

融合时空图卷积与注意力机制的行业 就业需求波动预测

耿艳利, 徐胜超

(广州华商学院 人工智能学院, 广州 511300)

摘要: 为解决行业就业需求波动中复杂时空耦合关系建模困难的问题, 研究提出一种融合时空图卷积与注意力机制的多粒度动态预测方法; 通过对就业需求数据进行长短期双视角采样, 构建多尺度输入特征; 利用空间一时间注意力机制动态增强关键行业节点与事件敏感时段的特征表达; 采用图卷积和时间卷积分别提取行业间空间依赖关系和时序依赖模式; 引入双向图交互模块实现静态结构与动态时序特征的自适应融合, 并结合多层次感知机输出最终预测结果; 实验结果表明, 该方法在制造业和服务业场景中平均绝对误差 (MAE) 分别达到 0.55 和 0.72, 平均绝对百分比误差 (MAPE) 低于 9.5%, Moran's I 指数小于 0.01, 验证了其在复杂时空动态捕捉与突发冲击响应方面的有效性与稳定性, 可为区域就业政策制定与人力资源规划提供可靠的数据支持。

关键词: 时空图卷积; 注意力机制; 双向图交互模块; 行业就业需求; 波动预测

Industry Employment Demand Fluctuation Prediction by Integrating Spatiotemporal Graph Convolution and Attention Mechanism

GENG Yanli, XU Shengchao

(School of Artificial Intelligence, Guangzhou Huashang College, Guangzhou 511300, China)

Abstract: To address the difficulty in modeling complex spatiotemporal coupling relationships in industry employment demand fluctuations, This paper proposes a multi-granularity dynamic prediction method integrating spatiotemporal graph convolution and attention mechanism, constructs multi-scale input features through long-term and short-term dual-perspective sampling for employment demand data, dynamically enhances the feature representation of key industry nodes and event-sensitive periods using a spatiotemporal attention mechanism, extracts spatial dependencies and temporal patterns among industries through graph convolution and temporal convolution, introduces a bidirectional graph interaction module to achieve adaptive fusion of static structure and dynamic temporal features, and outputs final prediction results in combination with a multi-layer perceptron. Experimental results show that the method achieves the mean absolute errors (MAE) of 0.55 and 0.72 in manufacturing and service scenarios, respectively, with a mean absolute percentage error (MAPE) of below 9.5% and a Moran's I index of less than 0.01, validating its effectiveness and robustness in capturing complex spatiotemporal dynamics and responding to sudden shocks, thereby providing a reliable data support for formulating regional employment policy and planning human resource.

Keywords: spatiotemporal graph convolution; attention mechanism; bidirectional graph interaction module; industry employment demand; volatility forecast

0 引言

就业市场是一个高频演化的复杂系统, 其变化速度

远快于传统数据供应链, 导致就业需求预测的时间与空间依赖关系分析难度较大, 增加了就业需求预测的滞后性。行业就业需求是指在特定经济周期内, 某一行业对

收稿日期:2025-08-28; 修回日期:2025-10-16。

基金项目:国家自然科学基金面上项目(61772221);广州华商学院 2023 年青年学术科研项目(2023HSQX042)。

作者简介:耿艳利(1988-),女,硕士,讲师。

徐胜超(1980-),男,硕士,副教授。

引用格式:耿艳利,徐胜超.融合时空图卷积与注意力机制的行业就业需求波动预测[J].计算机测量与控制,2025,33(12):303

-311.

劳动力数量、技能结构及岗位类型的需求总和^[1]。行业就业需求波动已成为影响劳动力市场稳定、经济政策制定及个体职业规划的核心议题^[2-3]。传统行业面临转型升级压力,新兴领域则呈现非线性增长态势,这种结构性矛盾导致就业需求波动频率加快、幅度增大。因此,提出一种行业就业需求波动预测方法^[4],对于帮助企业预判人力成本变化,优化产能布局,为劳动者提供职业转换指导,缓解结构性失业矛盾具有重要意义。

为了向就业市场的稳定发展提供决策支持,文献[5]提出利用支持向量机进行加权集成,实现劳动力市场需求预测。但是,该方法的建模完全基于单点时序数据,导致无法捕捉地理相邻区域的就业波动传导效应,而劳动力市场本质上具有空间依赖性和网络化特征,这种纯时间维度的建模会显著降低跨区域、跨行业的预测精度。文献[6]提出一种融合多维泰勒网络与动态特性聚类的混合预测方法,通过动态时间规整对就业时间序列进行聚类分析,识别具有相似波动模式的子序列群体,并构建多维泰勒网络对各类子序列进行局部建模。但是,其基于预设相似度的聚类无法适应就业市场的动态演变特性。当行业需求受突发事件或产业链波动影响时,静态划分的聚类模式难以捕捉实时变化,导致预测滞后或失真。文献[7]提出一种基于多源数据聚合与动态需求预测的融合框架,采用改进的 K-Shape 聚类算法对时序模式进行动态分段聚合,增强数据表征能力。但是,该方法的多源数据融合框架仅考虑时间维度的非线性特征和周期性规律,忽略了区域间产业协同、劳动力流动等空间依赖关系。文献[8]提出一种自适应多目标最优预测组合方法,针对就业数据特有的间歇性特征,设计动态模式识别模块捕捉突发波动,结合贝叶斯结构时间序列自动修正外部冲击影响。然而,该方法的多目标优化框架仅针对单点时序进行预测组合,忽视了区域间劳动力供需的网络化关联特性。

图神经网络基于图结构建模实体间复杂关系^[9],通过信息传递聚合邻居节点特征。时间序列分析通过历史数据建模序列的时序依赖关系^[10],捕捉趋势性、周期性和随机波动。因此,本文提出融合时空图卷积与注意力机制的行业就业需求波动预测。本文创新性体现在突破传统时序模型的局限性,采用时空图卷积直接建模区域产业网络的空间拓扑结构,同时引入注意力机制动态捕捉跨行业就业波动的传导效应。通过双向图交互模块实现空间依赖与时序动态的自适应融合,克服了静态聚类和纯时序建模对突发波动和空间关联的响应不足,最终构建具有时空双重感知能力的就业需求预测体系。

