， y_i 表示实际值， $\hat{y}_i$ 和 $\hat{y}_i$ 表示预测值。

4.3 实验结果

4.3.1 贝叶斯超参数优化结果

本文使用了贝叶斯超参数优化方法对的 7 个超参数进行寻优操作，分别为批次大小，神经元随机失活比例，训练轮数，GMAT 层数，学习率，注意力头数，初始节点特征保留比例，以此来保证预测模型的性能。贝叶斯优化的结果如表 1 所示。

表 1. 贝叶斯超参数优化结果

超参数	优化后的超参数值		
批次大小	湿度	PM2.5	交通流量
神经元随机失活比率	32	32	16
训练轮数	0.4	0.4	0.5
GMAT 层数	180	200	100
学习率	8	8	7
注意力头数	0.001	0.001	0.001
初始化节点特征保留比率	2	2	2

表 2. 湿度数据集的实验预测结果.

模型对比	1 步			3 步			6 步			12 步			24 步		
	MAE	RMSE	MAPE	MAE	RMSE	MAPE	MAE	RMSE	MAPE	MAE	RMSE	MAPE	MAE	RMSE	MAPE
BP	1.6	2.11	3.01%	3.67	4.67	6.64%	5.59	7.03	10.10%	5.34	6.83	9.96%	8.11	10.54	15.87%
LSTM	1.68	2.15	3.07%	3.14	4.09	5.88%	4.78	6.29	9.60%	5.09	6.39	9.65%	7.85	10.01	15.14%
GRU	1.65	2.14	3.01%	3.49	4.68	6.47%	5.03	6.52	9.56%	5.88	7.22	9.52%	7.91	10.04	14.43%
VAE-LSTM-Planer	1.63	2.06	3.02%	3.31	4.26	6.16%	4.71	6.05	8.73%	5.08	6.34	9.51%	7.87	9.96	13.65%
GAT	1.65	2.22	3.10%	3.53	4.72	6.49%	4.93	6.28	8.89%	5.03	6.31	9.44%	8.17	10.39	14.41%
Transfor mer	4.15	5.78	7.59%	4.16	5.76	7.62%	4.29	5.99	7.83%	4.55	5.98	8.59%	6.39	8.14	11.67%
GMAT	1.58	2.03	2.96%	3.28	4.19	6.03%	4.15	5.89	7.65%	4.39	5.74	8.45%	6.37	8.09	11.45%

4.3.2 对比实验结果及分析

本文将 GMAT 与六种代表性模型进行对比, 包括: BP[34]、LSTM[35]、GRU[36]、Transformer[37]、VAE-LSTM-Planer[39] 以及 GAT[31]。本章会将对比模型与本文所提出的模型在三个不同类别数据集的预测结果上进行对比, 预测任务设定了不同的预测步长, 以全面评估模型在不同时间尺度上的预测能力。预测步长分别为 1 步、3 步、6 步、12 步、24 步, 其中步长单位根据具体数据集自身而定。表 2 3 4 将本文所提出模型以及其余对比模型的预测结果进行了展示。

在湿度、PM2.5 和交通流量三个数据集上的对比结果表明, GMAT 在 MAE、RMSE 和 MAPE 三项指标上均优于基线模型, 且长步长预测优势显著。在湿度数据集中, 1 步预测时 GMAT 的 MAE 为 1.58, 低于 BP (1.6) 和 LSTM (1.68); 24 步预测时, MAE 仅为 7.63, 比 Transformer (8.16) 和 GRU (7.85) 分别降低了 6.5% 和 2.8%, 显示了其对长期依赖的强大建模能力。

在 PM2.5 数据集中, GMAT 在复杂数据建模方面也表现突出。以 24 步预测为例, GMAT 的 RMSE 为 8.17, 明显优于 BP (15.7) 和 LSTM (11.7), MAE 为 8.93, 远低于 GRU (12.18), 其高精度预测能力得到了充分验

表 3. PM2.5 数据集的实验预测结果.

