文章编号：1003-1421(2025)12-0129-09
引用格式：肖致明，马博文，程文毅. 基于LSTM模型的京津冀区域物流需求预测研究[J]. 铁道运输与经济，2025，47(12)：129-137.
XIAO Zhiming，MA Bowen，CHENG Wenyi. Logistics Demand Prediction in Beijing-Tianjin-Hebei Region Based on LSTM Model[J]. Railway Transport and Economy，2025，47(12)：129-137.

基于LSTM模型的京津冀区域物流需求预测研究

肖致明[1]，马博文[2]，程文毅[2]

(1.国能朔黄铁路发展有限责任公司，河北 沧州 062350；2.中国铁道科学研究院集团有限公司运输与经济研究所，北京 100081)

摘 要：精准预测区域物流需求对于合理规划物流资源配置、提升物流运作效率意义重大。长短期记忆网络(LSTM)作为一种深度学习模型，在处理具有复杂非线性关系和动态变化规律的时间序列数据方面展现出强大优势。将货物运输量作为物流需求的替代变量，深入剖析物流需求的影响因素，运用灰色关联分析方法计算各因素与物流需求的关联度，确定关键指标。在此基础上，利用LSTM构建适用于区域物流需求预测的深度学习模型，以捕捉数据中的复杂非线性关系和动态变化规律。最后运用训练优化后的LSTM模型预测京津冀区域物流需求的动态变化，将预测结果与基于BP神经网络的预测结果进行对比分析，验证了LSTM模型在区域物流需求预测方面的准确性和有效性。基于预测结果与区域差异分析，研究从制定差异化战略、强化区域协同及前瞻性基础设施规划3个方面，为京津冀物流政策优化提供了决策依据。

关键词：物流需求预测；京津冀；深度学习；LSTM模型；BP模型
中图分类号：U29；F252 **文献标识码：**A DOI：10.16668/j.cnki.issn.1003-1421.20250923005

Logistics Demand Prediction in Beijing-Tianjin-Hebei Region Based on LSTM Model

XIAO Zhiming[1]，MA Bowen[2]，CHENG Wenyi[2]

(1. CNN ENERGY Shuozhou-Huanghua Railway Development Co., Ltd., Cangzhou 062350, Hebei, China; 2. Transportation & Economics Research Institute, China Academy of Railway Sciences Corporation Limited, Beijing 100081, China)

Abstract: Accurate prediction of regional logistics demand is crucial for rational planning of logistics resource allocation and improving logistics operational efficiency. As a deep learning model, long short-term memory (LSTM) networks demonstrate strong advantages in processing time series data with complex nonlinear relationships and dynamic changing patterns. This paper adopted freight volume as a proxy variable for logistics demand, conducted an in-depth analysis of the factors influencing logistics demand, and employed grey relational analysis to calculate the correlation degree between each factor and logistics demand, thereby identifying key indicators. On this basis, an LSTM-based deep learning model was constructed to predict regional logistics demand, capturing the complex nonlinear relationships and dynamic patterns within the data. Finally, the trained and optimized LSTM model was applied to predict the dynamic changes in logistics demand in the Beijing-Tianjin-Hebei

收稿日期：2025-09-23
通信作者：马博文(1996—)，男，内蒙古赤峰人，中国铁道科学研究院集团有限公司运输与经济研究所助理研究员。
基金项目：国家能源投资集团有限责任公司科技创新项目(GJNY-24-105)

region. By comparing these prediction results with those derived from the BP neural network-based model, the paper verified the accuracy and effectiveness of the LSTM model in regional logistics demand prediction. Based on the prediction results and regional disparity analysis, this study provides a decision-making basis for optimizing logistics policies in the Beijing-Tianjin-Hebei region from three aspects: formulating differentiated strategies, enhancing regional coordination, and conducting forward-looking infrastructure planning.

