

基于大语言模型的时空数据零样本插补

梅雅欣^{1,2}, 秦慧玲¹, 梁玉珠¹, 张广学¹, 王田^{1*}

(1. 北京师范大学人工智能与未来网络研究院, 广东珠海 519087; 2. 北京师范大学人工智能学院, 北京 100875)

摘要: 物联网感知数据由于部署成本、环境约束、设备故障等多重因素普遍存在数据稀疏问题, 严重制约智能感知系统的整体性能。现有插补方法大多依赖标注数据进行监督训练, 在面对新场景“冷启动”时泛化能力严重不足, 难以满足物联网快速部署和跨域应用的实际需求。本文首次将大语言模型的内在推理能力引入时空数据插补领域, 提出了基于多智能体协同推理的ZeroImpute框架, 实现了从传统“数据驱动学习”向“知识驱动推理”的范式转换。该方法构建了由专门化任务的大语言模型智能体组成的协同推理系统: 时序分析智能体负责复杂时间依赖关系的语义理解与推理, 通过双向序列建模捕获前向演化趋势和后向约束条件; 空间分析智能体专注于动态空间关系的建模与解析, 基于时序上下文指导实现时变空间相关性的精准识别; 插补决策智能体整合多源语义知识, 运用自适应权重融合算法完成最终的智能插补决策。各智能体通过语义化的知识表达与逻辑推理实现对复杂时空模式的深度理解, 将传统的数值计算问题转化为多智能体可协同处理的语义推理任务, 突破了单一模型处理复杂时空关系的局限性。该框架具备一定的技术优势: 首先, 实现了真正的零样本泛化能力, 无需任何领域特定的训练数据即可直接部署; 其次, 通过多智能体分工, 提升了复杂时空模式的识别精度和推理质量; 再次, 具备良好的可解释性, 智能体推理过程透明化, 增强了系统的可信度; 最后, 即插即用部署大幅降低了实际应用的技术门槛和部署成本。在三个真实物联网数据集的综合评测中, ZeroImpute在完全零样本、零训练的严格设置下相比最优的专用深度学习模型在平均绝对误差MAE (Mean Absolute Error) 指标上实现了至少4.5%的性能提升。此外, 该方法在不同缺失率场景下均展现出鲁棒性, 能够有效解决新部署区域快速上线、跨域数据插补泛化以及资源受限环境高效部署等关键实际问题。本研究开辟了多智能体协同推理的时空计算新范式, 为时空数据插补领域提供了全新的技术路径, 为推动物联网技术在更广泛领域的产业化应用提供了关键的技术支撑和理论基础。

关键词: 物联网感知; 数据稀疏; 冷启动; 时空数据插补; 大语言模型; 零样本

基金项目: 国家自然科学基金(No.62372047); 北京市自然科学基金(No.4232028); 珠海市产学研项目(No.2220004002686, No.2320004002812); 珠海市基础与应用共础课题研究项目(No.2220004002619); 珠海市社会发展领域科技计划项目(No.2320004000213)

中图分类号: TP399 **文献标识码:** A **文章编号:** 0372-2112(2025)09-3047-13

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.12263/DZXB.20250473

LLM-Based Zero-Shot Imputation of Spatiotemporal Data

MEI Ya-xin^{1,2}, QIN Hui-ling¹, LIANG Yu-zhu¹, ZHANG Guang-xue¹, WANG Tian^{1*}

(1. Institute of Artificial Intelligence and Future Networks, Beijing Normal University, Zhuhai, Guangdong 519087, China;

2. School of Artificial Intelligence, Beijing Normal University, Beijing 100875, China)

Abstract: Internet of things (IoT) sensing data commonly suffers from data sparsity issues due to multiple factors including deployment costs, environmental constraints, and equipment failures, severely limiting the overall performance of intelligent sensing systems. Most existing imputation methods rely on labeled data for supervised training, resulting in severely insufficient generalization capabilities when facing “cold start” scenarios in new environments, failing to meet the practical demands of rapid IoT deployment and cross-domain applications. This paper introduces, for the first time, the intrinsic reasoning capabilities of large language models (LLM) into the spatiotemporal data imputation domain, proposing the ZeroImpute framework based on multi-agent collaborative reasoning that achieves a paradigmatic shift from traditional “data-driven learning” to “knowledge-driven reasoning.” The core innovation of this method lies in constructing a collaborative reasoning system comprising specialized task-oriented LLM agents: the temporal analysis agent is responsible for se-

semantic understanding and reasoning of complex temporal dependencies, capturing forward evolutionary trends and backward constraint conditions through bidirectional sequence modeling; the spatial analysis agent focuses on modeling and parsing dynamic spatial relationships, achieving precise identification of time-varying spatial correlations through temporal context guidance; the imputation decision agent integrates multi-source semantic knowledge and employs adaptive weight fusion algorithms to complete final intelligent imputation decisions. Each agent achieves deep understanding of complex spatiotemporal patterns through semantic knowledge representation and logical reasoning, transforming traditional numerical computation problems into semantic reasoning tasks that can be collaboratively processed by multiple agents, thereby overcoming the limitations of single models in handling complex spatiotemporal relationships. The framework possesses significant technical advantages: first, it achieves true zero-shot generalization capability, enabling direct deployment without requiring any domain-specific training data; second, through multi-agent specialization, it enhances the identification accuracy and reasoning quality of complex spatiotemporal patterns; third, it exhibits excellent interpretability with transparent agent reasoning processes, enhancing system trustworthiness; finally, plug-and-play deployment substantially reduces technical barriers and deployment costs for practical applications. Comprehensive evaluations on three real-world IoT datasets demonstrate that ZeroImpute achieves at least a 4.5% performance improvement in MAE compared to the best-performing specialized deep learning models under strictly zero-shot, zero-training settings. Moreover, the method exhibits robustness across different missing rate scenarios, effectively addressing critical practical challenges including rapid deployment in new regions, cross-domain data imputation generalization, and efficient deployment in resource-constrained environments. This research pioneers a new paradigm of multi-agent collaborative reasoning for spatiotemporal computation, providing novel technical pathways for the spatiotemporal data imputation field and offering crucial technical support and theoretical foundations for advancing IoT technology adoption across broader industrial applications.

Key words: internet of things sensing; data sparsity; cold start; spatiotemporal data imputation; large language models; zero-shot

Foundation Item(s): National Natural Science Foundation of China (No.62372047); Natural Science Foundation of Beijing (No.4232028); Zhuhai Industry-University-Research Project (No.2220004002686, No.2320004002812); Zhuhai Basic and Applied Basic Research Project (No.2220004002619); Zhuhai Social Development Field Science and Technology Plan Project (No.2320004000213)

1 引言

物联网(Internet of Things, IoT)通过赋予设备智能通信与感知的能力,为数字化转型奠定了坚实基础.融合环境感知与人工智能技术,物联网系统能够自主分析复杂数据流并提供实时智能决策^[1,2].例如,在智能交通系统中,基于V2I(Vehicle-To-Infrastructure)技术的信号控制系统通过获取实时交通流来智能调节信号配时,显著缓解城市交通拥堵^[3,4].传感器网络作为物联网感知层的关键支撑,通过大规模部署各类感知设备为上层应用提供丰富的时空数据资源^[5,6].这些感知数据经过深入分析处理,能够为生产制造、城市管理、环境保护等领域提供重要的数据支撑和洞察信息^[7-9].

然而,在实际部署中,物联网感知系统面临着诸多现实约束:一方面,受限于部署成本、地理环境和基础设施条件,难以实现理想的全域覆盖;另一方面,设备故障、电源耗尽、通信中断以及恶劣环境等因素不可避免地导致数据采集的中断和缺失.这种数据缺失问题在大规模、细粒度的物联网应用中尤为突出.采集到的时空数据往往表现出不完整、随机分布和高度稀疏的特征,严重影响了这些数据的分析质量和决策准确性,

进而导致整体服务质量的下降.

