E-Commerce Letters 电子商务评论, 2026, 15(11), 185-194
Published Online November 2026 in Hans. https://www.hanspub.org/journal/ecl
https://doi.org/10.12677/ecl.2026.15111226

Hans汉斯

基于融合多源嵌入信息双向Mamba的提升电子商务物流效率研究

王艺霖

浙江理工大学信息科学与工程学院，浙江 杭州

收稿日期：2026年5月15日；录用日期：2026年6月9日；发布日期：2026年11月12日

摘　要

为提升电子商务物流的履约时效与仓配周转效率，关键在于增强路网速度与拥堵状态的可预见性，以支撑更准确的ETA估计、更优的动态路径规划与更提前的运力调度。针对现有交通流预测方法在长程依赖建模与动态空间相关刻画方面的不足，本文提出一种融合多源嵌入信息的双向Mamba交通流预测方法(MEBI-Mamba)。在时间维度，采用双向Mamba并行建模正向与逆向序列并融合，强化上下文表示；在空间维度，将路网节点按保持局部性的顺序序列化，利用空间Mamba捕获动态空间依赖。模型进一步融合时间、空间与自适应节点嵌入，并结合通道注意力与门控机制实现特征优化。在PEMS04与PEMS08上实验表明，所提方法在60分钟预测任务中MAE分别为7.55和6.39，RMSE分别为19.11和15.80，模型参数量仅为0.68×10^{6}个，推理速度超过400样本/秒。结果显示，该方法可为电商干支线与末端配送提供可靠预测支撑。

关键词

电子商务物流，交通流预测，ETA估计，动态路径规划，双向Mamba

Enhancing E-Commerce Logistics Efficiency via Bi-Directional Mamba with Multi-Source Embedding Fusion

Yilin Wang

School of Information Science and Engineering, Zhejiang Sci-Tech University, Hangzhou Zhejiang

Received: May 15, 2026; accepted: June 9, 2026; published: November 12, 2026

Abstract

To improve e-commerce logistics fulfillment timeliness and warehouse-distribution turnover

文章引用: 王艺霖. 基于融合多源嵌入信息双向 Mamba 的提升电子商务物流效率研究[J]. 电子商务评论, 2026, 15(11): 185-194. DOI: 10.12677/ecl.2026.15111226

efficiency, it is crucial to enhance the predictability of road-network speeds and congestion states, thereby enabling more accurate estimated time of arrival (ETA) estimation, better dynamic route planning, and earlier capacity dispatching. To address the limitations of existing traffic flow forecasting methods in modeling long-range dependencies and characterizing dynamic spatial correlations, this paper proposes a bi-directional Mamba-based traffic flow forecasting method with multi-source embedding fusion (MEBI-Mamba). In the temporal dimension, a bi-directional Mamba is adopted to model forward and backward sequences in parallel and fuse them to strengthen contextual representations. In the spatial dimension, road-network nodes are serialized in a locality-preserving order, and a spatial Mamba is used to capture dynamic spatial dependencies. The model further integrates temporal, spatial, and adaptive node embeddings, and employs channel attention and gating mechanisms for feature refinement. Experiments on PEMS04 and PEMS08 demonstrate that, for the 60-minute forecasting task, the proposed method achieves MAE values of 7.55 and 6.39 and RMSE values of 19.11 and 15.80, respectively, with only 0.68 × 10^6 parameters and an inference speed exceeding 400 samples/s. The results indicate that the proposed method can provide reliable predictive support for e-commerce trunk-line and last-mile delivery.

Keywords

E-Commerce Logistics, Traffic Flow Forecasting, ETA Estimation, Dynamic Route Planning, Bi-Directional Mamba

Copyright © 2026 by author(s) and Hans Publishers Inc.
This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).
http://creativecommons.org/licenses/by/4.0/
Open Access

1. 引言

数字经济推动电商蓬勃发展，行业竞争逐步转向履约体验与运营效率，电商物流成为数字化转型与产业升级的重要议题[1]。在智慧养老社区等细分场景中，O2O 电商服务整合研究指出，线上平台需要与线下服务资源及第三方服务主体协同，以提升服务供给与运营能力[2]。电商物流订单碎片化、需求波动大、时效要求高，企业在控成本的同时，愈发关注准点率、运力利用率、仓库周转效率；依托数据与算法优化资源配置，是物流提质增效的核心方向。数字化发展进一步提高了物流时效与稳定性标准，而用户配送体验也直接影响平台竞争力，优化履约与服务质量具备现实价值。仓配全链路中，城市路网通行状况是影响履约稳定性的核心因素。行程时间不确定会加大 ETA 偏差，拖累路径规划、运力调度与仓配衔接，降低周转效率。因此，精准预判路网状态，可为动态路径规划、运力前置调度提供依据，是提升电商履约时效与仓配周转效率的重要基础。