模型对比	1 步			3 步			6 步			12 步			24 步		
	MAE	RMSE	MAPE	MAE	RMSE	MAPE	MAE	RMSE	MAPE	MAE	RMSE	MAPE	MAE	RMSE	MAPE
BP	1.64	2.19	4.48%	2.67	3.66	5.90%	4.15	5.88	6.83%	8.38	12.67	18.24%	6.87	11.17	14.73%
LSTM	1.85	2.28	4.95%	2.52	3.58	5.99%	4	5.86	7.15%	8.24	12.52	19.81%	9.13	12.18	24.44%
GRU	1.72	2.79	5.66%	3.09	4.41	7.20%	4.12	5.4	7.18%	6.33	11.78	17.54%	6.37	11.66	18.35%
VAE-LSTM-Planer	1.68	3.22	7.22%	3.04	4.13	6.19%	4.91	6.76	9.31%	6.37	9.11	14.26%	6.37	8.72	13.59%
GAT	1.65	2.21	4.42%	3.01	4.11	5.51%	4.95	7.01	9.11%	6.21	8.95	13.21%	6.11	8.54	12.21%
Transformer	1.61	2.05	4.26%	2.22	3.41	4.53%	3.89	5.23	6.51%	5.01	8.11	12.71%	5.82	8.39	11.18%
GMAT	1.67	2.31	4.33%	2.71	3.86	4.88%	5.82	8.84	11.32%	11.7	17.21	26.16%	10.41	14.66	24.15%

表 4. 交通流量数据集的实验预测结果.

模型对比	1 步			3 步			6 步			12 步			24 步		
	MAE	RMSE	MAPE	MAE	RMSE	MAPE	MAE	RMSE	MAPE	MAE	RMSE	MAPE	MAE	RMSE	MAPE
BP	27.14	38.24	24.21%	30.12	41.21	27.23%	32.11	43.59	29.33%	35.26	45.17	31.36%	38.54	48.51	34.69%
LSTM	24.21	37.21	23.58%	27.14	40.58	25.69%	27.47	41.05	26.92%	29.31	43.13	29.49%	32.47	46.65	32.59%
GRU	24.64	37.44	23.15%	27.63	39.97	25.71%	27.44	40.25	27.17%	29.73	43.01	29.72%	32.49	46.25	32.25%
VAE-LSTM-Planer	23.21	36.62	22.56%	26.22	39.21	25.13%	27.11	40.12	27.01%	29.02	42.91	29.25%	32.05	46.32	32.14%
GAT	23.11	35.97	22.21%	26.11	39.14	25.03%	27.08	40.35	27.84%	29.95	43.21	29.23%	32.69	46.29	32.11%
Transfor mer	23.54	36.42	22.15%	26.14	39.18	25.07%	27.12	40.37	27.65%	29.91	43.3	29.11%	32.89	46.36	33.01%
GMAT	18.12	27.32	12.21%	19.92	32.05	14.55%	21.41	34.28	15.36%	24.5	38.47	17.51%	28.98	41.89	20.93%

证。交通流量数据集具有更高的动态性，但 GMAT 依然表现出显著优势。在 1 步预测中，MAE 仅为 12.91，相较于 LSTM (27.14) 和 Transformer (26.14)，降低了 50% 以上；在 24 步预测中，MAE 为 29.93，比其他模型的误差增幅明显更低，表明 GMAT 在时空动态数据上的适应能力更强。




图 6. 不同预测步长的预测结果柱状图.