Keywords: Logistics Demand Prediction; Beijing-Tianjin-Hebei Region; Deep Learning; LSTM Model; BP Model

0　引言

区域是国家资源配置、产业布局和经济活动的重要空间载体，区域物流需求是衡量一个特定地域内经济活动活跃程度和物流产业发展的重要指标。准确预测区域物流需求对于促进区域产业链供应链发展、企业合理规划物流资源、优化运输及配送路线、提高资源配置效率，以及支撑政府部门制定区域协调发展策略、现代物流产业政策、物流基础设施规划方案等都具有重要意义。

在物流需求预测及相关领域研究方面，众多学者开展了丰富且深入的工作，采用了多样化的方法与模型，并基于不同地区、不同对象展开实证分析，取得了有价值的研究成果。

在铁路货运量与区域物流需求预测研究中，学者们采用了多种建模方法，并逐步从传统模型向机器学习与深度学习方向发展。早期研究多采用灰色预测模型，如周茵[1]构建残差灰色模型用于铁路货运量预测，但该模型在处理非线性、动态时序数据时精度有限。程肇兰等[2]引入长短期记忆网络(LSTM)，分别基于月度和日度数据构建多变量与时间序列预测模型，提升了复杂模式的捕捉能力。近期研究中，汪岗等[3]提出基于经验模态分解与注意力机制LSTM的组合预测模型，通过信号分解和特征加权提升了铁路货运站装车量预测精度；张海山等[4]则构建异质时空图注意力网络，融合车站间的多源时空关联信息，为车站级货运量预测提供了新思路。

区域物流需求预测方面，郭红霞[5]、赵文德等[6]和张建涛等[7]均采用BP神经网络构建预测模型，但该方法存在梯度消失与过拟合问题，难以有效捕捉长期依赖关系。为提升预测性能，阮俊虎[8]和王娜等[9]引入支持向量机方法，并分别结合遗传算法与网格搜索进行参数优化，但这类方法的计算复杂度较高。此外，左雷等[10]采用多元线性回归模型，赵文德等[6]和张建涛等[7]也尝试运用ARIMA模型，但这些传统方法或受限于非线性表征能力不足，或对数据平稳性要求较高，在复杂预测场景中应用效果有限。

在针对特定品类的物流需求预测研究中，张雅淇[11]与尹玥等[12]采用灰色GM(1，1)模型和指数平滑法对农产品物流需求进行分析，但灰色模型易受数据波动影响，指数平滑法则更适用于短期预测。近年来，随着机器学习发展，郑兴彤[13]引入随机森林进行特征筛选，并结合双向长短期记忆网络实现冷链物流需求预测；王辉[14]则将LSTM模型应用于可再生能源预测，但其在区域物流需求中的潜力仍需深入探索。此外，何西健[15]采用Gompertz曲线与弹性系数法进行运量预测，Dombi [16]和Mitra等[17]也分别基于需求趋势方程和时间序列分析方法开展了相关预测研究。

目前，区域物流需求预测主要面临以下问题。一是区域一体化融合不足，区域间地区分割和壁垒影响资源要素配置效率，跨行政区域协同水平较低；二是数据来源单一，传统预测方法往往仅依赖有限的物流业务数据，如货物周转量、仓储量等，忽视了其他相关领域数据对物流需求的影响，导致预测结果不够全面准确；三是数据异构性处理不强，实际物流数据来源广泛，传统方法难以有效融合处理；四是模型适应性差，区域物流需求受多种复杂因素影响，且具有动态变化特性，传统预测模型难以捕捉数据中的复杂非线性关系和动态变化规律，预测精度和泛化能力有限。

随着信息技术的发展，多源异构数据不断涌现，为区域物流需求预测提供了更丰富的信息来源。多数既有研究未能有效突破传统预测方法的局限，如线性回归难以处理复杂非线性关系、ARIMA模型对数据的平稳性要求较高、BP神经网络易陷入局部最优。深度学习技术在处理复杂数据、挖掘数据潜在规律方面具有显著优势，为解决上述问题

提供了新的思路和方法。LSTM作为一种深度学习模型，在处理具有复杂非线性关系和动态变化规律的时间序列数据方面展现出强大优势。然而，目前LSTM模型在区域物流需求预测中的应用尚不广泛，缺乏系统性的研究和应用案例。现有研究大多仅简单地将LSTM模型应用于特定地区或特定物流品类的需求预测，未充分考虑区域物流需求的复杂性和多样性，也未对LSTM模型在区域物流需求预测中的优化和应用进行深入探讨。在此背景下系统深入探究LSTM模型在区域物流需求预测中的应用，以填补该领域系统性研究的空白。