交通流预测旨在推断未来路网状态(速度、流量、占有率等)，本质上是时空序列建模问题：时间上存在周期性与长程依赖，空间上存在拓扑耦合与传播效应。早期统计模型如 HA 与 ARIMA 计算简洁但难以刻画非线性；深度学习方法成为主流[3]，LSTM/GRU 可捕捉时间依赖[4]，GNN 方法如 STGCN [5]、DCRNN [6]、AGCRN 及 Graph WaveNet 用于显式建模空间相关，但仍可能受过平滑与图结构不确定影响；Transformer 类方法强化全局依赖建模，却在长序列场景下面临较高计算开销。

为兼顾精度与效率，本文提出融合多源嵌入信息的双向 Mamba 时空预测模型(MEBI-Mamba)。模型在时间维度采用正向与逆向 Mamba 并行建模并融合，增强长程上下文表征；在空间维度将节点按局部性

保持顺序序列化，利用空间 Mamba 捕获动态空间依赖；同时融合时间、空间与自适应节点等多源嵌入，并进行多变量联合预测。本文旨在提升路网速度/拥堵的可预见性，为电商物流的 ETA 估计、动态路径规划与运力调度提供基础预测支撑，从而促进履约时效提升与仓配周转改善。

2. 本文方法

2.1. 整体概述

为提升电子商务物流的履约时效与仓配周转效率，本文从基础能力层面出发，构建面向路网速度/拥堵可预见性的时空预测模型 MEBI-Mamba。模型框架如图 1 所示，包含输入层、多源嵌入层、双向 Mamba 时空模块、轻量增强模块与输出层。模型以多变量交通观测为输入，通过高效时空建模输出未来多步路网状态预测，为更准确的 ETA 估计、更优的动态路径规划与更提前的运力调度提供先验信息支撑，进而提升干支线与末端配送效率并改善仓配周转。

从业务落地角度，模型输出的未来速度/拥堵预测可作为电商履约系统的基础输入：一方面用于更准确的 ETA 估计与配送承诺(如到达时间窗、超时风险评估与服务等级保障)，另一方面用于干支线与末端的动态路径规划与运力提前调度(如提前绕行、车辆/骑手预布点与班次动态调整)。进一步地，交通可预见性还可与仓内波次计划、出库节拍与装车窗口联动，减少车辆等待与仓内积压，从而提高车辆周转与仓库周转速率。本文聚焦并验证路网预测能力本身，相关业务决策与优化模块可在此基础上进行工程化对接与扩展。

模型原始输入由三类交通变量构成：流量(q)、速度(v)与占有率(o)。首先对原始输入进行线性投影获得特征嵌入；同时，使用可学习查找表得到日内时段和星期的时间嵌入，并为每个节点引入空间嵌入与自适应嵌入。随后将各嵌入沿特征维进行拼接，并通过线性层调整维度，以适配后续 Mamba 模块的输入要求。在双向 Mamba 时空模块中，模型并行启动时间通路与空间通路：时间通路对每个节点序列进行双向建模以捕获长程时间依赖；空间通路对每个时间片的全网状态进行序列化建模以学习动态空间相关。两通路输出采用可学习权重进行时空自适应加权融合，随后经过轻量级增强模块(SE 通道注意力与节点注意力门控)进一步校准通道与关键节点的重要性，归一化后映射得到多步预测输出。

2.2. 多源嵌入层

本模型通过多源嵌入策略将原始交通数据转换为丰富的特征表示空间。嵌入过程从时空自适应嵌入 Transformer (Spatio-Temporal Adaptive Embedding Transformer, STAEformer)架构中汲取设计思想，通过整合多种信息源为模型提供全面的时空背景。本文的嵌入策略显式包含了空间嵌入 $\boldsymbol{E}_s$，扩展了 STAEformer 中的嵌入方案。为构建统一的时空表示，首先将所有可用特征在通道维度上进行拼接。给定输入 $X \in \mathrm{R}^{B\times T_{\mathrm{in}}\times N\times F}$，其中批量大小为 B、输入时间步为 T_{in}、节点数为 N、原始特征维度为 F，把通道维度记为 C，中间融合特征形状为 $[B,T,N,C]$。