当前解决方案主要为插补技术,利用部分观测样本推断缺失数据,而非承担高成本来收集完整数据集^[10].该方案可行性源于感知数据的时空相关性,相邻时空位置数据表现出的强关联性为从有限观测中重构缺失信息提供了理论依据^[11].现有时空插补技术主要聚焦于构建场景专用模型,通过大量数据训练学习特定时空关联模式,一旦脱离训练分布环境,性能显著下降.统计学方法虽然具有一定的泛化性,但受限于线性假设和独立性假设,无法处理复杂的非线性时空依赖关系.在新兴应用场景中,缺乏充足训练数据导致模型学习偏差较大,传统方法在“冷启动”场景下表现不佳,亟需零样本插补策略填补这一技术空白.

大语言模型(Large Language Models, LLM)的快速发展为零样本生成提供了新思路.LLM在复杂任务中展现出了卓越能力,从自然语言理解到逻辑推理^[12].从理论基础来看,大语言模型通过在海量序列数据(如文本、音频、视频等)上的预训练,发展出了强大的序列建模和模式识别能力,这与时空数据分析所需的核心技能存在一定相似性:LLM的序列建模能力与时间序列分析高度契合,其语义推理能力可用于空间关系建模,

而其少样本泛化能力为零样本插补提供了理论基础。然而,现有研究主要集中于将LLM应用于时间序列预测任务,包括采用直接微调策略,或将数值时间序列转换为自然语言描述,直接利用LLM的文本理解能力进行分析^[13]。LLM在时空数据中的应用,特别是插补任务中的应用仍然有限。

基于此认知,本文首次将大语言模型的推理能力引入物联网时空数据插补任务。如图1所示,我们设计了基于LLM的插补策略,通过分析可观测时空数据内在关联模式,对缺失位置进行重构。




图1 基于LLM的时空数据插补

具体而言,本文提出了ZeroImpute框架,其实现了两个重要范式转换:首先,将传统基于数据驱动训练的学习范式转化为基于知识驱动推理的零样本范式;其次,将传统单一模型处理复杂问题的范式转换为多智能体协同推理范式,通过专门化智能体的分工协作实现对复杂时空问题的系统性解构与重构。基于这一范式创新,该框架将复杂时空插补任务分解为多个专门化LLM智能体可协同处理的语义推理子任务,充分释放多智能体协同推理在模式识别与决策融合方面的潜能。该框架构建了由四个核心组件组成的多智能体协同系统,分别是数据预处理模块、时序分析智能体、空间分析智能体以及插补决策智能体。通过专门化智能体的分工协作和知识交互,该系统能够处理比单一模型更加复杂的时空依赖关系,实现更高精度和更强鲁棒性的插补效果。

相比传统方法,ZeroImpute具有显著应用价值:首先,它消除了对深度学习专业知识、大量标注数据和高性能计算资源的依赖,使得非专业用户也能便捷地应用先进的插补技术;其次,天然适配数据稀缺环境,特别适用于新部署传感网络、偏远地区监测等缺乏历史数据的冷启动场景;最后,通过利用大语言模型的模式外推能力,规避了构建专用时空模型中常见的复杂网络设计与参数调优。

2 相关工作

2.1 数据插补

现有的数据插补方法可以大致分为三类:统计方法、机器学习方法和深度学习方法,它们在处理复杂度和建模能力上呈现递进关系。

统计方法基于基础统计属性和假设进行插补,具

有计算简单、易于理解的特点。典型方法包括均值插补和KNN(K-Nearest Neighbor)插补。均值插补通过使用观测数据的统计均值来填充缺失值,适用于数据分布相对均匀的场景。KNN插补使用最近邻相似性来估计缺失值,适用于局部相关性强的场景,但对大型数据集的计算成本较高。机器学习方法通过学习数据的内在结构和关联模式实现更精确的插补。主要包括矩阵分解^[14-18],如时间正则化矩阵分解(Temporal Regularized Matrix Factorization, TRMF)、回归方法^[19],如支持向量回归(Support Vector Regression, SVR)以及随机森林和梯度提升等技术^[20,21]。这些方法能够有效利用数据中的潜在关系,在中等规模和复杂度的插补任务中表现良好。

深度学习方法近年来在时空数据插补领域取得了突破性进展,通过构建复杂神经网络架构学习数据中的高维非线性模式。常见的深度学习方法有深度自回归方法^[22],通过递归结构捕获时间序列中的时间依赖性;深度生成模型方法^[23,24],使用生成对抗网络(Generative Adversarial Networks, GANs)和扩散模型来模拟数据生成过程,通过对抗训练有效填充缺失数据;基于Transformer的方法^[25-29],通过自注意力机制捕获时间空间依赖性,提高时空数据的插补精度;基于卷积神经网络(Convolutional Neural Network, CNN)的方法^[30,31],通过卷积操作捕获时间序列数据中的局部模式和特征,能够有效建模多周期模式和长期时间依赖关系,在时间序列插补任务中展现出良好的性能。此外,基于图神经网络(Graph Neural Network, GNN)的方法^[32-35]通过构建图结构来建模时空数据中复杂的空间依赖关系和时间动态特性。这类方法将时空数据中的空间位置作为图节点,利用图卷积操作捕获节点间的空间相关性,同时结合循环神经网络或时间卷积等时间建模组件处理时间序列信息,能够同时学习时空数据的空间拓扑结构和时间演化模式。

尽管深度学习方法在建模能力上显著优于传统方法,但它们普遍存在依赖大量训练数据、模型复杂度高、泛化能力有限等问题,特别是在面对新域数据或数据稀缺场景时往往表现不佳。

2.2 大语言模型在时空序列上的应用

近年来,大语言模型因其在自然语言处理、计算机视觉推理、知识整合等任务中展现出的卓越性能而引起了广泛关注。例如,生成式预训练转化器GPT(Generative Pre-trained Transformer)系列模型通过大规模预训练获得了强大的泛化能力和少样本学习能力,能够在有限数据条件下完成复杂的推理任务^[36]。

在时间序列分析领域,研究者们提出了多种将LLM应用于时序任务的技术方案。文献^[37]提出了利

用预训练语言模型进行通用时间序列分析的框架,该工作通过冻结预训练 Transformer(如 GPT-2)的自注意力和前馈层,仅通过微调输入输出层来适配时间序列任务.文献[38]则提出了更为精细的重编程技术,将冻结的预训练语言模型适配到时间序列预测任务,采用 Prompt-as-Prefix 策略将时序片段转换为自然语言原型,在保持语言模型参数不变的情况下实现了更加有效的时序建模. PromptCast^[39]则提出了基于提示的时间序列预测范式,将数值输入输出转换为提示格式,使预测任务成为句子到句子的生成任务,从而使预训练语言模型能够直接应用于预测目的.

然而,上述研究主要集中在单维度的时间序列分析上,针对更复杂的时空数据建模的探索仍然有限. UrbanGPT^[40]在这一方向上进行了有益尝试,通过将城市时空数据转换为文本序列,利用大语言模型的序列建模能力来捕获复杂的时空依赖关系,并结合城市领域知识进行时空数据分析.但该工作主要针对预测任务设计,在时空数据插补方面的应用尚未得到充分探索.

3 预备

3.1 定义

定义 1 感知数据:将时空感知数据定义为 $\mathbf{X}_{t:t+L} = [\mathbf{X}_t \mathbf{X}_{t+1} \cdots \mathbf{X}_{t+L}]$. 其中 $\mathbf{X}_t \in \mathbb{R}^{H \times W}$, ($H \times W = N$ 为感知区域的划分表示). 在任意观测时刻 t , 位置 (i, j) 处的观测数据记为 $x_{(i,j)}^t \in \mathbb{R}$.