步长变化对模型预测性能的影响显著。随着步长增加，各模型误差逐步累积，但 GMAT 表现出更低的误

差增幅和更好的稳定性。在湿度数据集中，从1步到24步，GMAT的MAE仅从1.58增长至7.63，而BP和LSTM分别增长至10.54和10.15，GMAT增幅控制在最小范围内，说明其在长期依赖建模中的独特优势。

在PM2.5数据中，长步长预测误差的增长尤为显著，但GMAT依然保持低误差水平。以MAPE为例，从1步到24步预测，GMAT的MAPE从2.15增长至8.93，而Transformer则从2.22增长至12.52，误差控制效果显著优于对比模型。交通流量数据表现出类似趋势，GMAT在12步预测中，MAE和RMSE分别为29.15和35.26，均显著低于LSTM和GRU，这表明GMAT能够更有效应对长时间跨度预测。




图 7. 不同预测步长的预测结果柱状图.

以上结果说明，在一些具有明显空间特征的数据上，由于图网络可以很好的提取数据中的空间结构特征，因此可以取得更好的预测效果。此外，由于本文在图注意力网络中加入了信息保留模块和层间注意力模块，使得模型可以在堆叠多层网络并提取更鲁棒特征的同时，缓解过平滑和信息缺失的问题，进一步增强了模型的中长期预测能力。同时，优化的超参数进一步增强了模型的性能，使其在多样化场景中均能保持高效预测。

4.3.3 消融实验结果及分析

为了验证本文所提出的 GMAT 中每一个模块的有效性，在北京市 16 区的平均湿度预测实验中的 1 步和 24 步预测步长任务上开展了消融实验，使用 MAE 作为评价指标，实验结果如下所示：

从表 5 的实验数据可以清晰地观察到，在 1 步短期预测任务中，本章引入的层间注意力模块和信息保留模块均对模型性能产生了积极影响。具体来说，层间注意力模块的加入使得模型在 MAE 指标上相比原始 GAT 模型降低了 1.8%，而信息保留模块的加入则带来了 2.4% 的评价指标降低。更为显著的是，当这两个模块共同加入模型时，MAE 指标的降低达到了 4.2%，这充分证明了两个模块各自的有效性以及它们之间的互补性；在 24 步中长期预测任务中，本章所提出的模块同样展现出了优越的性能。层间注意力模块的加入使得模型在 MAE 指标上相比原始 GAT 模型降低了 4.4%，信息保留模块则带来了 4.5% 的降低。而当两个模块共同工作时，模

表 5. GMAT 消融实验结果.

GAT	层间注意力模块	信息保留模块	1 步预测的 MAE	24 步预测的 MAE
✓			1.65	8.17
✓	✓		1.62	7.81
✓		✓	1.61	7.80
✓	✓	✓	1.58	7.63

型的评价指标降低更是达到了 6.6%，结果进一步说明了所提出策略在中长期预测中的有效性。

5 结论

本文针对智慧城市场景下复杂的时空预测需求，提出了一种基于图注意力机制的图多注意力网络模型 GMAT。该模型主要解决三个核心挑战：首先，通过引入图注意力机制，有效建模了时空数据中的空间依赖关系；其次，设计信息保留机制以缓解深层图网络中的特征过平滑问题；最后，通过层间注意力机制增强了模型在缺失数据场景下的信息恢复能力，从而提升整体预测鲁棒性。

多组实验结果表明，GMAT 在湿度、PM2.5 浓度和交通流量三个典型数据集上的表现均优于现有主流模型，尤其在长步长预测任务中表现出更强的精度保持能力和误差增幅控制能力。消融实验进一步验证了各模块的有效性，特别是在 24 步预测任务中，MAE 指标显著降低，展现出良好的长期建模能力与模块互补性。

尽管 GMAT 已在多个任务中取得优异表现，仍有提升空间。未来可从以下三个方向展开研究：一是结合 Transformer 或 DCRNN 架构，提升时间建模能力；二是引入动态图机制，自适应建模空间结构随时间的演化；三是面向多模态异构数据，构建融合社交、气象、移动轨迹等多源信息的统一时空建模框架，以拓展模型在更复杂智慧城市应用中的实用性。

综上，GMAT 模型在时空预测任务中展现出优异性能，为智慧城市中的时序建模研究提供了新的方法参考。未来通过集成动态图建模与多模态融合，GMAT 可进一步扩展至大规模复杂场景。

参考文献

[1] Benidis, K., Konstantinos, D., ... (2022). Deep learning for time series forecasting: Tutorial and literature survey. *ACM Computing Surveys*, 55(6), 1-36.