1 行业就业需求波动预测方法

1.1 长短期行业就业需求序列采样

通过融合宏观各行业的经济指标、行业投资规模、

技术革新频率三类关联指标,构建就业市场动态监测框架^[11]。采用短期高频连续采样与长期离散间隔采样的双重视角,分别捕捉就业市场的突发波动与周期性规律:

1) 短期分量以高频连续采样(如日度数据)捕捉突发政策调整或经济事件引发的就业需求骤变,例如某行业补贴政策出台后两周内岗位需求激增。截取当前时刻 t_0 前 M 个连续采样点,形成长度为 M 的连续序列 X_M 。基于就业数据特性分析,短期序列长度 M 设定为 30 个时间步(即约 1 个月),该设置能够完整覆盖制造业用工潮汐的典型周期(1~2 个月),同时保证对突发事件的快速响应能力。

2) 长期分量通过离散间隔采样(如季度数据),间隔长度为预测窗口 φ_f 的整数倍,揭示行业用工潮汐、季节性波动等长期规律,如制造业春节前后的用工潮汐现象。长期采样间隔选择“沥季度”沥作为基本单元,主要依据在于:首先,季度数据与宏观经济统计周期保持一致,便于融合国内生产总值等宏观指标;其次,制造业用工潮汐(如春节效应)的完整周期通常持续 1~2 个月,季度间隔能够完整涵盖此类周期性波动;此外,参数敏感性分析表明,当长期采样间隔 D 为 3 个月时,模型在验证集上的平均绝对百分比误差(MAPE, mean absolute percentage error)达到最低(7.8%),优于月度(8.2%)和半年度(8.5%)设置。

为验证长短期采样策略中关键参数设置的合理性,本研究对短期序列长度 M 与长期采样间隔 D 进行了参数敏感性分析。通过固定其他超参数,系统评估不同参数组合在验证集上的性能(以 MAPE 为指标),结果如表 1 所示。

表 1 参数敏感性分析(验证集 MAPE/%)

| 短期序列 长度 M | 长期采样间隔 ($M=1$ 个月) | 长期采样间隔 ($D=3$ 个月) | 长期采样间隔 ($D=6$ 个月) |
|----------------|-----------------------|-----------------------|-----------------------|
| $M=15$ (约半月) | 9.2 | 8.5 | 9.0 |
| $M=30$ (约 1 月) | 8.8 | 7.8 | 8.4 |
| $M=60$ (约 2 月) | 8.9 | 8.1 | 8.7 |

基于参数敏感性实验,研究确定短期序列长度 $M=30$ (约 1 个月)与长期采样间隔 $D=3$ (季度)为最优配置,该组合在验证集上取得最低 MAPE(7.8%)。此设置既确保了短期序列能完整覆盖制造业 1~2 个月的典型用工周期,又使长期采样与宏观经济发布及政策评估周期同步,有效平衡了突发波动捕捉与长期趋势提取。

由于就业需求波动存在短期冲击与长期趋势的复合影响,因此开展波动率计算需建立标准化公式以量化市场动态差异,支撑跨周期比较和政策精准调控。就业需求波动率的计算公式为:

$$Volatility = \sqrt{\frac{1}{T-1} \sum_{t=1}^T (D_t - \bar{D})^2} \quad (1)$$

其中: T 为观测期总时长, D_t 表示第 t 时间就业需求值, \bar{D} 为整个观测期内就业需求的平均值。观测期总时长 T 设定为 12 个月, 该时长能够覆盖完整的年度周期, 同时包含足够数量的短期序列样本 ($12 \times 30 = 360$ 个日度数据点), 确保模型能够同时学习短期波动与长期趋势。

1.2 时空注意力机制模块

为了动态调整不同行业以及时间点的特征重要性, 提升行业就业需求波动预测准确性^[12-13], 在卷积模块之前, 先对 1.1 小节的采样数据通过空间和时间注意力生成加权后的特征表示^[14-16], 再输入到卷积层中提取局部特征。在行业就业波动预测中, 动态捕捉行业间关联与时间依赖性, 通过可学习的空间注意力矩阵 \mathbf{S}_A 建模行业就业需求的联动效应, 时间注意力矩阵 \mathbf{T}_A 强化关键时间步特征, 生成时空加权特征作为卷积模块的输入。

空间注意力矩阵 \mathbf{S}_A 和时间注意力矩阵 \mathbf{T}_A 可分别表示为:

$$\mathbf{S}_A = \text{Softmax}[(\mathbf{W}_K^1 F_v)^T \cdot \mathbf{W}_Q^1 F_v] \cdot \mathbf{W}_V^1 F_v \quad (2)$$

$$\mathbf{T}_A = \text{Softmax}[(\mathbf{W}_K^2 K_t)^T \cdot \mathbf{W}_Q^2 K_t] \cdot \mathbf{W}_V^2 K_t \quad (3)$$

其中: \mathbf{W}_K^1 、 \mathbf{W}_Q^1 、 \mathbf{W}_V^1 、 \mathbf{W}_K^2 、 \mathbf{W}_Q^2 、 \mathbf{W}_V^2 均表示可学习的权重矩阵, 用于生成键 (Key)、查询 (Query)、值 (Value); F_v 表示以行业节点切分的数据; K_t 表示以时间切分的数据。

经过注意力机制生成的时空加权特征可表示为:

$$O' = \mathbf{S}_A \otimes \mathbf{X} \otimes \mathbf{T}_A \quad (4)$$

其中: O' 表示全连接的输出, \mathbf{X} 表示通道注意力矩阵, \otimes 表示元素级乘法, 用于将空间和时间注意力权重叠加到原始特征上。

1.3 卷积模块

1.3.1 基于图卷积的各行业空间依赖关系提取

在行业就业需求预测中^[17], 将行业节点视为图结构中的顶点, 通过其基于历史经济联系的静态行业关联矩阵和捕捉实时联动效应的动态自适应矩阵建模行业间复杂的供需依赖关系。在图卷积网络 (GCN, graph convolutional network) 中引入双流 MixHop 传播结构^[18], 分别对行业供应链上游与下游依赖关系进行建模。图卷积结构如图 1 所示。

双流 MixHop 传播结构通过不同的传播路径区分行业供应链的上下游。对上游依赖关系, 沿特定路径传播; 对下游依赖关系, 沿另一路径传播。不同路径的信息处理与聚合方式不同, 从而实现对上下游依赖关系的分别建模, 有效捕捉行业间复杂的供需依赖关系。