模型使用的多源嵌入包括：输入特征嵌入 $\boldsymbol{E}_f$、时段嵌入 $\boldsymbol{E}_{\mathrm{tod}}$、星期嵌入 $\boldsymbol{E}_{\mathrm{dow}}$、空间位置嵌入 $\boldsymbol{E}_s$、自适应嵌入 $\boldsymbol{E}_a$。上述嵌入在最后一维进行拼接，得到综合特征张量，如式(1)：

$$\boldsymbol{Z} = \boldsymbol{E}_f \,\|\, \boldsymbol{E}_p \,\|\, \boldsymbol{E}_s \,\|\, \boldsymbol{E}_a \tag{1}$$

式中：$\|$表示沿最后一个维度拼接各嵌入分量；$\boldsymbol{Z} \in \mathrm{R}^{B\times T_{\mathrm{in}}\times N\times Model_{\mathrm{dim}}}$，$\boldsymbol{Model}_{\mathrm{dim}} = \boldsymbol{E}_f + \boldsymbol{E}_p + \boldsymbol{E}_s + \boldsymbol{E}_a$；

周期性嵌入 $\boldsymbol{E}_p$ 由时段嵌入和星期嵌入级联而成：$\boldsymbol{E}_p = \boldsymbol{E}_{\mathrm{tod}} \,\|\, \boldsymbol{E}_{\mathrm{dow}}$。

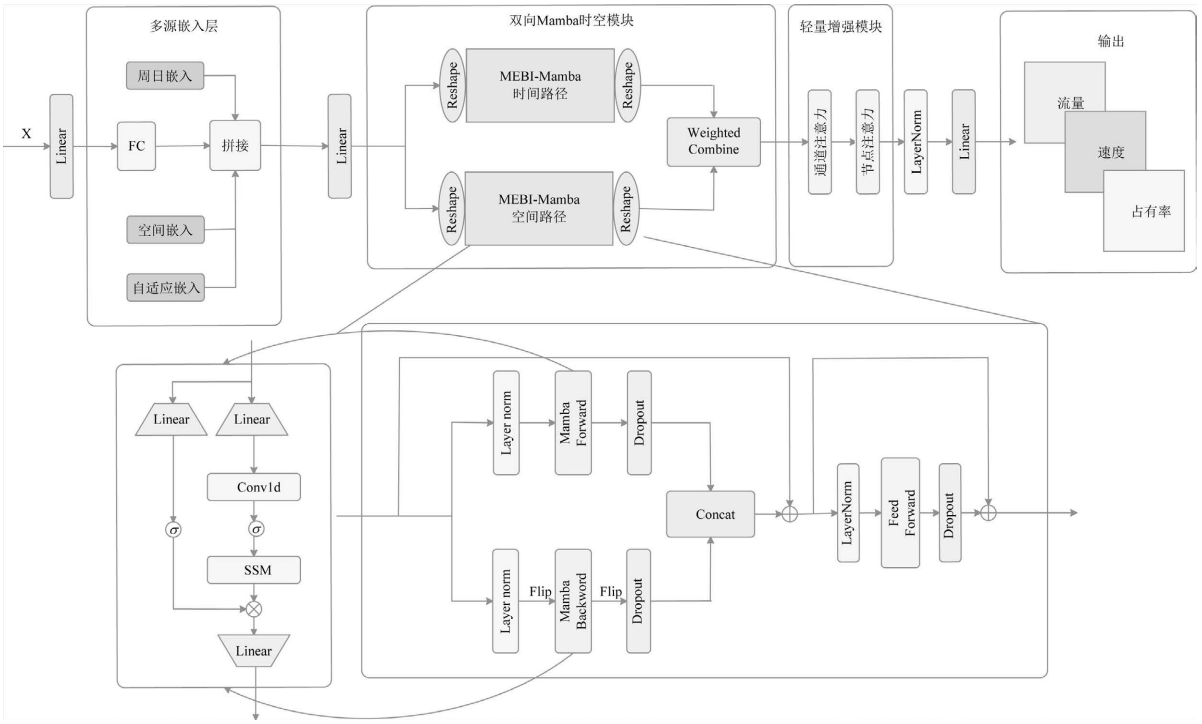


Figure 1. MEBI-Mamba model architecture
图 1. MEBI-Mamba 模型框架图

2.3. 双向 Mamba 时空模块

在经过多源嵌入模块融合之后，模型采用双通路并行架构，通过 Mamba 模块分别处理时间和空间两个维度，这种解耦设计使模型能够高效捕获长程时间依赖和复杂空间关联，且无需依赖显式的图结构建模。对电商末端履约而言，时间通路有助于降低高峰切换时段的外推误差，空间通路有助于刻画拥堵传播与局部异常扩散，从而减少路径级 ETA 偏差与绕行失败风险。