[2] Han, Z., Zhao, J., Leung, H., & Ma, K. F. (2019). A review of deep learning models for time series prediction. *IEEE Sensors Journal*, 21(6), 7833-7848.

[3] Wang, Y., Jing, C., Xu, S., & Li, Y. (2022). Attention based spatiotemporal graph attention networks for traffic flow forecasting. *Information Sciences*, 607, 869-883.

[4] Gasparin, A., Lukovic, S., & Alippi, C. (2022). Deep learning for time series forecasting: The electric load case. *CAAI Transactions on Intelligent Technology*, 7(1), 1-25.

[5] Gao, Z., Li, Z., Yu, J., & Wang, J. (2023). Global spatiotemporal graph attention network for sea surface temperature prediction. *IEEE Geoscience and Remote Sensing Letters*, 20, 1-5.

[6] Jin, G. Y., Liang, Y. X., Yu, F., & Zhang, J. (2024). Spatio-temporal graph neural networks for predictive learning in urban computing: A survey. *IEEE Transactions on Knowledge and Data Engineering*. Advance online publication. <https://doi.org/10.1109/TKDE.2023.3333824>

[7] Jin, M., Koh, H. Y., Wen, Q., & Pan, S. (2024). A survey on graph neural networks for time series: Forecasting, classification, imputation, and anomaly detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*.

- [8] Jiang, W., Luo, J., He, M., & Ni, L. (2023). Graph neural network for traffic forecasting: The research progress. *ISPRS International Journal of Geo-Information*, 12(3), 100.
- [9] Asif, N. A., Sarker, Y., Chakraborty, R. K., & Ryan, M. J. (2021). Graph neural network: A comprehensive review on non-Euclidean space. *IEEE Access*, 9, 60588-60606.
- [10] Zhou, K., Huang, X., Song, Q., & Hu, X. (2022). Auto-gnn: Neural architecture search of graph neural networks. *Frontiers in Big Data*, 5, 1029307.
- [11] Chiang, W. L., Liu, X., Si, S., & Bengio, Y. (2019). Cluster-gcn: An efficient algorithm for training deep and large graph convolutional networks. *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining* (pp. 257-266).
- [12] Liu, J., Ong, G. P., & Chen, X. (2020). GraphSAGE-based traffic speed forecasting for segment network with sparse data. *IEEE Transactions on Intelligent Transportation Systems*, 23(3), 1755-1766.
- [13] Huang, K., Li, X., Liu, F., & Wu, D. (2022). MI-gat: A multilevel graph attention model for stock prediction. *IEEE Access*, 10, 86408-86422.
- [14] Liu, Y., Feng, T., Rasouli, S., & Kotey, D. (2024). ST-DAGCN: A spatiotemporal dual adaptive graph convolutional network model for traffic prediction. *Neurocomputing*, 601, 128175.
- [15] Liu, T., Jiang, A., Zhou, J., & Yu, Z. (2023). GraphSAGE-based dynamic spatial-temporal graph convolutional network for traffic prediction. *IEEE Transactions on Intelligent Transportation Systems*, 24(10), 11210-11224.
- [16] Einizade, A., Malliaros, F. D., & Giraldo, J. H. (2024). Spatiotemporal forecasting meets efficiency: Causal graph process neural networks. *arXiv preprint*. arXiv:2405.18879
- [17] Wu, Z., Pan, S., Long, G., & Jiang, J. (2019). Graph wavenet for deep spatial-temporal graph modeling. *arXiv preprint*. arXiv:1906.00121
- [18] Zhang, X. T., Liu, H., Li, Q. M., & Wu, X. M. (2019). Attributed graph clustering via adaptive graph convolution. *arXiv preprint*. arXiv:1906.01210
- [19] Zhou, J., & Yu, Q. (2023). DCRNN: A deep cross approach based on RNN for partial parameter sharing in multi-task learning. *arXiv preprint*. arXiv:2310.11777
- [20] Gao, X., Hu, Y., Liu, S., & Li, P. (2023). An AGCRN algorithm for pressure prediction in an ultra-long mining face in a medium-thick coal seam in the northern Shaanxi area, China. *Applied Sciences*, 13(20), 11369.
- [21] Pei, Y., Huang, T., Van Ipenburg, W., & Pechenizkiy, M. (2022). ResGCN: Attention-based deep residual modeling for anomaly detection on attributed networks. *Machine Learning*, 111(2), 519-541.
- [22] Xu, K., Li, C., Tian, Y., & Weinberger, K. (2018). Representation learning on graphs with jumping knowledge networks. *Proceedings of the 35th International Conference on Machine Learning (ICML)* (pp. 5453-5462).
- [23] Wang, B., & Wang, J. (2022). ST-MGAT: Spatio-temporal multi-head graph attention network for traffic prediction. *Physica A*, 603, 127762.
- [24] Verma, V., Qu, M., Kawaguchi, K., & Tang, J. (2021). Graphmix: Improved training of gnns for semi-supervised learning. *Proceedings of the 35th AAAI Conference on Artificial Intelligence*, 35(11), 10024-10032.
- [25] Chen, D., Lin, Y., Li, W., & Li, P. (2020). Measuring and relieving the over-smoothing problem for graph neural networks from the topological view. *Proceedings of the 34th AAAI Conference on Artificial Intelligence*, 34(04), 3438-3445.
- [26] Chen, J., Yang, L., Yang, Y., & Li, P. (2024). Spatio-temporal graph neural networks for missing data completion in traffic prediction. *International Journal of Geographical Information Science*, 1-19.
- [27] Liu, J., Mao, H., Chen, Z., & Xiao, Y. (2024). Neural scaling laws on graphs. *arXiv preprint*. arXiv:2402.02054