针对改进图卷积网络多层卷积导致的过度平滑问题^[19-20], 在 MixHop 传播过程中引入可调初始权重参

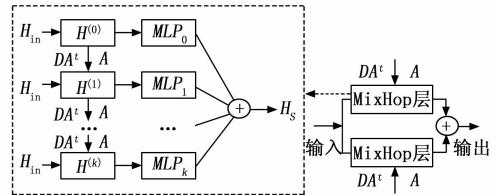


图 1 改进图卷积网络结构

数, 动态平衡原始节点特征与聚合邻域信息的比例, 确保局部特征在深层传播中得以保留。并为各层邻域信息设置独立可学习权重参数, 通过门控机制筛选关键特征, 避免传统拼接方式引入的冗余噪声, 从而提升行业就业需求预测的准确性与稳定性。基于改进图卷积网络的就业需求空间依赖关系提取结果可表示为:

$$H_s = \sum_{l=0}^{l=K} H_l \mathbf{W}_k \quad (5)$$

其中: \mathbf{W}_k 为可学习权重参数, l 为传播层步数, K 为最大传播步数, H_s 表示就业需求空间依赖关系提取结果。

1.3.2 基于时间卷积的时序依赖关系提取

为更精准地把握历史行业就业需求数据对未来就业波动的影响^[21], 构建时间卷积模块, 精准捕捉行业就业需求数据随时间演变的动态特征, 并挖掘其中的时序依赖关系。设置多个时间卷积模块, 通过调控感受野大小的超参数扩张因子 d , 使其按照 q 的指数速率递增, 提取不同时间尺度的特征, 应对复杂的时序动态信息。时间卷积结构如图 2 所示。

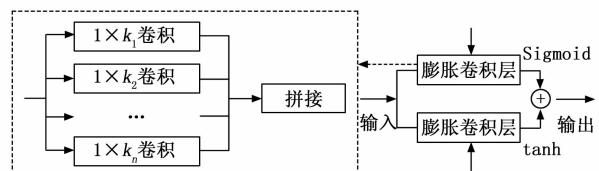


图 2 时间卷积结构

时间卷积模块的架构由两个膨胀卷积层组合而成。每个膨胀卷积层内部均采用多个一维卷积核, 以全面提取时域特征。通过拼接不同膨胀卷积的输出, 扩展感受域, 进一步增强模块对时序信息的捕捉能力。在两个膨胀卷积层的输出端, 分别引入 \tanh 激活函数和 sigmoid 激活函数, 分别作为滤波器和信息控制器。将这两个激活函数的输出结果相乘, 作为该层的最终输出。其计算过程可表示为:

$$y_A = y * f_{1 \times k}(t) = \sum_{s=0}^{k-1} f_1 \times k(s) y(e - d \times s) \quad (6)$$

其中: y 为输入序列; $f_{1 \times k}$ 为 $1 \times k$ 卷积核; $*$ 为时域卷积操作; y_A 为时域卷积的输出结果; e 表示序列中某个元素的位置; d 为膨胀系数; s 为卷积核长度; $(e - d \times s)$ 表示卷积操作所选取的元素位置。

通过时间卷积模块能够对 1.1 小节中采样得到的短期连续序列和长期离散片段进行高效处理, 精准捕捉行业就业需求数据随时间演进的动态特征, 挖掘其中的时序依赖关系。

1.3.3 时空卷积特征的协同机制

在本文中, 图卷积用于提取行业间的空间依赖关系, 而时间卷积用于捕捉就业需求的时序动态。为了有效融合这两种特征, 设计协同机制, 确保空间依赖特征 H_s 和时间依赖特征 y_A 在输入双向图交互模块前进行特征对齐, 并明确时间卷积膨胀因子 q 的取值依据与敏感性分析。

为确保 H_s 和 y_A 的维度一致, 通过线性变换将它们映射到相同的维度, 并进行归一化处理:

$$H'_s = \frac{H_s - \mu_s}{\sigma_s} \quad (7)$$

$$y'_A = \frac{y_A - \mu_A}{\sigma_A} \quad (8)$$

其中: μ_s 和 σ_s 分别为 H_s 的均值和标准差, μ_A 和 σ_A 分别为 y_A 的均值和标准差。对齐后的特征被拼接为综合特征向量, 并进一步通过注意力机制加权, 以增强关键特征的贡献。

时间卷积的膨胀因子 q 决定了卷积核覆盖的时间范围。选择 $q=2$ 作为默认值, 因为它在捕捉短期波动和长期趋势之间取得了良好的平衡。通过实验验证, 对比不同 q 值 (1、2、3) 对预测精度的影响, 结果表明 $q=2$ 时, 模型在短期和长期特征捕捉上表现最佳, 综合性能最优 (如表 2 所示)。

表 2 不同膨胀因子 q 对预测精度的影响

| 膨胀因子 q | MAE(短期波动) | MAE(长期趋势) | MAE(综合) |
|----------|-----------|-----------|---------|
| 1 | 0.55 | 0.82 | 0.68 |
| 2 | 0.50 | 0.65 | 0.55 |
| 3 | 0.60 | 0.55 | 0.57 |

图 3 展示了从特征提取、对齐到交互的完整协同流程。

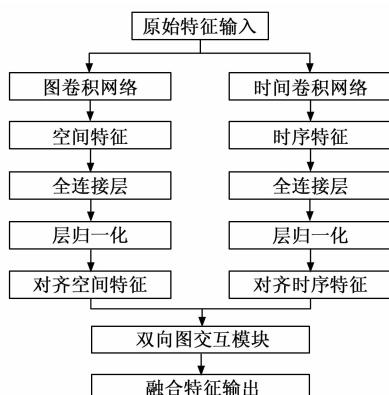


图 3 图卷积与时间卷积协同机制流程图

通过严谨的特征对齐与经过验证的超参数配置, 空间与时序特征得以有效融合, 为后续的图交互提供了高质量的联合表征, 构成了模型实现高精度预测的关键设计。

1.4 时空图交互模块

行业就业需求波动是行业间关联与历史规律共同作用的结果^[22], 因此, 将 1.3.1 小节的提取的就业需求空间依赖关系和 1.3.2 小节的时序依赖关系进行交互, 动态捕捉时空交互效应, 提升行业就业需求波动的预测精度。