1　区域物流需求影响因素选取

在物流需求的度量指标中，现有研究主要采用货运量和社会物流总费用2种。前者通过统计货物运输规模直接反映物流活动强度，并常作为需求预测的量化依据；后者以社会物流总费用为表征，从经济核算角度综合衡量物流系统的资源投入与成本结构。前者虽能直观体现物流作业量，却可能忽略运输距离、服务附加值等需求维度；后者虽全面但依赖多源数据整合，存在核算滞后性与口径差异。鉴于此，选取货运量作为物流需求的替代变量。

基于物流需求驱动逻辑，将数据按区域经济基础、产业特征、物流供给能力、市场需求、基础设施水平五大维度分类，形成一级指标框架。针对每个一级指标，进一步拆解为可量化的二级指标，最终构建的指标体系涵盖14项量化参数，区域物流需求指标体系如表1所示，为后续相关性分析和神经网络模型预测货运量提供结构化数据支撑。

表1　区域物流需求指标体系

Tab.1　Regional logistics demand indicator system

一级指标	二级指标	单位
区域经济发展水平	GDP总量	亿元
	人均可支配收入	元/人
	固定资产投资增长率	%
产业结构水平	第一产业增加值	亿元
	第二产业增加值	亿元
	第三产业增加值	亿元
物流规模	货物周转量	亿t·km
	物流业占GDP比重	%
市场需求	社会消费品零售总额	亿元
	进口总额	亿美元
	出口总额	亿美元
基础设施水平	铁路营业里程	km
	公路里程	km
	内河航道里程	km

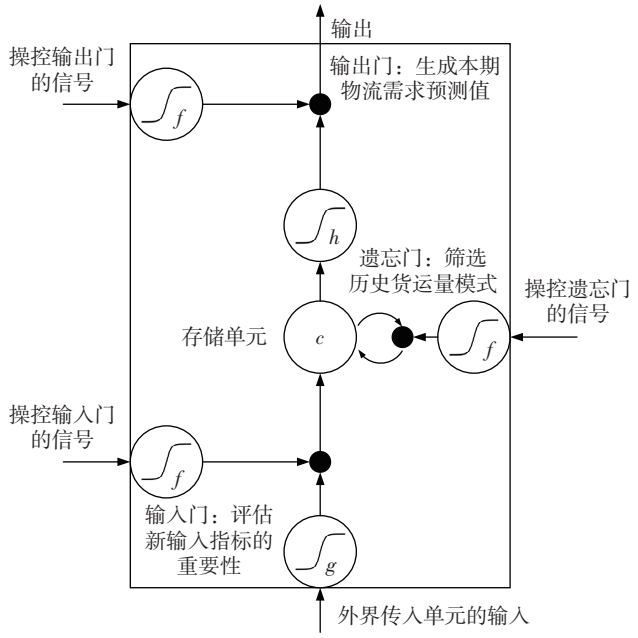

图1　LSTM记忆元示例

Fig.1　Example of an LSTM memory cell

2　LSTM物流需求预测模型

2.1　LSTM模型概述

长短期记忆网络(Long Short-Term Memory，LSTM)是循环神经网络(RNN)领域的重要突破，其设计初衷在于解决传统RNN在处理长时序数据时面临的梯度消失与梯度爆炸问题。作为RNN的改进架构，LSTM通过引入门控机制与细胞状态管理，极大提升了模型对时间序列特征的建模能力，尤其在物流需求预测等复杂场景中展现出一定优势。