定义 2 掩码标记:引入二值掩码矩阵 $\mathbf{M}_t \in \{0, 1\}^{H \times W}$ 表示 t 时刻各子区域的缺失情况. 其中, $m_{(i,j)}^t = 1$ 表示 t 时刻子区域 (i, j) 存在有效观测数据, $m_{(i,j)}^t = 0$ 表示该位置数据缺失,即 $x_{(i,j)}^t = \text{NaN}$. 为简单表示,记 $\mathbf{M}_{t:t+L} = [\mathbf{M}_t \mathbf{M}_{t+1} \cdots \mathbf{M}_{t+L}]$ 表示时间窗口 $[t: t+L]$ 内的数据缺失情况.

3.2 问题描述

大语言模型凭借其在海量数据上的预训练优势,发展出了强大的序列建模和模式识别能力,能够从复杂的字符或数值序列中有效学习并捕获潜在的分布规律、依赖关系以及高层语义特征. 这种能力为将 LLM 应用于时空数据插补任务提供了重要的理论基础.

基于时空感知数据 $\mathbf{X}_{t:t+L}$ 和掩码标记 $\mathbf{M}_{t:t+L}$ (简单起见,后文省略下标),本文的核心任务可以形式化表达为

$$\mathcal{F}(\mathbf{X}, \mathbf{M}, \mathcal{L}) \rightarrow \hat{\mathbf{X}} \quad (1)$$

其中, $\hat{\mathbf{X}}$ 为重构的完整时空数据; \mathcal{L} 为提示词等语义信息. 重构过程中,满足 $m_{(i,j)}^t = 1$ 的位置保持观测值不变, $m_{(i,j)}^t = 0$ 的位置通过模型生成相应的插补值,从而实现时空数据的完整性恢复.

这一问题形式化的核心在于将传统的数值优化问题转化为语义推理问题,通过引入语义信息 \mathcal{L} ,使得插补过程不再仅仅依赖于数值计算,而是融合了基于知识的逻辑推理,从而实现更加智能和准确的插补效果.

4 方法

4.1 总体框架

本文提出的 ZeroImpute 方法基于多智能体协同推理构建了一种新颖的语义化时空插补架构,通过将数值序列转换为结构化语言表示,使专门化 LLM 智能体能够协同识别和推理传统方法难以建模的复杂时空依赖关系. 该设计基于一个关键洞察,即时空数据中的模式特征(如趋势性、周期性、空间相关性等)本质上可通过语义化表示进行精确刻画,而多个专门化大语言模型智能体在跨域协同推理方面的优势为复杂模式识别提供了新的技术路径.

该架构的核心设计在于构建由时序分析智能体、空间分析智能体和插补决策智能体组成的三层协同推理体系,建立数值与语义表示的双向映射桥梁,实现从数值序列到多智能体语义推理,再从协同推理结果到最终插补值的完整转换链路. 这种设计突破了传统单一模型直接在数值空间进行插补的局限性,充分利用了多智能体在专门化语义理解和协同逻辑推理方面的优势.

整体框架如图 2 所示. 数据预处理模块采用标准化和文本格式化策略,将数值型时空数据转换为各智能体可理解的统一语义化表示;时序分析智能体负责复杂时间依赖关系的语义理解与推理,通过双向序列建模从演化趋势和约束模式两个互补视角深度挖掘时序特征;空间分析智能体专注于动态空间关系的建模与解析,基于时序分析智能体提供的上下文指导识别时变空间相关性模式;插补决策智能体作为协调者整合多源语义知识,基于多智能体推理结果和局部上下文特征,通过自适应权重融合算法生成最终的智能插补决策. 通过专门化智能体的分工协作和智能体间的知识交互机制,该框架实现了对复杂时空依赖关系的系统性理解和高精度重构.

与传统方法相比,ZeroImpute 不仅能够处理复杂的非线性时空依赖关系,还具备良好的可解释性和泛化能力.

4.2 数据预处理

4.2.1 数据扁平化

针对大语言模型的序列处理特性,本文设计了基于滑动窗口的时空数据序列化方法,实现了时空结构向一维序列的语义保持映射. 通过 $k \times k$ 滑动窗口对二维空间进行扫描,将每个窗口内的空间展开为一维序

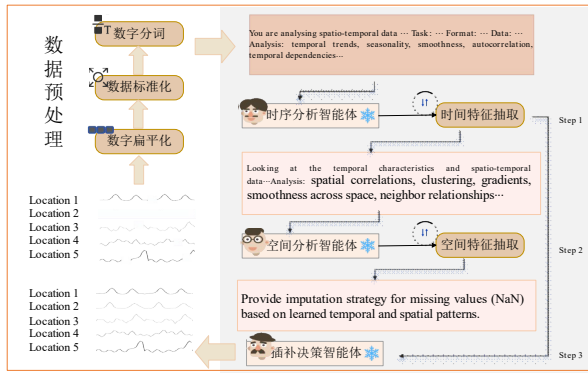


图2 ZeroImpute 框架

序列. 将每个窗口内的空间区域展开为连续子序列, 这种设计不仅有效保持了原始数据的空间邻域关系, 还通过自适应窗口尺寸调节实现了局部聚合粒度的精确控制. 基于这种扁平化表示, 原始时空数据 $X_{t:t+L} \in \mathbb{R}^{L \times H \times W}$ 被转化为 $X_{t:t+L} \in \mathbb{R}^{L \times N}$ (x_i^t 构成 $X_{t:t+L}$, 其表示 t 时刻第 i 个位置的观测值), 相应的掩码矩阵 $M_{t:t+L}$ 同步进行对应变换.

4.2.2 数据标准化

原始时空观测数据往往存在数值范围差异显著、包含负值以及极端异常值等问题, 这些因素会对 LLM 的理解和处理产生不利影响, 如在固定的上下文窗口限制下无法保留足够的有效信息、不同量级的数值混合可能导致 LLM 难以识别数据的内在分布特征等.

为解决这一问题, 本文采用基于分位数的标准化策略. 受文献[41]的启发, 我们将序列中第 α 百分位数 x_α 设定为标准化基准点, 映射至固定标准值 1.0. 相较于传统的最大值标准化方法, 该策略具有显著的异常值抵抗性, 能够有效抑制极端观测值对整体数据尺度的扭曲影响. 同时引入偏移量 β 实现数据的正值平移, 消除负值和近零值可能导致的数值不稳定性. 对于任意观测值 x_i^t , 其标准化变换定义为

$$\tilde{x}_i^t = \frac{x_i^t - \min(X \circ M)}{x_\alpha - \min(X \circ M)} + \beta, \quad 1 \leq i \leq N \quad (2)$$

4.2.3 数据分词

标准化后的数值需要进一步转换为 LLM 友好的文本格式. 传统的 BPE (Byte-Pair Encoding) 分词方法在处理数值序列时存在固有缺陷, 往往将完整数值拆分为语义不连贯的子词单元, 破坏了数值的内在逻辑结构和逐位关联性.

为克服这一局限, 本文采用“十进制逐位分解”策略. 该策略首先将标准化后的数值 \tilde{x}_i^t 按照预设精度 d 进行四舍五入处理 (例如 $d = 2$ 表示保留两位小数) 得到 $\bar{x}_i^t = \text{round}(\tilde{x}_i^t, d)$, 随后移除小数点并转换为 $d + m$ 位整数表示 \bar{x}_i^t (其中 m 为整数部分位数), 通过将数值拆分为

独立字符并插入空格分隔符, 形成字符级别的 token 序列:

$$s_i^t = u_1 u_2 \cdots u_{d+m} \quad (3)$$

例如, 当 $d=2$ 且 $\bar{x}_i^t = 1.23$ 时, 有 $\bar{x}_i^t = 123$ (记作“123”), 对应的 token 序列为 $s_i^t = "1 2 3"$. 完整的数据可以表示为

$$S_t = [s_1^t s_2^t \cdots s_N^t] \quad (4)$$

$$S_{t:t+L} = [S_t S_{t+1} \cdots S_{t+L}] \quad (5)$$

这种精细化的分词策略使大语言模型能够在字符级别学习数值间的逐位依赖关系, 显著提升了对复杂数值模式的识别能力. 值得注意的是, 该策略针对不同的 LLM 架构具有不同的适配性, 对于 LLaMA (Large Language Model meta AI) 等已采用数字字符独立分词的模型, 可直接省略空格插入步骤, 保持方法的通用性和灵活性[41].