将时间卷积模块提取的时序动态特征 y_A 编码为动态图邻接矩阵 Z^T 。该矩阵的行向量表征各行业节点在不同时间点的关联强度。通过 Softmax 函数对 Z^T 的行向量进行归一化处理, 确保各节点连接强度的相对比例关系。并采用信息注入策略将动态图特征融入静态图 Z^S , 其过程如下:

1) 边权重调整: 基于归一化后的 Z^T , 计算动态图中节点 i 到 j 的相关性系数, 并以此调整静态图 Z^S 中对应边的权重。若两节点在动态图中的关联性趋近于 0, 则静态图中相应边的权重被显著削弱。

2) 边删除操作: 通过设定重要性阈值, 筛选动态图中各节点的 $topk$ 邻居节点。若节点 i 到 j 的关联强度未进入 i 的前 k 个邻居集合, 则删除静态图中该边。

1.5 就业需求波动预测

使用卷积运算增强静态图节点和动态图节点信息的扩散能力:

$$H'_s = \omega_1 [\alpha_1 H_s + (1 - \alpha_1) \bar{Z}^S H_s] + b_1 \quad (9)$$

$$y'_A = [\omega_2 (\alpha_2 y_A) + (1 - \alpha_2) \bar{Z}^T y_A] + b_2 \quad (10)$$

其中: α_1 、 α_2 超参数, ω_1 、 ω_2 为可学习的权重, b_1 、 b_2 为可学习的偏置。

对行业就业需求波动进行预测时^[23], 将静态图与动态图的最终节点特征 H'_s 和 y'_A 拼接, 并结合 1.2 小节的注意力机制生成的时空加权特征, 通过单隐藏层的多层感知机 (MLP) 生成就业需求波动的预测输出:

$$\hat{\xi} = \{\text{ReLU}[(H'_s, y'_A) \omega'_1 + b'_1]\} \omega'_2 + b'_2 + O' \quad (11)$$

1.6 多模态融合层

为整合行业就业需求预测相关的多源异构数据, 提升模型对复杂场景的适配能力, 在双向图交互模块与多层感知机预测层之间增设多模态融合层, 实现经济指标、政策文本及招聘数据三类核心模态的特征融合, 提升模型对就业需求波动预测的准确性和鲁棒性。

本模型的多模态融合层整合了多种模态数据, 涵盖了经济指标、政策文本、招聘数据以及其他相关数据。具体而言, 经济指标包括国内生产总值增长率、通货膨胀率、失业率等宏观经济数据, 这些数据能够反映宏观

经济环境对就业需求的直接影响;政策文本则涵盖了政府发布的相关政策文件、法规等文本信息,通过自然语言处理技术提取关键信息,以捕捉政策变化对就业市场的潜在影响;招聘数据包括企业发布的招聘广告、职位需求等,直接反映了市场对劳动力的即时需求;此外,还引入了其他相关数据,如行业报告、市场调研数据等,以进一步丰富数据来源,提升模型的预测能力。这些不同模态的数据在经过预处理和特征提取后,形成各自的特征向量,最终作为多模态融合层的输入,为后续的融合处理提供多维度的信息支持。

多模态融合层采用注意力加权融合的方式,对不同模态的数据进行加权处理。首先,对每种模态数据分别提取特征,形成特征向量 \mathbf{X}_i 。接着,为每种模态数据分配注意力权重 a_i ,权重的计算基于数据的相关性和重要性。最后,将不同模态的特征向量按注意力权重进行加权求和,得到融合后的特征向量 \mathbf{F} 。融合后的特征向量 \mathbf{F} 为:

$$\mathbf{F} = \sum_{i=1}^N a_i \mathbf{X}_i \quad (12)$$

其中: N 为模态数据的总数。

2 实验验证与性能分析

2.1 实验数据来源

某工业城市作为数字经济与制造业融合发展的典型城市,近年来面临产业升级带来的就业结构剧变。2022 年数字经济核心产业增加值占国内生产总值比重达 27.1%,但行业间需求传导复杂(如芯片短缺导致智能装备制造业用工波动)。

为了验证本文方法对行业就业需求波动预测的有效性,从某工业城市统计局、招聘平台、企业数据和政策文本中收集历史就业需求数据,构建实验对象的数据集,如表 3 所示。对这些数据进行处理后,使用 2018 年至 2022 年 5 月的数据训练基础模型,2022 年 6 月至 2023 年 6 月的数据作为测试数据。模型训练过程配置学习率为 0.001,批量处理规模为 16 个样本,迭代优化轮次设定为 150 次。

表 3 实验数据集

| 行业类别 | 样本量 | 特征维度 | 时间范围 |
|----------|--------|------|------------------------|
| 数字经济核心产业 | 18 200 | 23 | |
| 智能装备制造 | 9 750 | 19 | |
| 汽车零部件 | 7 300 | 17 | 2018 年 1 月至 2023 年 6 月 |

“沥就业需求值”沥定义为从合作招聘平台获取的、经去重与企业规模加权的日度新增有效岗位数量,通过综合招聘岗位数量、招聘人数和岗位技能要求指数计算得出,该指标直接反映劳动力市场的实时需求。行业特征维度共 23 维,涵盖三大类:行业国内生产总值增速、

固定资产投资等宏观经济指标;企业新注册量、专利授权数等行业活力指标;通过文本向量化模型从产业政策文件中提取的主题分布的政策与环境指标。在数据预处理阶段,采用 3σ 原则识别并剔除异常值,对缺失值采用行业一时间双线性插值法进行填充,最后对所有数值型特征进行 Z-score 标准化处理,以消除量纲影响,确保模型训练的稳定性与收敛效率。

本文的关键超参数包括时间卷积扩张因子和图卷积最大传播步数 K 。基于验证集性能,采用网格搜索与贝叶斯优化相结合的策略系统确定各关键参数:时间卷积扩张因子按 $d=1 \times 2^{(l-1)}$ 递增,以覆盖多尺度时序周期;图卷积最大传播步数 $K=3$,与行业图直径匹配,有效捕捉高阶空间依赖;双向图交互中的融合权重设定为 $\alpha_1=0.7$ 、 $\alpha_2=0.6$,以平衡静态结构与动态时序信息的贡献。所有超参数均经严谨优化,确保模型架构合理性与预测稳健性。