LSTM记忆元示例如图1所示，LSTM的核心在于构建了自适应信息筛选框架，通过遗忘门、输入门和输出门的协同作用，实现了对历史信息的选择性保留与当前输入的融合。遗忘门通过sigmoid激活函数对前一时刻的细胞状态进行信息筛选，决定保留或丢弃特定历史特征；输入门则采用双阶段处理机制，首先通过sigmoid层判断新信息的更新强度，再利用tanh层生成候选状态向量，最终通过加权融合实现细胞状态的渐进式更新；输出门则结合更新后的细胞状态与当前输入，生成具有时序敏感性的隐藏层输出。这使得LSTM能够有效缓解传统

RNN的固有缺陷——通过门控单元对信息流的精细化调控，网络在反向传播过程中可自动调整导数路径，避免梯度指数级衰减或放大；同时，细胞状态的加性更新策略确保了信息流的稳定性，即使在参数固定的情况下，模型仍能通过动态时序缩放机制捕捉长程依赖关系。

LSTM神经单元在时刻t计算的具体步骤如下。

步骤1：遗忘门处理。单元会通过遗忘门读取h_{t-1}和x_t(x_t表示当前输入LSTM神经单元的信息，h_{t-1}表示前一个LSTM神经单元中存储单元输出的信息)，并对输入信息进行处理，决定从上一时刻的细胞状态中丢弃的信息。

$$f_t = \sigma(W_f \cdot [h_{t-1},\ x_t] + b_f) \tag{1}$$

式中：f_t为遗忘门；σ为Sigmoid激活函数；W_f为遗忘门输入权值矩阵；b_f为遗忘门偏差项；x_t为当前时间步长；h_{t-1}为前一个时间步长。

在物流需求预测中，遗忘门的作用是筛选与当前预测最相关的历史信息。例如，当模型接收到新的输入数据时，遗忘门会评估历史细胞状态(其中蕴含了过往的货运量趋势、季节性波动等长期信息)，并决定保留哪些持续有效的模式(如长期增长趋势)，同时“遗忘”那些可能因突发事件而产生、且对预测未来不再有用的临时性波动。

步骤2：信息更新判断。决定需要向细胞状态中更新的信息。这部分包括2个步骤：首先输入门通过sigmoid层判断需要更新的信息，同时每个tanh层形成一个向量作为进入存储单元的备选更新信息；然后将sigmoid和tanh层结合对存储单元进行更新。

$$i_t = \sigma(W_i \cdot [h_{t-1},\ x_t] + b_i) \tag{2}$$

$$C_t = \tanh(W_c \cdot [h_{t-1},\ x_t] + b_c) \tag{3}$$

式中：i_t为输入门的sigmoid输出；σ为sigmoid激活函数；W为输入门权值矩阵；b_i为输入门偏差项；x_t为当前时间步的输入数据；C_t为候选存储单元状态；tanh()为tanh激活函数；W为存储单元输入权值矩阵；b_c为存储单元偏差项。

此步骤旨在将新的影响因素融入模型。输入门判断当前时刻的新输入，如当年的GDP、产业增加值、社会消费品零售总额等特征的价值有多大。候选状态则根据这些新特征生成一个备选的更新方案。

步骤3：存储单元更新。将存储单元的信息进行更新，将C_{t-1}更新为新细胞状态C_t。

$$C_t = f_t \cdot C_{t-1} + i \cdot C_t \tag{4}$$

式中：C_{t-1}为前一时间步的存储单元；i表示输入门输出。

此步骤通过将遗忘门筛选后的历史状态与输入门过滤后的新信息相加，细胞状态得以更新。例如，模型在保留长期增长趋势的同时，融入了最新产业结构升级带来的物流需求变化，从而形成更全面、更准确的当前状态认知，作为预测未来的基础。

步骤4：输出门处理。输出门使用输出信息o_t和存储单元信息C_t，从新细胞状态中过滤、缩放得到隐藏层的输出信息h_t。

$$o_t = \sigma(W_o \cdot [h_{t-1},\ x_t] + b_o) \tag{5}$$

$$h_t = o_t \cdot \tan C_t \tag{6}$$

式中：o_t为输出信息；W_o为输出门的权值矩阵；x_t为当前输入；$[h_{t-1},\ x_t]$为前一步隐藏状态和当前输入的拼接向量；b_o为输出门的偏差项；h_t为当前时间步的输出信息。