2.3.1. 双向 Mamba 模块

双向 Mamba 模块采用正逆向双路径并行处理机制。正向路径依次执行层归一化、正向 Mamba 处理和随机失活 dropout 操作，捕获从过去到未来的时间依赖；逆向路径则先对输入进行层归一化，随后沿时间维度翻转序列，经逆向 Mamba 处理后再次翻转以对齐正向输出，最后应用 dropout，从而实现从未来到过去的逆向建模。

两条路径的输出沿特征维度拼接为$\left[x_{\text{fwd}}, x_{\text{bwd}}\right]$，并通过线性投影降维($2D \to D$)，在保留双向信息的同时维持维度一致。融合后的特征首先与原始输入相加构成第一个残差连接，确保信息有效传递。随后，特征经过前馈神经网络进行增强，该网络包括层归一化、4 倍维度扩展、GELU 激活、dropout、降维和再次 dropout 等操作。前馈神经网络的输出通过第二个残差连接加回融合结果，形成稳定的梯度流通路径，从而构建完整的双向 Mamba 处理单元。

2.3.2. 时间相关建模

交通流预测的输入数据本质上是四维张量，而 Mamba 模块要求三维输入[批量，序列长度，维度]，因此，时间通路的核心在于将每个节点的多变量时间序列视为独立的序列样本。

为了对时间动态进行建模，将采用以下维度重组操作，如式(2)所示：

$$X_{\text{temporal}} = \text{Reshape}\left(\text{Permute}\left(X,(0,2,1,3)\right),\left[B\times N,T,C\right]\right) \tag{2}$$

式中：Permute 是将维度从$[B,T,N,C]$调整为$[B,N,T,C]$，将节点维度移至第二位；Reshape 是将前两个维度合并，得到$[B\cdot N,T,C]$，将每个节点的时间序列展开为独立样本。

该变换使双向 Mamba 能够并行学习所有节点的时间演化规律，充分刻画周期性、节奏变化与长程依赖，从而提升对未来速度变化的前瞻感知能力，降低 ETA 在高峰切换附近的系统性偏差。

2.3.3. 空间相关建模

与时间通路相对应，空间通路的设计理念是将每个时间步视为交通网络的空间快照，从而学习节点间的空间依赖关系和拓扑传播模式。

空间建模采用不同的维度重组方式，如式(3)所示：

$$X_{\text{spatial}} = \text{Reshape}\left(\text{Permute}\left(X,(1,0,2,3)\right),\left[T\times B,N,C\right]\right) \tag{3}$$

式中：Permute 是将维度从$[B,T,N,C]$调整为$[T,B,N,C]$，将时间维度移至首位；Reshape 是将前两个维度合并，得到$[T\cdot B,N,C]$，将每个时间步的空间网络展开为独立样本。

这种变换使得 Mamba 模块能够隐式学习空间依赖关系，例如拥堵传播、节点间影响等，而无需依赖预定义的图结构。该机制仍可学习拥堵传播、枢纽关联与局部异常扩散等空间模式，为路径级 ETA 提供更贴近真实传播过程的预测基础。

2.3.4. 时空融合

时间和空间双通路处理后，需要将两种特征有效融合，采用可学习的加权融合策略，融合公式为式(4)所示：

$$X_{\text{fused}} = X_{\text{temporal}} \odot \boldsymbol{w}_0 + X_{\text{spatial}} \odot \boldsymbol{w}_1 \tag{4}$$

式中：$X_{\text{temporal}} \in \mathrm{R}^{B\times T\times N\times C}$：时间通路输出；$X_{\text{spatial}} \in \mathrm{R}^{B\times T\times N\times C}$：空间通路输出；$\boldsymbol{w}_0 \in \mathrm{R}^{C}$、$\boldsymbol{w}_1 \in \mathrm{R}^{C}$：可学习的融合权重向量；$\odot$：逐元素乘法。