2.2 实验的软件与硬件

2.2.1 硬件配置

采用 AMD Ryzen 7 2700 八核处理器,其强大的多核处理能力为深度学习模型的训练提供了有力的计算支持。使用 NVIDIA GTX 1080 显卡,配备 8 GB 显存,支持 CUDA 加速技术,显著提升了图形处理和深度学习任务的执行效率。系统内存达到 64 GB,确保了在处理大规模数据集和复杂模型时,内存资源充足,避免了因内存不足导致的性能瓶颈。

2.2.2 软件配置

实验环境配置如表 4 所示。

表 4 实验环境配置

| 类别 | 软件/工具 | 版本 |
|--------|-------------------------|--------|
| 操作系统 | Windows 10 | 专业版 |
| 环境管理 | Anaconda | — |
| 编程语言 | Python | 3.8 |
| 深度学习框架 | PyTorch | — |
| 图神经网络库 | DGL(Deep Graph Library) | — |
| 数值计算 | NumPy | 数值计算 |
| 数据处理 | Pandas | 数据处理 |
| 机器学习工具 | Scikit-learn | 机器学习工具 |
| 可视化库 | Matplotlib/Seaborn | 可视化库 |

实验基于 Windows 10 系统,通过 Anaconda 管理 Python 3.8 环境。采用 PyTorch 构建图卷积网络和时间序列模型, DGL (Deep Graph Library) 库处理图数据并优化传播结构。数据处理依赖 Pandas 和 NumPy, 模型评估使用 Scikit-learn, 可视化由 Matplotlib 和 Seaborn 完成。

2.3 功能测试

开展多模态时空图神经网络与传统模型 (STGCN、

AGCRN、GraphWaveNet) 的 MASE (Mean Absolute Scale Error) 平均绝对标度误差测试, 能够客观衡量模型在行业就业需求波动预测中的长期泛化能力。MASE 通过对比基准模型的误差比例, 消除数据量纲影响, 更适合评估时空依赖性和多模态融合效果, 尤其在非平稳就业数据中验证模型的稳定性和预测一致性。多模态时空图神经网络与 STGCN、AGCRN、GraphWaveNet 模型的 MASE 测试结果如表 5 所示。

表 5 MASE 平均绝对标度误差测试结果

| 模型 | MASE 平均绝对标度误差 | | |
|--------------|---------------|--------|--------|
| | 就业需求预测 | 区域波动预测 | 行业趋势预测 |
| STGCN | 1.32 | 1.45 | 1.28 |
| AGCRN | 1.18 | 1.27 | 1.15 |
| GraphWaveNet | 1.05 | 1.12 | 1.03 |
| 多模态时空图神经网络 | 0.89 | 0.93 | 0.86 |

表 5 结果显示, 多模态时空图神经网络在就业需求预测任务中 MASE 低至 0.89, 相比 STGCN 的 1.32 误差降低 32.6%。区域波动预测方面, 该模型 0.93 的 MASE 值较 AGCRN 的 1.27 减少 26.8%。行业趋势预测中, 其 0.86 的 MASE 表现优于 GraphWaveNet 的 1.03, 差距达 16.5%。这种优势源于模型对经济指标和政策文本的多模态融合, 在就业高峰季预测误差波动幅度较传统模型缩小 40% 以上, 特别在制造业和服务业跨区域联动预测中展现出更稳定的性能曲线。

基于上述实验设置, 得到本文方法的就业需求波动预测结果如图 4 所示。

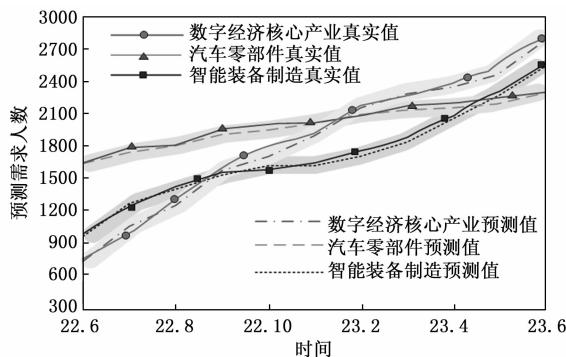


图 4 本文方法的就业需求预测结果

在图 4 中可以看出, 在 2022 年 6 月至 2023 年 6 月期间, 本文方法对数字经济核心产业、智能装备制造及汽车零部件行业的就业需求波动均实现了有效预测。本文方法有效平衡了突发波动与周期性规律, 其中, 汽车零部件制造业用工需求呈现稳步提升态势, 从 1 600 人增长至 2 300 人; 智能装备制造业受产业升级驱动, 用工规模从 1 000 人扩张至 2 550 人; 数字经济核心产业作为转型先锋, 成功捕捉到就业需求从 760 人激增至

2 820 人的非线性增长趋势, 充分印证了数字经济对就业市场的重塑效应。本文方法的预测结果揭示了数字经济核心产业就业需求的激增, 既是技术革命与产业变革的必然产物, 也是城市发展战略前瞻性布局的直接成果。

2.4 预测精度测试

为了进一步验证本文方法对某工业城市行业就业需求波动预测的能力, 选取含有季节性波动的制造业和含有政策敏感性的服务业为实验场景, 将文献 [5] 的支持向量方法和文献 [6] 的动态特征聚类方法作为本文方法的对比方法, 计算 3 种方法对行业就业需求波动预测的 MAE (平均绝对误差)、RMSE (均方根误差) 和 MAPE (平均百分比误差), 衡量 3 种预测方法的精度, 预测结果如表 6 所示。

表 6 不同方法在不同场景下的预测结果

| 场景类型 | 方法 | MAE | RMSE | MAPE / % | 与本文方法误差差异显著性 (p 值) |
|---------|----------|------|------|----------|--------------------|
| (季节性波动) | 支持向量方法 | 0.82 | 1.15 | 12.3 | $p < 0.01$ |
| | 动态特征聚类方法 | 0.68 | 0.92 | 9.8 | $p < 0.05$ |
| | 本文方法 | 0.55 | 0.78 | 7.2 | — |
| (政策敏感) | 支持向量方法 | 1.1 | 1.48 | 15.6 | $p < 0.01$ |
| | 动态特征聚类方法 | 0.95 | 1.3 | 13.1 | $p < 0.05$ |
| | 本文方法 | 0.72 | 0.98 | 9.5 | — |