输出门负责产生最终的预测结果。o_t决定当前更新后的细胞状态C_t中有多少信息需要输出到最终的预测值h_t中。在物流预测场景下，h_t即是模型基于所有历史数据和当前最新特征后，所生成的t时刻的区域物流需求预测值。*tanh*函数则确保输出值在一个合理的范围内。

LSTM单元结构如图2所示。

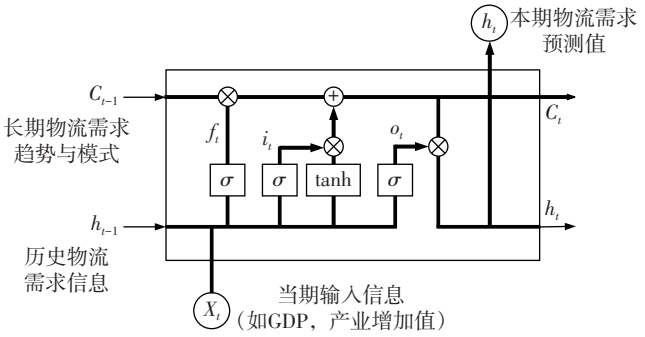

图2　LSTM单元结构

Fig.2　Structure of an LSTM unit

2.2　LSTM模型构建

在Anaconda环境下使用Python语言构建LSTM预测模型，模型框架结构示意图如图3所示。模型以多项关键指标t_1~t_n作为输入特征，例如地区生产总值(GDP)、人均可支配收入、固定资产投资额、

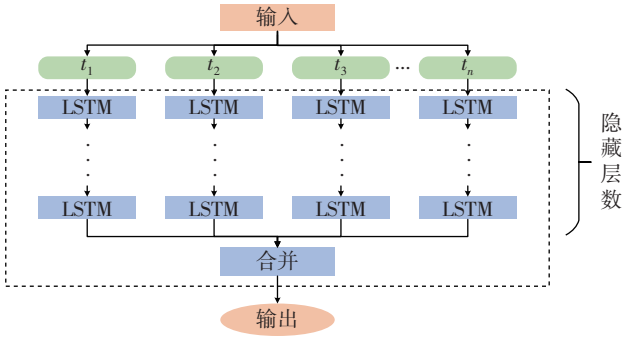

图3　LSTM 模型框架结构示意图

Fig.3　Structure of LSTM model framework

货物周转量等。该特征序列被输入多层LSTM网络进行训练与预测。

模型的具体层数和每层的隐藏节点数量需根据训练集和验证集的误差表现进行动态调整：若数据量较少，可减少LSTM层数以防止过拟合；若训练集和验证集误差均较高，则增加节点数以提升模型容量；若训练误差低而验证误差高，则减少节点数以降低模型复杂度。最终输出层生成目标区域总物流需求的预测值。

在预测过程中，为评估模型预测效果，用平均绝对百分误差*MAPE*和R^2 2种评判模型精准度的计算方法作为参照标准，各误差计算方法如下。

$$MAPE = \sum_{i=1}^{N}\left|\frac{y_i - x_i}{y_i}\right| \times \frac{100}{N} \tag{7}$$

$$R^2 = 1 - \frac{[\sum_i (x_i - y_i)]^2}{\sum_i (x_i - y_i)^2} \tag{8}$$

式中：N为数据样本总数；y为真实值；x为预测值。若实验后误差较大，则调整LSTM超参数，如增加时间步长、隐藏层节点数。

3　模拟计算与结果分析

3.1　数据收集与相关性分析

选取1990—2024年度货运量作为区域物流需求的代理变量。基于物流需求影响因素分析，初步采用北京、天津和河北的GDP、人均可支配收入、固定资产投资增长率、第一产业增加值、第二产业增加值、第三产业增加值、货物周转量、物流业占GDP比重、社会消费品零售总额、进口总额、出口总额、铁路营业里程、公路里程、内河航道里程14个指标作为特征变量。时间序列数据主要来源于国家统计局、北京市统计局、天津市统计局、河北省统计局。对于缺失数据，采用线性插值法填充。