4.3 特征学习

4.3.1 时序特征学习

时序特征学习旨在通过 LLM 的语义理解能力, 实现对时间序列复杂模式的深度挖掘和精准刻画. 与传统预测任务的单向信息流不同, 时空插补任务具有本质上的双向依赖特性: 缺失值的最优估计不仅依赖于历史演化轨迹, 同时也受到未来观测值的强约束. 如图3所示, 这种双向信息可用性构成了插补精度提升的重要理论基础, 其中前向依赖性体现了缺失值对历史趋势的继承性, 后向依赖性则确保了插补结果与未来观测的逻辑一致性.




图3 时序双向依赖性

基于这一认知, 本文设计了前向与后向双向时序学习机制, 通过构建时序分析智能体实现对复杂时序模式的全方位理解. 该智能体基于设计的结构化提示策略 (如图4所示), 引导 LLM 从趋势性、周期性、平滑度、自相关性等多个维度对输入时间序列进行综合分析, 并以自然语言形式返回对观测模式的综合描述.

双向时序分析的工作流程可形式化表述为

$$A_t(X \circ M) \rightarrow \mathcal{L}_{f_o}, \mathcal{L}_{b_{ack}} \quad (6)$$

其中, A_t 表示时序分析智能体, \mathcal{L}_{f_o} 和 $\mathcal{L}_{b_{ack}}$ 分别为前向和

```

The PEMS08 dataset is a traffic flow dataset collected by...
This dataset contains data collected by 170 sensors, which
are distributed at different locations and collect data every
five minutes for 62 consecutive days...

***
[Task]: Analyze the temporal patterns (how values change over time) for the
given spatial location.
***
[Data Format]: Time × Space, each sequence shows how one location
changes over time...
***
[Analyze]: Temporal trends, seasonality, smoothness, autocorrelation, and
temporal dependencies.

```

图4 时间特征学习 prompt 示例

后向时序模式的自然语言描述。

利用 LLM 在复杂模式理解和语言表达方面的优势,识别传统数值方法难以捕捉的复合特征,生成如“该序列呈现稳定的上升趋势,伴随轻微的周期性波动,整体变化较为平滑,显示出较强的短期自相关性”等综合性描述。为实现语义描述向数值特征的有效转换,可以通过关键词匹配和语义解析,将 \mathcal{L} 映射为结构化特征向量。例如,“强烈上升趋势”被转换为趋势得分 +2.0,“中等波动性”被转换为波动性得分 +0.5,“明显季节性”被转换为周期性得分 +1.5。同时,为增强特征表示的可靠性,引入传统统计量作为补充验证,包括线性回归系数验证趋势特征、标准差验证波动性、自相关系数验证时序依赖性等。通过多源特征融合策略,得到前向时序特征 \mathbf{E}_{fo} 和后向时序特征 \mathbf{E}_{back} ,为后续的时空耦合分析提供丰富的时序语义信息。这种语义化的特征表达相比传统的数值统计量具有更强的表达能力和可解释性,能够捕获复杂的非线性模式特征。

4.3.2 空间特征学习

空间特征学习的核心设计在于构建了时空耦合的空间关系识别机制,将时序分析智能体生成的知识作为关键上下文信息,指导空间分析智能体进行更加精准的空间依赖性挖掘。这一设计突破了传统方法将时空维度独立建模的局限性,基于一个重要的理论洞察:时空数据中的空间相关性模式往往受到时序演化规律的显著调制,忽略这种深层耦合关系将导致空间特征表征的不完整性和插补精度的损失。

传统空间插补方法通常基于静态空间相关性假设,即认为不同位置间的关系在时间维度上保持恒定。然而,现实时空系统中的空间相关性模式呈现显著的时变特征。例如,在气象系统中,温度场的空间分布模式随季节变化表现出截然不同的相关结构;在城市交通网络中,道路间的流量耦合关系在高峰与非高峰时段展现出迥异的传播特性。这种动态演化的空间相关性正是时空耦合分析的核心挑战和价值所在。本文的空间特征学习通过引入时序上下文信息,实现了对这种时变空间关系模式的精确捕获。

具体而言,空间分析智能体接收三个关键输入信

息:时空观测数 \mathbf{X} 、时序特征描述 $\mathcal{L}_t = \{\mathcal{L}_{t_{fo}}, \mathcal{L}_{t_{back}}\}$ 以及缺失数据的位置标注信息 \mathbf{M} ,其分析过程可形式化为

$$\mathcal{A}_s(\mathbf{X}, \mathcal{L}_t, \mathbf{M}) \rightarrow \mathcal{L}_s \quad (7)$$

该智能体能够生成体现深层时空关联的语义化描述,典型输出示例如下:“基于时序周期性特征,当前时刻的空间相关性应考虑周期同步效应。观察发现相邻位置不仅在数值上相关,更重要的是在周期相位上高度一致,这种相位同步增强了实际的空间依赖强度。建议在周期性背景下,空间相关性的有效作用距离应扩大约 30%,衰减率相应减缓”。这种描述不仅识别了空间相关性,更重要的是揭示了时序特征对空间模式的塑造作用。

类似于时序特征处理,输出的语义描述通过解析转换为数值化的空间特征。该转换过程重点关注空间相关性的强度、方向性和衰减模式等关键属性。同时,为确保特征提取的统计可靠性,引入传统空间统计量作为交叉验证基准,包括空间自相关系数(用于验证整体空间相关性强度)、变异函数(用于验证空间相关性的衰减模式)、最近邻相关性(用于验证局部空间结构特征)等。时空耦合的空间特征学习的最终输出是一个融合了时序上下文信息空间特征 \mathbf{E}_{spa} ,该特征不仅保留了传统空间统计信息,更重要的是编码了时序演化对空间模式的动态影响机制,为后续高精度插补提供了丰富而可靠的空间语义信息。

4.3.3 插补决策

插补决策智能体负责将多维度特征信息融合为精确的缺失值估计。该智能体基于语义理解的自适应权重分配机制,根据局部时空上下文的复杂性动态调整不同特征源的贡献权重,实现从固定权重融合向智能化决策融合的根本性转变。

插补过程的输入包括三个同维度的语义化特征表示:前向时序特征矩阵 \mathbf{E}_{fo} 、后向时序特征矩阵 \mathbf{E}_{back} 和时空耦合空间特征矩阵 \mathbf{E}_{spa} 。对于每个待插补的缺失值 x'_i ,首先识别其有效邻域集合:

$$\mathcal{O} = Y_t(x'_i) \cup Y_s(x'_i) \quad (8)$$

其中, $Y_t(x'_i)$ 和 $Y_s(x'_i)$ 分别表示 x'_i 时间邻域和空间邻域集合。

随后将邻域信息构造为结构化的文本描述,使用 LLM 进行分析:

$$\mathcal{A}_w(\mathbf{X}, \mathbf{M}, \mathcal{O}) \rightarrow (w_{fo}, w_{back}, w_{spa}) \quad (9)$$

典型的 LLM 分析输出如下:“考虑到当前位置的空间邻域观测密度较低,且时序演化呈现明显的非平稳特征,建议采用时序主导的融合策略:前向时序权重 0.45(利用历史稳定趋势),后向时序权重 0.35(保证未来一致性),空间权重 0.20(补充局部空间信息)”。这种语义化的权重分配不仅提供了数值结果,更重要的是

给出了决策的逻辑依据,增强了插补过程的可解释性和可信度.