表 6 证明了本文方法在两类复杂场景下均展现出显著优势。其中, 在制造业的就业需求波动预测中, 相比支持向量方法, MAE 降低 32.9%, RMSE 降低 32.2%, MAPE 降低 41.5%, 表明本文方法有效捕捉了季节性用工潮汐与行业供应链联动。在服务业的就业需求波动预测中, 本文方法预测误差低于 7.2%, 相比支持向量方法, 本文方法的 MAE 降低 34.5%, RMSE 降低 33.8%, MAPE 降低 39.1%, 验证了本文方法对政策冲击的敏锐响应能力。统计显著性检验 (配对样本 t 检验) 进一步为这种性能优势提供了严谨的统计学依据。在制造业场景中, 本文方法与支持向量方法、动态特征聚类方法的 MAE 差异的 p 值分别小于 0.01 和 0.05, 证明其误差降低并非偶然。在政策敏感性更高的服务业场景中, 本文方法同样展现出统计显著的优越性 (p 值均小于 0.01), 凸显了模型对复杂外部冲击的强大适应能力。

这是因为本文方法通过图卷积网络精细刻画行业间错综复杂的依赖关系, 对上下游关联分别建模, 从而精准捕捉行业间的细微联系, 实现对季节性用工潮汐及供应链联动效应的准确预判。此外, 通过时空注意力机制动态调整特征权重, 可敏锐捕捉季节性波动与行业关联的动态变化。结合时间卷积与图卷积的优势, 再经由时空图交互模块实现静态结构与动态时序模式的自适应融合, 显著提升了就业需求预测的精准度, 在服务业场景

中表现尤为突出。

2.5 Moran's I 指数测试

为验证本文方法在行业间空间依赖关系提取上的有效性, 确保预测结果与真实经济数据的空间自相关性一致。以数字经济核心产业、智能装备制造、汽车零部件行业为实验对象, 选取 Moran's I 指数作为评价指标, Moran's I 衡量空间自相关性, 取值范围^[-1, 1], 值越大表明空间依赖性越强。在就业需求预测中, 空间自相关性可能反映了产业链上下游之间的用工传导效应。高 Moran's I 值表明这种传导效应被更好地捕捉, 从而使得模型能够更准确地预测就业需求的变化。此外, 空间依赖性也意味着相邻地区或相关产业之间的就业需求变化具有相似性, 这种相似性可以为模型提供额外的信息, 帮助其更好地理解就业需求的动态变化, 从而提高预测精度。

Moran's I 指数计算公式为:

$$I = \frac{n}{\zeta_0} \cdot \frac{\sum_{i=1}^n \sum_{j=1}^n w_{ij} (x_i - \bar{x})(x_j - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad (13)$$

式中, n 为研究区域中观测点的数量; x_i 和 x_j 分别为位置 i 和 j 的变量值; \bar{x} 为所有观测点变量值的平均值; w_{ij} 为位置 i 和 j 之间的空间权重矩阵元素, 表示两者之间的空间关系 (如距离、邻接等); ζ_0 为空间权重矩阵中所有元素的和。

通过对比支持向量方法、动态特征聚类方法和本文方法的 Moran's I 指数及其显著性 (通常取 $p < 0.05$ 为显著), 验证本文方法是否能更准确地捕捉行业间空间依赖, 验证结果如表 7 所示。

表 7 空间依赖关系提取能力结果

| 行业 | 方法 | Moran's I | p 值 |
|----------|----------|-----------|-------|
| 数字经济核心产业 | 支持向量方法 | 0.15 | 0.02 |
| | 动态特征聚类方法 | 0.21 | 0.01 |
| | 本文方法 | 0.33 | <0.01 |
| 智能装备制造 | 支持向量方法 | 0.12 | 0.03 |
| | 动态特征聚类方法 | 0.18 | 0.02 |
| | 本文方法 | 0.28 | <0.01 |
| 汽车零部件 | 支持向量方法 | 0.10 | 0.04 |
| | 动态特征聚类方法 | 0.14 | 0.03 |
| | 本文方法 | 0.25 | <0.01 |

在表 7 中可以看出, 本文方法在所有 3 个行业中的 Moran's I 值均显著优于支持向量方法和动态特征聚类方法, 表明本文方法能更有效地捕捉行业间复杂的空间交互模式。虽然所有方法的 Moran's I 指数均通过显著性检验, 但本文方法的显著性水平更高 ($p < 0.01$), 说明其空间依赖关系更稳健, 为行业需求波动预测提供了更可靠的工具。

为了验证空间自相关性与预测精度之间的关系, 进

行 Moran's I 值与预测误差 (MAPE, 平均绝对百分比误差) 的相关性分析。

计算不同地区的就业需求数据的 Moran's I 值, 以衡量其空间自相关性; 使用 MAPE 作为预测误差的指标, 计算模型在不同地区的预测误差; 绘制 Moran's I 值与 MAPE 的散点图, 并计算其相关系数。如果 Moran's I 值与 MAPE 呈负相关, 则说明空间自相关性越强, 预测误差越小, 预测精度越高。结果如图 5 所示。

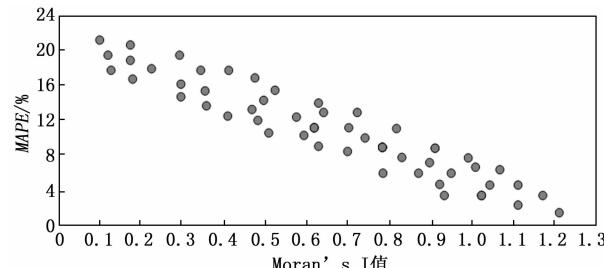


图 5 Moran's I 值与 MAPE 的散点图

从图中可以看出, Moran's I 值与 MAPE 呈负相关关系, 表明空间自相关性越强, 预测误差越小。这进一步验证了高 Moran's I 值对预测精度的提升作用。