该融合策略可在高峰期或异常事件下自适应提高空间信息贡献，在平稳时段增强时间信息贡献，从而提升预测稳健性与可用性。

2.4. 轻量级增强模块

时空融合后的特征包含多通道、多节点信息，但不同通道与不同节点对预测贡献并不一致。为在较小的参数与计算增量下突出关键信息，本文引入轻量级增强模块，包括 SE 通道注意力与节点注意力门控：前者用于动态校准各通道重要性，后者用于突出关键节点(如瓶颈路段、枢纽周边)，以提升与末端 ETA 相关的关键路段预测质量。融合后的特征包含多个通道，不同通道对预测的贡献度不同，通道注意力动态校准各通道重要性。

2.5. 输入和输出

给定输入数据$X \in \mathrm{R}^{B\times T_{\text{in}}\times N\times F}$，其中批量大小为$B$、输入时间步为$T_{\text{in}}$、节点数为$N$、原始特征维度为$F$，把通道维度记为$C$，中间融合特征形状为$[B,T,N,C]$。

本文所用的多通道数据中，原始特征维度 F 包含三类 5 分钟粒度的观测数据，用于表征路段状态：

(1) 平均速度(v)：传感器在该 5 分钟区间内检测到的车辆平均速度(km/h)；

(2) 交通流量(q)：在该 5 分钟区间内通过传感器位置的车辆总数，通常由更短间隔(如 30 s)的原始计数加总得到；

(3) 平均占有率(o)：该区间内传感器被车辆占用的时间比例，计算为 o = (占用总时长/区间时长) × 100%。

与仅使用流量单通道(F = 1)相比，同时利用流量、速度、占有率(F = 3)能够更全面地刻画交通状态，有助于捕捉三者之间的耦合关系。该模型原生面向多变量输入设计，能够有效挖掘多通道数据蕴含的时空信息。

预测任务可形式化为：基于最近 T_{in} 个时间步的观测，预测未来 T_{out} 个时间步在所有节点上的状态，如式(5)所示：

$$\left[X_{t+1}, X_{t+2}, \cdots, X_{t+t_{\text{out}}}\right] = f\left(\left[X_{t-t_{\text{in}}+1}, X_{t-t_{\text{in}}+2}, \cdots, X_{t}\right]\right) \tag{5}$$

式中：$f(\cdot)$ 为从历史序列映射到未来序列的预测函数。

在模型的最终处理阶段，首先对组合输入特征 X_C 施加通道维度的层归一化，得到归一化后的特征 X_{out}。随后，通过线性投影层将特征维度从 C 映射为目标输出维度 D_{out}，此步骤后特征形状更新为 $[B, T, N, D_{\text{out}}]$。最终，为获取预测结果，选取该投影输出中最后 T 个时间步的特征作为预测输出 $\hat{Y} \in \mathrm{R}^{B \times T_{\text{out}} \times N \times D_{\text{out}}}$，完成从输入到预测结果的转换。该预测结果可进一步转换为路段行程时间与路径级 ETA，为末端配送路径规划、调度提前量计算与时效承诺管理提供基础数据支撑。

3. 实验

3.1. 数据集

在本次实验中，使用加州交通监测(PEMS)系列的两个公开数据集(PEMS04、PEMS08)对模型进行评估。两者均以 5 分钟为时间分辨率，面向多路段、多传感器的城市交通状态建模，适合检验时空预测方法的泛化能力。在表 1 中给出了这两个数据集的详细信息。从电商履约视角看，PEMS 数据集虽非直接来自物流业务系统，但其对城市路网速度与拥堵状态的刻画与末端配送高度相关：速度可近似反映路段行程时间，流量与占有率能够表征拥堵强度与排队程度，三者共同决定 ETA 的偏差与波动范围。对于具有“到达时间承诺”的电商配送而言，路网状态的可预测性不仅影响路线选择与绕行策略，也会传导至派单提前量、站点装车窗口安排与运力冗余配置，从而影响准点率与单位时间完成单量等关键运营指标。

PEMS04 覆盖洛杉矶地区多条干道，包含分布在 29 条道路上的 3848 个传感器。数据从 2018 年 1 月 1 日开始连续采集 59 天，每 5 分钟记录一次交通观测量。该数据集规模大、空间分布广，能有效考察模型在复杂路网下的时空依赖建模能力。

PEMS08 采集自圣贝纳迪诺县，时间跨度为 2016 年 7~8 月共 62 天。数据来自 8 条道路上的 1979 个检测器，记录频率为 5 分钟。相比 PEMS04，该数据集传感器数量较少但覆盖道路更集中，便于评估模型在不同网络密度与规模下的稳健性。

Table 1. Dataset details
表 1. 数据集详细信息

数据集	节点数	时间范围	特征数
PEMS04	307	2018.01.01~2018.02.28	流量、速度、占有率
PEMS08	170	2016.07.01~2016.08.31	流量、速度、占有率