基于智能权重分配结果,执行多特征自适应融合操作:

$$\mathbf{E}_{\text{fused}} = w_{\text{fo}} \cdot \mathbf{E}_{\text{fo}} + w_{\text{back}} \cdot \mathbf{E}_{\text{back}} + w_{\text{spa}} \cdot \mathbf{E}_{\text{back}} \quad (10)$$

s.t. $w_{\text{fo}} + w_{\text{back}} + w_{\text{spa}} = 1$

进一步地,计算 \mathcal{O} 中每个观测值的权重 $w'_{i'}$,该权重综合考虑距离衰减:

$$w'_{i'} = \exp\left(-\frac{d_{\text{st}}((i, t), (i', t'))}{\tau}\right), (i', t') \in \mathcal{O} \quad (11)$$

其中, d_{st} 表示时空距离; τ 为温度参数,用于调节权重衰减的敏感性. 最终的插补结果通过融合特征预测和邻域加权插补获得:

$$\hat{x}^t_{i'} = \gamma \frac{\sum_{(i', t') \in \mathcal{O}} w'_{i'} \cdot x'_{i'}}{\sum_{(i', t') \in \mathcal{O}} w'_{i'}} + (1 - \gamma) \cdot \mathbf{E}_{\text{fused}}(i', t') \quad (12)$$

其中, γ 为平衡参数,动态调节基于观测值的直接插补与基于特征融合的语义插补之间的权重.

5 实验评估

5.1 实验设置

5.1.1 数据集

为了验证 ZeroImpute 在零样本插补上的有效性,我们在三个公开数据集上进行了实验,数据集信息如表 1 所示.

表 1 数据集描述

数据集	PEMS08 ^[32]	METR-LA ^[42]	AQI ^[43]
类别	交通流	速度	PM2.5
位置	圣贝纳迪诺	洛杉矶	北京等
子区域数	170	207	437
时间步数	17 856	34 272	8 760
时间间隔/min	5	5	60

5.1.2 基线方法

我们使用的 LLM 模型主要包括 GPT-3.5、GPT-4、GPT-4o、DeepSeek-v3. 对比方法包括传统统计学插补方法以及基于深度学习的时空插补方法. 统计学方法主要为 Mean 插补,基于深度学习的时空插补方法可以进一步细分为基于深度自回归的方法(Brits)、基于深度生成式的方法[CSDI (Conditional Score-based Diffusion model)、US-GAN (UnSupervised Generative Adversarial Network)]、基于 CNN 的方法[TimesNet、SAITS (Self-Attention-based Imputation for Time Series)],基于 Transformer 的方法(Imputeformer),基于图神经网络的方法[T-GCN (Temporal Graph Convolutional Network)、StemGNN (Spectral Temporal Graph Neural Network)]以

及基于 LLM 的方法[GPT4TS (Generative Pre-trained Transformer for Time Series)].

5.2 插补性能对比

为了评估模型在完全零样本、零训练条件下的时空插补性能,我们在三个公开数据集上进行了对比实验,统一设置 20% 的数据缺失率,展平窗口大小为 2. 由于大语言模型的输出具有固有的随机性(如图 5 所示,该箱型图通过 10 次独立采样的 Z-Score 标准化结果展示了 ZeroImpute(GPT-4)的输出分布),我们采用 10 次输出结果的中位数作为插补结果,以确保评估结果的稳健性.




图 5 ZeroImpute (GPT-4)采样结果的标准化分布

表 2 的实验结果显示(其中加粗数据为最优结果), ZeroImpute 方法在以 GPT-4o 为模型基底时,在所有测试数据集上均取得了最优的插补性能,同时其他 LLM 基底模型也展现出稳定的性能表现,充分证实了大语言模型驱动的时空插补范式的有效性和泛化能力. 与传统深度学习方法相比,我们的方法展现出明显优势,在 MAE 指标上实现了至少 4.5% 的精度提升. 这一结果源于框架对 LLM 语义推理和模式识别能力的充分释放,通过双向时序分析、时空耦合建模和协调插补机制,实现了对复杂时空依赖关系的深度理解和精准重构.

传统深度学习方法在零样本场景下的表现揭示了数据驱动范式的固有局限性. Imputeformer 作为基于 Transformer 的方法,在有训练数据的情况下通常表现优秀,但在零样本设置下性能显著下降. SAITS 和 TimesNet 等基于 CNN 的方法同样面临相似问题,它们依赖于从训练数据中学习的网络参数,在没有训练的情况下无法发挥应有的建模能力. T-GCN 和 StemGNN 等图神经网络方法的表现更加说明了专用模型的局限性. 这些方法需要预先构建图结构来表示空间关系,但在零样本场景下,这种图结构的构建缺乏数据支撑,导致空间建模效果不佳. 相比之下,我们的方法通过语义理解自动识别空间关系,避免了这一问题.

CSDI 作为代表性的扩散模型方法,其在所有数据集上的表现甚至劣于简单的均值插补基线,这一反常

表2 20%缺失率下不同模型在三种数据集上的零样本插补能力比较

数据集	PEMS08		METR-LA		AQI	
	MAE	RMSE	MAE	RMSE	MAE	RMSE
ZeroImpute(GPT-3.5)	52.03	65.81	4.74	6.02	22.18	26.14
ZeroImpute(GPT-4)	42.82	58.88	4.60	5.82	14.79	23.90
ZeroImpute(GPT-4o)	40.15	56.80	3.49	4.90	14.14	22.25
ZeroImpute(DeepSeek-v3)	41.82	57.76	4.12	5.66	14.52	22.37
GPT4TS ^[37]	44.45	60.38	3.90	7.70	16.93	30.05
Imputeformer ^[28]	42.02	58.71	4.54	8.10	20.73	34.80
SAITS ^[29]	46.80	63.71	6.91	12.95	27.34	42.66
TimesNet ^[30]	62.21	82.96	4.039	8.00	20.50	35.22
US-GAN ^[24]	53.01	69.55	7.04	11.46	26.21	40.01
CSDI ^[23]	266.63	488.23	58.74	145.34	817.77	1 837.42
Brits ^[22]	55.57	75.65	7.77	13.39	25.90	40.58
T-GCN ^[34]	62.17	86.21	9.30	14.13	25.41	44.84
StemGNN ^[35]	66.69	91.40	11.15	20.02	37.75	56.66
Mean	119.82	144.11	16.39	21.63	35.15	52.14


现象深刻揭示了生成式模型对训练数据的极强依赖性. 扩散模型的核心机制基于学习数据从噪声到真实观测的逆向去噪过程, 这一复杂的生成机制需要在海量训练样本上进行长期迭代优化, 以掌握目标数据的潜在概率分布特征. 在零样本条件下, CSDI失去了训练阶段积累的分布先验知识, 只能依赖随机初始化参数进行盲目去噪, 生成结果趋近于无意义的随机噪声而非合理的插补估计, 充分说明了传统生成式方法在零样本场景下的根本性缺陷.

5.3 鲁棒性实验


为了进一步评估ZeroImpute在不同数据稀疏程度下的鲁棒性, 我们选取了能力适中的ZeroImpute(GPT-4)与三种性能相对较优的基线方法(GPT4TS、SAITS、ImputeFormer)进行对比分析, 在三个基准数据集上测试了从10%~50%的渐进缺失率场景, 以考察方法的稳定性和可靠性.

如图6所示, ZeroImpute在整个缺失率谱上展现了稳定的性能优势. 在较低缺失率(10%~30%)下, 能够利用可观测信息, 通过多智能体分析挖掘数据中的潜在规律并生成高质量的插补结果. 特别是在AQI (Air Quality Index)空气质量指数数据集上, ZeroImpute的误差显著低于其他方法. 而在其他缺失率场景下, ZeroImpute依然保持了竞争优势.


综合三个数据集的结果可以看出, 我们的方法不仅在单一缺失率下表现优异, 在面对不同程度的数据稀疏、不同环境时依然能提供稳定可靠的插补结果. 这证明了ZeroImpute具有良好的实用价值, 能够适应实际应用中不可预测的数据缺失情况以及各种数据环境, 为物联网中的时空数据插补提供了解决方案.