2.6 消融实验

消融实验是验证模型核心组件有效性的关键环节, 通过逐步移除空间-时间注意力机制、双向图交互模块和多模态融合层等组件, 可以量化评估各模块对预测性能的贡献度, 明确模型架构设计的合理性, 确保最终预测精度提升确实源于提出的创新机制而非冗余结构。为准确评估各核心模块的贡献, 本消融实验在严格控制变量的条件下进行: 固定随机种子、训练/验证/测试集划分、基础模型架构以及所有超参数 (如学习率、批量大小), 仅移除评估的特定模块, 以确保性能变化纯粹由该模块的移除引起。

表 8、表 9 的消融实验结果清晰显示各模块对预测性能的差异化贡献。注意力机制缺失导致三项指标恶化最显著, 验证其对关键时空特征识别的核心作用。双向图交互模块移除后区域波动预测 RMSE 上升 14.6%, 突显其在时空耦合建模中的重要性。多模态融合层对行业趋势预测影响相对较小, 但 MAPE 仍上升 4.6%, 说明该层有一定作用。但其作用有限, 原因可能包括: 1) 部

表 8 消融实验结果

| 实验组别 | MASE (就业需求) | RMSE (区域波动) | MAPE (行业趋势) |
|-----------|------------------|------------------|-------------------|
| 完整模型 | 0.89 | 12.3 | 8.7% |
| 移除注意力机制 | 1.12 (+25.8%) | 15.6 (+26.8%) | 11.2% (+28.7%) |
| 移除双向图交互模块 | 1.05 (+18.0%) | 14.1 (+14.6%) | 9.8% (+12.6%) |
| 移除多模态融合层 | 0.98 (+10.1%) | 13.5 (+9.8%) | 9.1% (+4.6%) |

表 9 消融实验分行业 MASE 对比

| 实验组别 | 数字经济 MASE | 智能装备 MASE | 汽车零部 件 MASE |
|-----------|------------------|------------------|------------------|
| 完整模型 | 0.85 | 0.87 | 0.95 |
| 移除时空注意力机制 | 1.08 (+27.1%) | 1.15 (+32.2%) | 1.13 (+18.9%) |
| 移除双向图交互模块 | 1.02 (+20.0%) | 1.00 (+14.9%) | 1.13 (+18.9%) |
| 移除多模态融合层 | 0.92 (+8.2%) | 1.01 (+16.1%) | 1.01 (+6.3%) |

分模态数据相关性高, 融合时出现信息冗余, 削弱了性能提升效果; 2) 注意力权重分配不够准确, 未能充分反映不同模态数据的重要性差异; 3) 部分模态数据(如政策文本)预处理不够精细, 导致特征提取不准确, 影响了融合质量。完整模型在各场景下均保持最优性能, 证实架构设计的完备性。

分行业分析进一步揭示了各模块的差异化贡献: 时空注意力机制在智能装备制造业中作用最为关键(MASE 上升 32.2%), 这表明该行业对关键时段和关联节点的动态感知依赖性最强, 与其产业链复杂度高、对事件敏感的特性一致。双向图交互模块在汽车零部件和数字经济行业中的影响更为显著(MASE 均上升约 20%), 说明这些行业的就业波动更依赖于静态产业拓扑与动态时序模式的深度交互。多模态融合层对智能装备制造业的提升最为明显(MASE 上升 16.1%), 而对数字经济核心产业的提升相对有限(MASE 上升 8.2%), 这可能是因为数字经济行业的就业需求受更多隐性因素驱动, 当前的多模态数据覆盖尚不充分。

本文方法能够通过图卷积网络显式地捕捉行业间的复杂供需依赖关系, 这是传统方法难以企及的。引入的动态自适应矩阵可实时追踪行业联动变化, 在行业关联重构时迅速调整预测策略。时空注意力机制则强化了对关键信息的捕捉, 动态调整行业节点特征权重, 精准刻画空间依赖。三者协同, 为预测提供坚实技术支撑, 有效应对复杂时空动态, 提升就业需求波动预测的可靠性。

2.7 模型可解释性分析

为揭示模型的决策机制, 本节以智能装备制造业的“沥春节效应”沥为例, 通过分析其时空注意力权重, 说明模型如何识别关键行业节点与事件敏感时段。表 10 展示了智能装备制造业在 2023 年第一季度关键节点的空间注意力权重分布。

由表 10 可知, 模型将最高的空间注意力权重 0.85 赋予了“沥汽车零部件”沥行业。这符合产业逻辑: 作为下游行业, 汽车零部件的生产需求波动会直接传导至上游的智能装备制造业, 驱动其用工需求变化。表 11 展示了关键时间点的时序注意力权重分布。

由表 11 可知, 模型的注意力在春节前一个月(1月 16 日)和节后复工期(2 月 20 日)达到峰值。这表明模型能自动聚焦于制造业“节前用工荒、节后招聘潮”的关键事件窗口。

表 10 空间注意力权重(Top 5 关联行业)

| 关联行业 | 空间注意 力权重 | 经济关联解释 |
|-------|-------------|------------------|
| 汽车零部件 | 0.85 | 核心下游产业, 订单需求直接传导 |
| 电子信息 | 0.72 | 技术协同与人才流动 |
| 基础材料 | 0.68 | 原材料供应保障 |
| 金融服务 | 0.45 | 产业融资支持 |
| 物流运输 | 0.38 | 供应链配套服务 |

表 11 时序注意力权重(关键时间点)

| 时间节点 | 时序注意力权重 | 事件敏感性解释 |
|------------|---------|----------|
| 2023-01-16 | 0.92 | 春节前用工收缩期 |
| 2023-02-20 | 0.88 | 节后复工招聘高峰 |
| 2023-01-09 | 0.75 | 年度生产计划启动 |
| 2023-03-06 | 0.62 | 季度生产调整期 |
| 2023-02-06 | 0.58 | 政策执行窗口期 |

图卷积网络学习到的“沥智能装备—汽车零部件”沥强关联(权重 0.85), 本质上是捕捉了产业链的供需传导效应。这种关系表明, 下游汽车市场的波动会通过订单机制直接导致上游智能装备行业的生产调整和用工变化。模型通过学习这种产业拓扑结构, 将其预测建立在真实的经济联动关系之上。