为确保实验准确性，按照交通流预测研究中大多数实验设置，将训练集、验证集、测试集的比例设置为 7:1:2。所有特征仅基于训练集的均值与标准差进行 Z-score 标准化，模型以过去 12 个时间步(1 小时)

作为输入，同时预测接下来 12 个时间步的流量、速度、占有率。本文采用过去 12 个时间步(1 小时)预测未来 12 个时间步(1 小时)的设定，一方面符合交通预测领域的常用窗口，另一方面与电商末端调度的滚动决策节奏匹配：在小时级预测范围内，平台可提前进行预派单与预布点、动态调整绕行与合单策略，并将潜在拥堵风险前置到站点作业与装车/出库节拍的安排中，从而降低因道路波动带来的履约违约风险。

3.2. 实验设置及评价指标

本实验在 Ubuntu22.04 系统，处理器 13th Gen Intel(R) Core (TM) i7-13700K，GPU 为 NVIDIA GeForce RTX 4070 Ti 的设备上进行，在训练过程中具体的模型参数设置信息如表 2 所示。

Table 2. Detailed experimental settings
表 2. 详细实验参数

数据集	PEMS04	PEMS08
学习率	0.001	0.001
Dropout 率	0.1	0.1
输入时间窗口	12	12
批处理大小	32	64
模型维度	96	96
训练轮数	100	100
优化器	Adam	Adam

为评估预测精度，本文采用 3 个常用评价指标，平均绝对误差(MAE)、均方根误差(RMSE)、平均绝对百分比误差(Mean Absolute Percentage Error, MAPE)。每个评价指标的计算式如式(6)、式(7)、式(8)所示：

$$\mathrm{MAE}=\frac{1}{N_{\text{samples}}}\sum_{i=1}^{N_{\text{samples}}}\left|Y_i-\hat{Y}_i\right| \tag{6}$$

$$\mathrm{RMSE}=\sqrt{\frac{1}{N_{\text{samples}}}\sum_{i=1}^{N_{\text{samples}}}\left(Y_i-\hat{Y}_i\right)^2} \tag{7}$$

$$\mathrm{MAPE}=\frac{1}{N_{\text{samples}}}\sum_{i=1}^{N_{\text{samples}}}\left|\frac{Y_i-\hat{Y}_i}{Y_i}\right|\times 100\% \tag{8}$$

式中：N_{samples} 样本，Y_i 真实值，$\hat{Y}_i$ 预测值。

3.3. 与基线方法对比的实验结果

为评估所提模型的预测性能，将 MEBI-Mamba 与 HA、ARIMA、LSTM、GRU [4]、STGCN [5]、DCRNN [6]、STAformer [7]、PDFformer [8]、SVR [9]、ASTGCN [10]、MGCN [11]、ST-Mamba [12]等 12 种基线方法的预测性能进行了对比。

表 3 汇报了在数据集 PEMS04 与 PEMS08 上，预测步长为 12 步(1 小时)的整体结果。与仅在单通道上计分的做法不同，MEBI-Mamba 对流量、速度、占有率三类通道的误差进行聚合，更全面地反映时空预测性能。

Table 3. Performance comparison of different methods on PEMS04 and PEMS08
表 3. 不同方法在 PEMS04 和 PEMS08 上的性能比较

模型	PEMS04			PEMS08		
	MAE	RMSE	MAPE	MAE	RMSE	MAPE
HA	33.78	47.59	24.27%	26.92	40.33	18.57%
ARIMA	32.63	48.95	22.83%	25.83	38.75	17.62%
SVR	28.22	42.33	19.15%	23.25	34.88	15.29%
LSTM	27.84	41.28	18.25%	22.81	35.67	14.89%
GRU	27.33	41.08	18.12%	22.26	35.12	14.56%
DCRNN	21.22	33.44	14.17%	16.82	26.36	10.92%
STGCN	22.70	35.55	16.30%	18.02	27.83	11.40%
ASTGCN	22.93	35.22	16.56%	18.25	28.34	11.64%
STAformer	18.76	30.95	12.36%	15.34	24.51	9.91%
PDFformer	18.36	30.03	12.00%	13.58	23.41	9.05%
MGCN	19.70	31.80	13.10%	15.40	24.80	9.94%
ST-Mamba	18.19	30.17	11.88%	13.40	23.20	9.00%
MEBI-Mamba	**7.55**	**19.11**	**13.73%**	**6.39**	**15.80**	**11.62%**