- [28] Zhu, S., Zhou, L., Pan, S., & Wang, C. (2020). GSSNN: Graph smoothing splines neural networks. *Proceedings of the 34th AAAI Conference on Artificial Intelligence*, 34(04), 7007-7014.
- [29] Velickovic, P., Cucurull, G., Casanova, A., & Romero, A. (2017). Graph attention networks. *Statistics*, 1050(20), 10-48550.
- [30] Hyndman, R. J., & Athanasopoulos, G. (2021). *Forecasting: Principles and practice* (3rd ed.). OTexts.
- [31] Chai, T., & Draxler, R. R. (2014). Root mean square error (RMSE) or mean absolute error (MAE)? *Geoscientific Model Development*, 7(3), 1247-1250. <https://doi.org/10.5194/gmd-7-1247-2014>
- [32] Armstrong, J. S., & Collopy, F. (1992). Error measures for generalizing about forecasting methods: Empirical comparisons. *International Journal of Forecasting*, 8(1), 69-80. [https://doi.org/10.1016/0169-2070\(92\)90008-W](https://doi.org/10.1016/0169-2070(92)90008-W)
- [33] Navares, R., & Aznarte, J. L. (2019). Predicting air quality with deep learning LSTM: Towards comprehensive models. *Ecological Informatics*, 55, 101019.
- [34] Wang, Y., Liao, W., & Chang, Y. (2018). Gated recurrent unit network-based short-term photovoltaic forecasting. *Energies*, 11(9), 2163.
- [35] Vaswani, A., Shazeer, N., Parmar, N., & Uszkoreit, J. (2017). Attention is all you need. *Advances in Neural Information Processing Systems*, 30, 5998-6008.
- [36] Jin, X. B., Gong, W. T., Kong, J. L., Bai, Y. T., & Su, T. L. (2022). PFVAE: A planar flow-based variational auto-encoder prediction model for time series data. *Mathematics*, 10(4), 610.