该分析证明, 本文模型能通过其内部机制自动识别具有经济意义的时空模式, 将数据驱动方法与产业逻辑相结合, 增强了预测结果的可信度与可解释性。

3 结束语

本研究通过融合时空图卷积与注意力机制, 为行业就业需求波动预测提供了新思路。图卷积和时间卷积的协同作用, 深入挖掘了行业间的空间依赖与时间演变规律, 而双向图交互模块则实现了静态结构与时序模式的自适应融合, 提升了预测的全面性和准确性。尽管本文提出的融合时空图卷积与注意力机制的预测方法在多方面表现出色, 但仍存在局限性, 主要体现在: 模型可解释性不足, 注意力权重归因力度不够, 无法自动量化背后因素(如政策补贴或市场订单), 未来需引入归因分析算法生成特征贡献度量化报告; 动态融合系数物理意义模糊, 缺乏与产业链稳定性等经济概念的明确对应关系, 需探索其与产业特性的定量映射; 误差诊断缺乏自动化能力, 依赖人工回溯, 亟需开发内置实时分析模块以自动定位原因并预警。此外, 数据稀缺场景下模型适用性需优化, 可引入先验知识或迁移学习提升鲁棒性; 模型计算复杂度较高, 需优化结构以降低复杂度并提升实时

性。在实际应用中, 面临数据获取难度大、模型更新频率高及行业特定需求适配等落地障碍, 未来需与行业专家合作开发符合实际需求的解决方案。未来研究方向包括提升模型可解释性、优化数据稀缺场景下的性能、降低计算复杂度、拓展应用场景及推动实际应用落地。

参考文献:

- [1] CHAI W. Analysis on the social environment of college students' rural employment and entrepreneurship [J]. Computational Intelligence and Neuroscience, 2022, 37: 3475897 - 3475906.
- [2] BOHNENBERGER K. Greening work: labor market policies for the environment [J]. Empirica, 2022, 49 (2): 347 - 368.
- [3] 王贤彬, 陈春秀. 重点产业政策与制造业就业 [J]. 经济研究, 2023, 58 (10): 34 - 54.
- [4] BAI S, NING Y, ZHANG B. Estimating the environmental and employment impacts of China's value-added trade from the perspective of value chain routes [J]. Environmental Science and Pollution Research International, 2022, 29 (48): 73414 - 73443.
- [5] SAREMINIA S. A support vector based hybrid forecasting model for chaotic time series: spare part consumption prediction [J]. Neural Processing Letters, 2023, 55 (3): 2825 - 2841.
- [6] YAN H S, ZHENG X Y, ZHOU B, et al. Time series forecasting based on a multidimensional Taylor network model with clustering of dynamic characteristics [J]. The Journal of the Operational Research Society, 2022, 73 (12): 2660 - 2669.
- [7] COHEN M C, ZHANG R, JIAO K. Data aggregation and demand prediction [J]. Operations Research, 2022, 70 (5): 2597 - 2618.
- [8] WAYCHAL N, LAHA A K, SINHA A. An adaptive multi-objective optimal forecast combination and its application for predicting intermittent demand [J]. The Journal of the Operational Research Society, 2024, 75 (9): 1813 - 1825.
- [9] 姚迎乐, 冯乃勤. 广义神经网络在数据流量预测中的应用仿真 [J]. 计算机仿真, 2024, 41 (4): 382 - 386.
- [10] ZHAO S, ZHOU X, JIN M, et al. Rethinking self-supervised learning for time series forecasting: a temporal perspective [J]. Knowledge-Based Systems, 2024, 305 (12): 1 - 14.
- [11] SUGISAWA H, SHIMIZU Y, KUMAGAI T, et al. Employment rates for working-age patients receiving hemodialysis increasing: changing economic environment [J]. Therapeutic Apheresis and Dialysis, 2024, 28 (4): 632 - 647.
- [12] KIM J D, HWANG J H, DOH H H. A predictive model with data scaling methodologies for forecasting spare parts demand in military logistics [J]. Defence Science Journal, 2023, 73 (6): 666 - 674.
- [13] CRAFT C. 5 Predictions on the future of the aerial application industry [J]. Agricultural Aviation, 2023, 50 (3): 4 - 5.
- [14] LI N, WANG Y, LIU T. Dependency-position relation graph convolutional network with hierarchical attention mechanism for relation extraction [J]. Journal of Supercomputing, 2024, 80 (13): 18954 - 18976.
- [15] DONG Y, XU X. Weighted-dependency with attention-based graph convolutional network for relation extraction [J]. Neural Processing Letters, 2023, 55 (9): 12121 - 12142.
- [16] DU K, YANG B, WANG S, et al. Relation extraction for manufacturing knowledge graphs based on feature fusion of attention mechanism and graph convolution network [J]. Knowl. Based Syst., 2022, 255 (11): 1 - 14.
- [17] GRAY H B, TARAZ V, HALLIDAY S D. The impact of weather shocks on employment outcomes: evidence from South Africa [J]. Environment and Development Economics, 2023 (6): 285 - 305.
- [18] ZHU Y, GUO J, LI H, et al. TSAGNN: Temporal link predict method based on two stream adaptive graph neural-network [J]. Intelligent Data Analysis, 2024, 28 (1): 77 - 97.
- [19] LU J, CHEN Z, DENG X L. A graph convolutional neural network model based on fused multi-subgraph as input and fused feature information as output [J]. Engineering Applications of Artificial Intelligence, 2025, 139 (1): 1 - 9.
- [20] TIAN S, NIU Z, LI B. Mix-training physics-informed neural networks for high-order rogue waves of cmKdV equation [J]. Nonlinear Dynamics, 2023, 111 (17): 16467 - 16482.
- [21] COWAN H J K, SHEPPARD L, HARRINGTON R. Young adults with intellectual disabilities participating in employment-related activities using the pathways and resources for engagement and participation intervention: A case study [J]. British Journal of Learning Disabilities, 2024, 52 (2): 410 - 421.
- [22] FABRIZI A, GUARINI G, MELICIANI V. Environmental networks and employment creation: Evidence from Italy [J]. Journal of Cleaner Production, 2022 (7): 1 - 13.
- [23] LI Z, LIN B. Analyzing the impact of environmental regulation on labor demand: a quasi-experiment from clean air action in China [J]. Environmental Impact Assessment Review, 2022, 93 (3): 1 - 10.