在 PEMS04 与 PEMS08 数据集上，本文的模型 MEBI-Mamba 在 MAE、RMSE、MAPE 三项指标上的整体误差均显著低于多数基线模型，表现出稳定且全面的优势。对电商末端而言，这类改进通常对应更小的 ETA 偏差与更低的“临近超时”波动，有助于提升滚动调度的可行性(如提前绕行、动态调整派送顺序)并降低因误判路况导致的无效调度与空驶。相较于 Transformer 预测方法系列(如 STAformer、PDFormer)和 Mamba 变体(例如 ST-Mamba、MGCN)，MEBI-Mamba 在多数指标上进一步降低误差，说明其在捕获复杂时空相关性与提升数值稳定性方面更为有效。

综合来看，MEBI-Mamba 模型在 PEMS04 上，MAE 为 7.55、RMSE 为 19.11，相较最强基线显著提升，相对 ST-Mamba (MAE: 18.19)，MAE 降低 58.5%；相对 PDFformer (RMSE: 30.03)，RMSE 降低 36.4%；对应的 MAPE 为 13.73%，高于最佳基线模型 ST-Mamba 的 11.88%。

在 PEMS08 上，MEBI-Mamba 的 MAE 为 6.39、RMSE 为 15.80，同样优于现有方法，相对 ST-Mamba (MAE: 13.40)，MAE 降低 52.3%；相对 ST-Mamba (RMSE: 23.20)，RMSE 降低 31.9%，MAPE 为 11.62%，高于最佳基线 ST-Mamba 的 9.00%。

MEBI-Mamba 模型在 MAE 与 RMSE 上取得了显著优势，但 MAPE 并未同步取得最优，甚至略高于部分基线。该现象的主要原因在于 MAPE 对近零真值高度敏感：当分母 y 接近 0 时，微小的绝对误差会被夸大为较大的相对误差。此外，当用 MAPE 评估不同通道(流量、速度、占有率)的预测误差时，由于这些指标的数值尺度和分布差异大，MAPE 在跨通道比较时会混合不同的尺度效应，降低指标的可解释性。值得注意的是，占有率在夜间及低峰时段更容易接近零，这与电商业务中的“低峰配送/夜间补货”等场景相对应。此时 MAPE 对近零分母高度敏感，会将小幅绝对误差放大为较大的相对误差，因此本文将 MAPE 解释为补充指标，并结合 MAE、RMSE 共同评估模型在履约相关波动下的稳定性。

如表 4 所示，详细列出了模型在流量、速度和占有率三个独立通道上的预测值与真实值的对比指标。模型的整体 MAPE 指标略高于部分基线，这主要归因于占有率通道的特性。由于占有率在夜间等低峰时

段的真实值常接近于零，导致 MAPE 计算公式中的分母极小，从而使微小的绝对误差被不成比例地放大。因此，略高的 MAPE 并非模型预测能力的缺陷，而是特定评估指标在处理具有稀疏或近零值特征数据时固有的统计局限性。

Table 4. Per-channel predictions and errors at a 60-minute prediction horizon
表 4. 60 分钟预测步长下的通道级预测与误差

模型	PEMS04			PEMS08		
	预测值	真实值	误差	预测值	真实值	误差
流量	213.90	214.07	−0.17	230.39	230.65	−0.27
速度	63.12	62.85	0.27	63.32	63.03	0.29
占有率	0.036	0.052	−0.016	0.011	0.066	−0.055

4. 结束语

面向电商物流履约中“需求波动大、时效承诺强、链路协同复杂”的业务特征，城市路网速度与拥堵的波动会直接放大路径级行程时间不确定性，进而影响 ETA 估计精度、动态路径规划有效性与末端调度响应。为提升路网运行状态的可预见性并为履约系统提供更可靠的先验信息，本文提出融合多源嵌入信息的双向 Mamba 时空预测模型(MEBI-Mamba)。在时间维度，模型采用双向 Mamba 并行建模正向与逆向序列并进行融合，以增强长程上下文表征与趋势刻画；在空间维度，模型将同一时刻的节点特征按局部性保持顺序进行序列化，并利用空间 Mamba 在无需显式邻接矩阵的前提下学习动态空间依赖，从而刻画拥堵传播与跨节点联动。与此同时，模型系统融合时间、空间与自适应节点等多源嵌入，并通过通道注意力与节点门控对关键通道与关键节点进行轻量增强，在保证效率的同时提升预测稳定性。