(a) PEMS08



(b) METR-LA



(c) AQI

图6 变化缺失率下模型的插补表现

5.4 时间维度插补表现

为验证ZeroImpute在时间维度上的插补精度, 我们随机选取了三个数据集中的时间序列进行分析, 通过对比真实观测值与插补结果来评估方法在不同时序模

式下的表现能力。

如图 7 所示, ZeroImpute (GPT-4) 在三个数据集上都展现出了较好的插补效果. 在加州交通评估系统数据集 PEMS08 (caltrans Performance Measurement System 08) 交通流量数据中, 其精准捕获了交通流的单调上升趋势特征, 插补点与真实观测轨迹实现了高度吻合. 这一优异表现源于双向时序学习机制的协同效应: 前向时序分析通过语义化建模识别历史演化的趋势性和连续性特征, 后向时序分析则利用未来观测值提供的强约束信息, 确保插补结果与整体演化方向的逻辑一致性. 在 METR-LA (Metro Traffic Los Angeles) 洛杉矶交通数据集中, 其成功识别了交通传感器数据的高频振荡特征, 准确捕获了短期内的急剧变化和局部抖动模式. 这种对微观时序结构的精确建模体现了时序分析智能体的语义理解优势: 通过将数值波动转化为“急剧上升-短暂稳定-快速下降”等语义化描述, LLM 能够理解和推理传统统计方法难以建模的复杂非线性时序模式. AQI 空气质量数据展现了更为复杂的多峰波动和非周期性变化特征, 包括污染物浓度的急剧上升、缓慢扩散和波动衰减等多种模式的组合. 我们的方法同样实现了高质量的模式重构, 充分体现了基于语义推理的时序建模在处理复杂环境数据方面的独特优势. 传统数值方法往往将这种复合模式视为噪声或异常, 而我们的方法能够通过语义理解识别其中的逻辑规律, 如“污染源爆发-大气扩散-自然沉降”等环境过程的语义表达.

5.5 时空插补表现

为了直观展示 ZeroImpute 的时空插补效果, 我们对三个数据集在 20% 缺失率下的插补结果进行了可视化. 图 8 通过热力图形式展示了 PEMS08 和 METR-LA 数据集中 2 h 时间窗口内 50 个传感器位置的插补效果, 以及 AQI 数据集中 1 d 观测周期内 50 个监测站点的重构结果, 通过原始观测数据与插补结果的直接对比, 展现方法在时空连续性保持和模式重现方面的性能.

从可视化结果可以看出, ZeroImpute 基本重构了不同数据集的时空分布. 在 PEMS08 交通流量数据中成功保持了数据的整体空间分布格局, 特别是准确重现了低流量区域的空间定位和数值特征. METR-LA 数据集呈现出更为复杂的时空异质性模式, 不同传感器位置间存在显著的数值差异和动态变化, ZeroImpute 的插补结果准确捕获了这种时空变异性, 在高数值区域与低数值区域的过渡边界处保持了良好的连续性. AQI 空气质量数据展现了典型的空聚特征, 插补结果不仅精确重现了这种空聚模式, 还保持了污染物扩散的自然渐变特性.

ZeroImpute 通过基于语义理解的时空耦合建模机制, 克服了传统方法在处理复杂时空依赖关系时常见

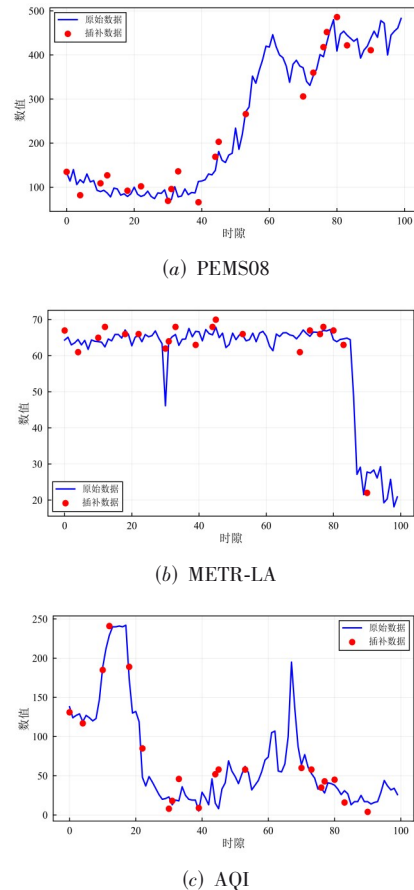


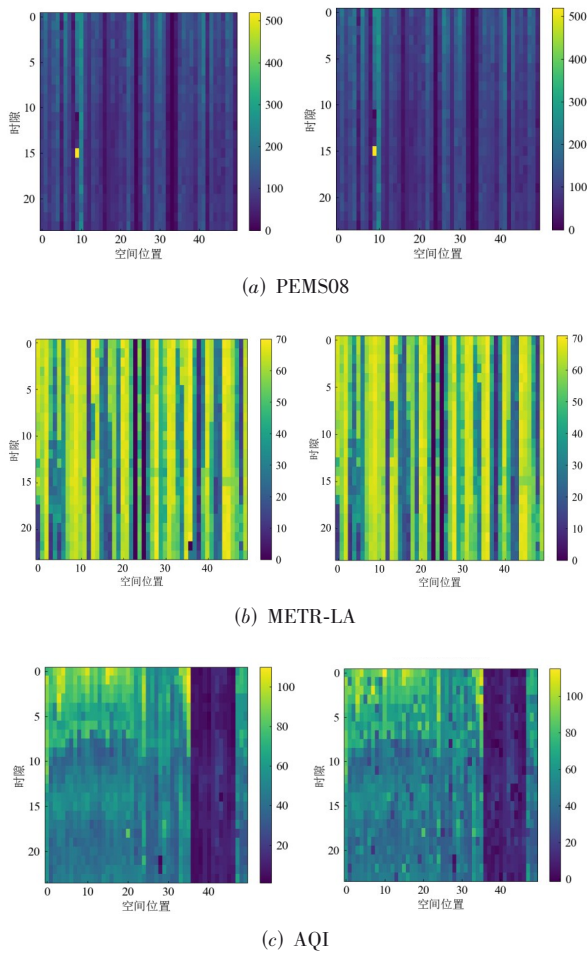
图 7 20% 缺失率下 ZeroImpute (GPT-4) 的时序插补表现

的不连续性和不一致性问题, 保持了原始数据的宏观时空结构特征和局部细节信息的完整性, 为时空数据插补提供了准确自然的重构效果.

5.6 滑动窗口大小分析

为研究 $k \times k$ 滑动窗口参数对插补性能的影响, 我们进行了窗口大小的敏感性分析. 如图 9 所示, 实验设计涵盖了 k 值在 1~4 范围内的系统性变化, 并引入随机打乱 (shuffle) 的对比实验来验证空间结构保持对插补性能的重要性.

实验结果揭示了不同数据集对窗口参数需求的显著差异化特征. PEMS08 和 METR-LA 交通流量数据集在 $k = 4$ 时达到最优性能, 而 AQI 空气质量数据集在 $k = 2$ 时表现最佳. 这种差异化的最优窗口配置深刻反映了不同时空系统的内在空间依赖特征: 交通网络数据由于传感器节点间存在复杂的多跳相关性和网络级联效应, 需要更大的空间窗口来充分捕获远程空间依赖关系和交通流的传播模式; 相比之下, 环境监测数据主要表现为基于物理扩散的局域性空间相关特征, 较小的邻域窗口即可有效捕获污染物浓度的空间梯度和扩散模式.



(a) PEMS08

(b) METR-LA

(c) AQI

注:GPT-4)的时空插补表现(左为原始数据,右为插补数据).

图8 20%缺失率下ZeroImpute




图9 不同滑动窗口大小k对插补性能的影响

当我们破坏原有的空间邻近关系,对所有空间位置进行随机展平时,所有数据集的性能都出现了明显下降,然而插补效果仍然保持在可接受的范围内,这一现象有力证明了LLM的强大泛化能力和鲁棒性.即使在空间结构信息被完全破坏的极端情况下,LLM仍能够通过识别数值序列中的潜在模式进行合理推断.

5.7 大语言模型的能力探索

基于LLM的插补方法的有效性本质上依赖于大语言模型从不完整观测数据中识别潜在规律的能力.如果LLM能够准确识别缺失数据的生成模式,就具备了

进行合理插补的必要条件.基于这一假设,本节通过生成函数识别实验验证了LLM的模式抽象能力.

实验中,我们构造了7种具有不同数学特征的生成函数,覆盖了常见的数据模式类型:高斯波函数、指数函数、线性函数、正弦函数、Sigmoid函数、对数函数以及二次函数.这些函数分别代表了线性增长、非线性变化、周期性振荡、局部化特征等不同的数学结构.实验数据生成过程如图10所示,首先,在预定义的7个生成函数中随机选择一个作为真实模式,在指定区间内生成100个数据点;然后,通过随机采样在序列中引入特定比例的缺失值,模拟真实应用场景中的不完整观测;最后,将含缺失的数值序列连同7个候选函数描述一同输入LLM,要求模型基于不完整信息进行函数类型识别.图11展示了典型的任务提示设计,通过结构化的问题形式引导LLM进行推理判断.

```

functions = {
    'gaussian_wave': lambda t: np.exp(-5 * (t-0.6)**2) * np.sin(20 * (t-0.6)),
    'exp': lambda t: np.exp(2 * t),
    'linear': lambda t: 0.3 + 0.5 * t,
    'sine': lambda t: np.sin(40 * t + 3),
    'sigmoid': lambda t: 1 / (1 + np.exp(-4 * t)),
    'log': lambda t: np.log(1 + t),
    'square': lambda t: 3 * (t-0.6)**2
}

selected_function = random.choice(list(functions.keys()))
selected_function = functions[selected_function]

t = np.linspace(0, 1, sequence_length)
original_sequence = selected_function(t)
sequence_with_missing = original_sequence.copy()
num_missing = int(sequence_length * missing_ratio)

# 随机选择位置设为NaN
missing_indices = np.random.choice(sequence_length, size=num_missing, replace=False)
sequence_with_missing[missing_indices] = np.nan

```

图10 序列生成过程

```

[Task]: Given the series <Series> with missing data, carefully analyze the series. Use your observations to identify which of the functions is most likely to have generated it. Reason your way to a solution and at the end give a name as your answer such as 'Answer: gaussian_wave'.
***
[Function]:
gaussian_wave, exp, linear, sine, sigmoid, log, square

```

图11 任务prompt示例

我们在GPT-4、Claude Sonnet 4、DeepSeek-v3等主流大语言模型上进行了多次重复实验.实验结果显示,即使在50%的缺失率下,所测试的LLM均能够达到100%的识别准确率.这一表现充分证实了LLM具备从稀疏、不完整的数值序列中准确提取关键结构化特征的能力,包括增长趋势的识别、波动模式的捕获、局部极值的定位以及变化率的估计等.更为重要的是,这种基于稀疏观测的特征抽象能力为LLM在时空插补任务中的优异表现提供了坚实的理论支撑.

6 结束语

时空数据插补作为物联网感知系统中的关键技术挑战,长期以来受制于传统方法对大规模训练数据的严重依赖以及在复杂时空依赖关系建模方面的局限性.本文提出的ZeroImpute框架通过引入多智能体协同推理机制,实现了时空插补领域从数据驱动学习向知识驱动推理的根本性范式转变.通过构建由时序分析智能体、空间分析智能体和插补决策智能体组成的专门化LLM协同系统,ZeroImpute将传统的数值计算问题转化为多智能体可协同处理的语义推理任务.在多个真实物联网数据集上的对比实验表明,基于多智能体协同推理的ZeroImpute在零样本零训练设置下相较于传统深度学习方法取得了显著提升,充分验证了智能体分工协作的有效性.在不同缺失率场景下,ZeroImpute依然能展现出良好的鲁棒性,体现了协同推理相对于单一模型的优势.该研究为物联网感知系统的数据质量保障开辟了新的技术路径,其零样本特性使其能够直接应用于新部署的感知网络而无需大量训练数据,特别适用于偏远地区监测、应急响应等数据获取困难的应用场景.

参考文献

- [1] 张依琳, 梁玉珠, 尹沐君, 等. 移动边缘计算中计算卸载方案研究综述[J]. 计算机学报, 2021, 44(12): 2406-2430.
ZHANG Y L, LIANG Y Z, YIN M J, et al. Survey on the methods of computation of f loading in mobile edge computing[J]. Chinese Journal of Computers, 2021, 44(12): 2406-2430. (in Chinese)
- [2] 申岩松, 李琳, 黄传明. 全局和局部感知的交通速度预测模型[J]. 电子学报, 2024, 52(9): 3195-3205.
SHEN Y S, LI L, HUANG C M. Global and local information aware traffic speed prediction[J]. Acta Electronica Sinica, 2024, 52(9): 3195-3205. (in Chinese)
- [3] ZHANG J, TAO D C. Empowering things with intelligence: A survey of the progress, challenges, and opportunities in artificial intelligence of things[J]. IEEE Internet of Things Journal, 2021, 8(10): 7789-7817.
- [4] MEI Y X, WANG W H, LIANG Y Z, et al. Privacy-enhanced cooperative storage scheme for contact-free sensory data in AIoT with efficient synchronization[J]. ACM Transactions on Sensor Networks, 2024, 20(4): 1-19.
- [5] LUONG N C, HOANG D T, WANG P, et al. Data collection and wireless communication in Internet of Things (IoT) using economic analysis and pricing models: A survey[J]. IEEE Communications Surveys & Tutorials, 2016, 18(4): 2546-2590.
- [6] XU W Z, XIAO T, ZHANG J Q, et al. Minimizing the deployment cost of UAVs for delay-sensitive data collection in IoT networks[J]. IEEE/ACM Transactions on Networking, 2022, 30(2): 812-825.
- [7] GHDIRI O, JAAFAR W, ALFATTANI S, et al. Offline and online UAV-enabled data collection in time-constrained IoT networks[J]. IEEE Transactions on Green Communications and Networking, 2021, 5(4): 1918-1933.
- [8] CAPPONI A, FIANDRINO C, KLIAZOVICH D, et al. A cost-effective distributed framework for data collection in cloud-based mobile crowd sensing architectures[J]. IEEE Transactions on Sustainable Computing, 2017, 2(1): 3-16.
- [9] XU C F, GUO J X, LI Y P, et al. Dynamic parallel multi-server selection and allocation in collaborative edge computing[J]. IEEE Transactions on Mobile Computing, 2024, 23(11): 10523-10537.
- [10] 蒋伟进, 王海娟, 周为, 等. 基于自适应连续时间的群智感知轨迹隐私保护方案[J]. 电子学报, 2023, 51(10): 2894-2901.
JIANG W J, WANG H J, ZHOU W, et al. Track privacy protection scheme based on adaptive continuous time in crowdsensing[J]. Acta Electronica Sinica, 2023, 51(10): 2894-2901. (in Chinese)
- [11] LI C X, LI Z T, LONG S Q, et al. Robust data inference and cost-effective cell selection for sparse mobile crowd-sensing[J]. IEEE/ACM Transactions on Networking, 2024, 32(5): 3760-3775.
- [12] 兰玉乾, 饶元, 李冠呈, 等. 基于内在质量约束的文本生成和评价综述[J]. 电子学报, 2024, 52(2): 633-659.
LAN Y Q, RAO Y, LI G C, et al. A survey of text generation and evaluation based on intrinsic quality constraints[J]. Acta Electronica Sinica, 2024, 52(2): 633-659. (in Chinese)
- [13] FENG M K, GU J J, QIU J, et al. From news to forecast: Integrating event analysis in LLM-based time series forecasting with reflection[C]//Advances in Neural Information Processing Systems 37. Vancouver: Neural Information Processing Systems Foundation, Inc. (NeurIPS), 2024: 58118-58153.
- [14] YU H F, RAO N, DHILLON I S. Temporal regularized matrix factorization for high-dimensional time series prediction[C]//Proceedings of the 30th International Conference on Neural Information Processing Systems. New York: ACM, 2016: 847-855.
- [15] CHEN X Y, HE Z C, CHEN Y X, et al. Missing traffic data imputation and pattern discovery with a Bayesian augmented tensor factorization model[J]. Transportation Re-