在 PEMS04 与 PEMS08 公开数据集上的实验结果表明，MEBI-Mamba 在 MAE 与 RMSE 等核心指标上整体优于对比基线方法；消融实验进一步量化了多源嵌入、双向 Mamba 机制与轻量级增强模块的独立贡献，验证了各组件的有效性与必要性。结合状态空间模型的线性复杂度优势，本文方法在长序列、多节点预测场景下兼具精度与推理效率，为电商履约场景中高频滚动的 ETA 更新与在线调度提供了更具可部署性的预测模型基础。

未来工作将从两方面推进：其一，引入天气、交通事故、重大活动等外部扰动因素，提升模型对非平稳与突发变化的鲁棒性；其二，面向电商业务闭环探索更深度的工程对接与评估方式，例如将促销/节假日信号、区域订单热度、末端运力供给与站点作业节奏等业务侧信息以可插拔形式纳入多源嵌入框架，并在准点率、超时率与资源利用率等履约指标上开展端到端验证，以进一步评估模型对履约体验与运营效率的实际价值。

基金项目

浙江省自然科学基金资助项目(LTGS23F030002)；嘉兴市应用性基础研究项目(2023AY11034)。

参考文献

[1] 张世宇, 叶纯, 代丽. 农村电商物流的研究现状及热点分析——基于 CiteSpace 知识图谱分析[J]. 电子商务评论, 2025, 14(12): 7185-7196.

[2] 张玲君. 面向智慧养老社区的 O2O 电商服务整合模式与优化策略研究[J]. 老龄化研究, 2026, 13(2): 195-201. https://doi.org/10.12677/ar.2026.132022

[3] Yin, X., Wu, G., Wei, J., Shen, Y., Qi, H. and Yin, B. (2022) Deep Learning on Traffic Prediction: Methods, Analysis,

and Future Directions. *IEEE Transactions on Intelligent Transportation Systems*, **23**, 4927-4943. https://doi.org/10.1109/tits.2021.3054840

[4] Dey, R. and Salem, F.M. (2017) Gate-Variants of Gated Recurrent Unit (GRU) Neural Networks. 2017 *IEEE* 60*th International Midwest Symposium on Circuits and Systems* (*MWSCAS*), Boston, 6-9 August 2017, 1597-1600. https://doi.org/10.1109/mwscas.2017.8053243

[5] Yu, B., Yin, H. and Zhu, Z. (2017) Spatio-Temporal Graph Convolutional Networks: A Deep Learning Framework for Traffic Forecasting. https://arxiv.org/abs/1709.04875

[6] Li, Y., Yu, R., Shahabi, C., *et al*. (2018) Diffusion Convolutional Recurrent Neural Network: Data-Driven Traffic Forecasting. *Vancouver*: *International Conference on Learning Representations*, Vancouver, 2018, 1-16.

[7] Xu, M., Dai, W., Liu, C., *et al*. (2022) STAformer: Spatial-Temporal Attention Transformer for Traffic Flow Forecasting. *Orlando*: *2022 IEEE International Conference on Data Mining*, Orlando, 2022, 1345-1350.

[8] Jiang, J., Han, C., Zhao, W., *et al*. (2023) PDFormer: Propagation Delay-Aware Dynamic Long-Range Transformer for Traffic Flow Prediction. arXiv:2301.07945. https://arxiv.org/abs/2301.07945

[9] Awad, M. and Khanna, R. (2015) Support Vector Regression. In: Awad, M. and Khanna, R., Eds., *Efficient Learning Machines*, Apress, 67-80. https://doi.org/10.1007/978-1-4302-5990-9_4

[10] Guo, S., Lin, Y., Feng, N., Song, C. and Wan, H. (2019) Attention Based Spatial-Temporal Graph Convolutional Networks for Traffic Flow Forecasting. *Proceedings of the AAAI Conference on Artificial Intelligence*, **33**, 922-929. https://doi.org/10.1609/aaai.v33i01.3301922

[11] Lin, W., Zhang, Z., Ren, G., Zhao, Y., Ma, J. and Cao, Q. (2025) MGCN: Mamba-Integrated Spatiotemporal Graph Convolutional Network for Long-Term Traffic Forecasting. *Knowledge-Based Systems*, **309**, Article 112875. https://doi.org/10.1016/j.knosys.2024.112875

[12] Yuan, D., Xue, J., Su, J., *et al*. (2024) ST-Mamba: Spatial-Temporal Mamba for Traffic Flow Estimation Recovery Using Limited Data. arXiv:2407.08558. https://arxiv.org/abs/2407.08558