- search Part C: Emerging Technologies, 2019, 104: 66-77.
- [16] SALAKHUTDINOV R, MNIH A. Bayesian probabilistic matrix factorization using Markov chain Monte Carlo[C]// Proceedings of the 25th International Conference on Machine Learning. New York: ACM, 2008: 880-887.
- [17] CHEN X Y, SUN L J. Bayesian temporal factorization for multidimensional time series prediction[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 44(9): 4659-4673.
- [18] 金红, 胡智群. 基于非负矩阵分解的稀疏网络社区发现算法[J]. 电子学报, 2023, 51(10): 2950-2959.
- JIN H, HU Z Q. The non-negative matrix factorization based algorithm for community detection in sparse networks[J]. Acta Electronica Sinica, 2023, 51(10): 2950-2959. (in Chinese)
- [19] AYDILEK I B, ARSLAN A. A hybrid method for imputation of missing values using optimized fuzzy c -means with support vector regression and a genetic algorithm[J]. Information Sciences, 2013, 233: 25-35.
- [20] SHUMWAY R H, STOFFER D S. An approach to time series smoothing and forecasting using the em algorithm[J]. Journal of Time Series Analysis, 1982, 3(4): 253-264.
- [21] NELWAMONDO F V, MOHAMED S, MARWALA T. Missing data: A comparison of neural network and expectation maximization techniques[J]. Current Science, 2007, 93(11): 1514-1521.
- [22] CAO W, WANG D, LI J, et al. Brits: Bidirectional recurrent imputation for time series[C]//Proceedings of the 32nd International Conference on Neural Information Processing Systems. New York: ACM, 2018: 6776-6786.
- [23] TASHIRO Y, SONG J M, SONG Y, et al. CSDI: Conditional score-based diffusion models for probabilistic time series imputation[C]//Proceedings of the 35th International Conference on Neural Information Processing Systems. New York: ACM, 2021: 24804-24816.
- [24] MIAO X Y, WU Y Y, WANG J, et al. Generative semi-supervised learning for multivariate time series imputation[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2021, 35(10): 8983-8991.
- [25] LIU Y, WU H X, WANG J M, et al. Non-stationary transformers: Exploring the stationarity in time series forecasting[C]//Proceedings of the 36th International Conference on Neural Information Processing Systems. New York: ACM, 2022, 9881-9893.
- [26] ZHANG Y H, YAN J C. Crossformer: Transformer utilizing cross-dimension dependency for multivariate time series forecasting[C]//the 11th International Conference on Learning Representations. Appleton: ICLR, 2023: 1-21.
- [27] LIU Y, HU T G, ZHANG H R, et al. iTransformer: Inverted transformers are effective for time series forecasting[EB/OL]. (2024-03-14)[2025-05-25]. <https://arXiv.org/abs/2310.06625>.
- [28] NIE T, QIN G Y, MA W, et al. ImputeFormer: Low rankness-induced transformers for generalizable spatiotemporal imputation[C]//Proceedings of the 30th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. New York: ACM, 2024: 2260-2271.
- [29] DU W J, CÔTÉ D, LIU Y. SAITS: Self-attention-based imputation for time series[J]. Expert Systems with Applications, 2023, 219: 119619.
- [30] WU H X, HU T G, LIU Y, et al. TimesNet: Temporal 2D-variation modeling for general time series analysis[EB/OL]. (2023-04-12)[2025-05-25]. <https://arXiv.org/abs/2210.02186>.
- [31] LUO D H, WANG X. ModernTCN: A modern pure convolution structure for general time series analysis[C]//The 12th International Conference on Learning Representations. Appleton: ICLR, 2024: 1-43.
- [32] SONG C, LIN Y F, GUO S N, et al. Spatial-temporal synchronous graph convolutional networks: A new framework for spatial-temporal network data forecasting[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(1): 914-921.
- [33] ZHANG Q R, HUANG C, XIA L H, et al. Automated spatio-temporal graph contrastive learning[C]//Proceedings of the ACM Web Conference 2023. New York: ACM, 2023: 295-305.
- [34] ZHAO L, SONG Y J, ZHANG C, et al. T-GCN: A temporal graph convolutional network for traffic prediction[J]. IEEE Transactions on Intelligent Transportation Systems, 2020, 21(9): 3848-3858.
- [35] CAO D F, WANG Y J, DUAN J Y, et al. Spectral temporal graph neural network for multivariate time-series forecasting[C]//Proceedings of the 34th International Conference on Neural Information Processing Systems. New York: ACM, 2020: 17766-17778.
- [36] LIANG Z J, XU Y J, HONG Y F, et al. A survey of multi-model large language models[C]//Proceedings of the 3rd International Conference on Computer, Artificial Intelligence and Control Engineering. New York: ACM, 2024: 405-409.
- [37] ZHOU T, NIU P, SUN L, et al. One fits all: Power gener-

al time series analysis by pretrained lm[C]//Proceedings of the 37th International Conference on Neural Information Processing Systems. New York: ACM, 2023: 43322-43355.

- [38] JIN M, WANG S Y, MA L T, et al. Time-LLM: Time series forecasting by reprogramming large language models[EB/OL]. (2024-01-29)[2025-05-25]. <https://arXiv.org/abs/2310.01728>.
- [39] XUE H, SALIM F D. PromptCast: A new prompt-based learning paradigm for time series forecasting[J]. IEEE Transactions on Knowledge and Data Engineering, 2024, 36(11): 6851-6864.
- [40] LI Z H, XIA L H, TANG J B, et al. UrbanGPT: Spatio-temporal large language models[C]//Proceedings of the 30th ACM SIGKDD Conference on Knowledge Discov-

ery and Data Mining. New York: ACM, 2024: 5351-5362.

- [41] GRUVER N, FINZI M, QIU S, et al. Large language models are zero-shot time series forecasters[C]//Proceedings of the 37th International Conference on Neural Information Processing Systems. New York: ACM, 2023: 19622-19635.
- [42] WANG J Y, JIANG J W, JIANG W J, et al. LibCity: An open library for traffic prediction[C]//Proceedings of the 29th International Conference on Advances in Geographic Information Systems. New York: ACM, 2021: 145-148.
- [43] ZHENG Y, LIU F R, HSIEH H P. U-Air: When urban air quality inference meets big data[C]//Proceedings of the 19th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM, 2013: 1436-1444.

作者简介



梅雅欣 女,1996年12月出生于安徽省芜湖市.现为北京师范大学人工智能学院博士研究生.主要研究方向为数据挖掘、边缘智能、物联网.

E-mail: meiyax@163.com



秦慧玲 女,1996年8月出生于广西壮族自治区桂林市.现为北京师范大学珠海校区讲师、博士生导师.主要研究方向为时空数据挖掘、城市计算.主持国家级科研项目1项,在国内外发表顶级学术论文十余篇.中国电子学会会员编号:E190188248M.

E-mail: qinhuilin@bnu.edu.cn



梁玉珠 男,1994年10月出生于安徽省亳州市.2025年毕业于北京师范大学人工智能学院,现为北京师范大学博士后.

E-mail: yuzhuliang@bnu.edu.cn



张广学 男,1992年1月出生于河南省开封市.现为北京师范大学珠海校区自然科学高等研究院工程师.主要研究方向为声纹识别、语音识别、边缘智能.

E-mail: guangxue_zhang@bnu.edu.cn



王田 男,1982年2月出生于湖南省汨罗市.现为北京师范大学长聘教授、博士生导师,国家级青年拔尖人才.主要研究方向为物联网、边缘智能.中国电子学会会员编号:E190026040M.

E-mail: tianwang@bnu.edu.cn