基于收集到的基础数据，首先利用灰色关联分析方法精简影响因素。灰色关联度分析是了解事物在发展过程中的关联程度，通过分析物流需求与影响因素之间关系的强弱、大小和次序，可以知道各影响因素的重要程度。对各相关影响因素分别计算其与参考序列对应元素的关联系数的均值，以反映区域物流需求与相关影响因素的关联关系，并称其为关联度r_{oi}，其公式如下。

$$r_{oi} = \frac{1}{n}\sum_{k=1}^{n}\zeta_i(k) \tag{9}$$

式中：$\frac{1}{n}$为第n个指标变量的权重；k为关联系数的数量；$\zeta_i(k)$为第i个评价对象关于第k个指标变量的取值。

灰色关联系数计算结果如表2所示，对于各区域分别保留关联度大于0.6的影响因素，作为LSTM模型中的特征值。通过灰色关联分析发现，除物流规模与市场需求等直接关联维度外，区域经济发展、产业结构与基础设施是驱动京津冀物流需求的3个关键维度，其具体影响指标因地区而异：北京的核心关联指标为GDP总量、固定资产投资增长率、第一产业增加值、第三产业增加值、货物周转量、物流业占GDP比重、铁路营业里程；天津的关键影响因素包括人均可支配收入、固定资产投资增长率、第一产业增加值、第三产业增加值、货物周转量、铁路营业里程、公路里程、内河航道里程；而河北的物流需求则与GDP总量、人均可支配收入、第一产业增加值、第二产业增加值、第三产业

表2　灰色关联系数计算结果

Tab.2　Calculation results of grey relational coefficients

区域	GDP总量	人均可支配收入	固定资产投资增长率	第一产业增加值	第二产业增加值	第三产业增加值	货物周转量	物流业占GDP比重	社会消费品零售总额	进口总额	出口总额	铁路营业里程	公路里程	内河航道里程
北京	0.61	0.59	0.66	0.79	0.59	0.62	0.72	0.64	0.51	0.52	0.56	0.64	0.56	—
天津	0.58	0.61	0.75	0.75	0.59	0.61	0.76	0.51	0.53	0.58	0.59	0.72	0.60	0.77
河北	0.69	0.72	0.54	0.66	0.62	0.75	0.55	0.58	0.56	0.62	0.65	0.59	0.76	0.44

增加值、进口总额、出口总额、公路里程高度相关。

3.2　模型训练

实验在Intel(R) Core(TM) Ultra 9 285H @2.90 GHz，32G RAM的计算机上进行。网络构建采用Keras框架实现。LSTM将历年相关影响因素的指标数据分为训练集和测试集数据，使用训练集数据对模型进行调优，模型随机选取数据集的70%作为训练集，其余30%作为测试集。通过反复试验，对于北京、天津、河北地区，分别设定LSTM网络模型的隐含层层数为1，1，5。参数调整对照实验结果(河北)如图4所示。

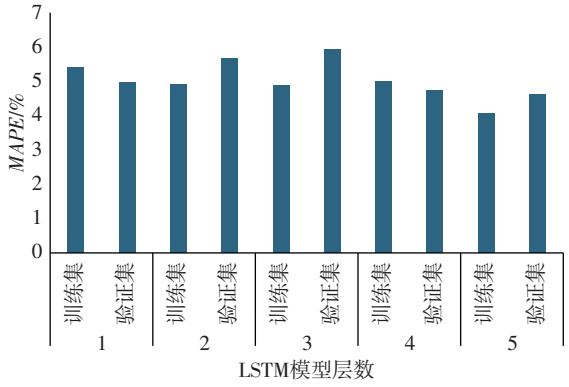

图4　参数调整对照实验结果(河北)

Fig.4　Comparative experimental results of parameter adjustment (Hebei)

调优过程表明：1层模型在训练集上表现欠佳，存在欠拟合；2层与3层模型在训练集上误差降低，但验证集误差显著升高，出现了过拟合；4层与5层模型有效控制了过拟合，验证集性能优异。最终选定5层作为河北省的最终模型。北京与天津地区的调优过程类似，结果表明1层隐含层结构即可达到最佳验证集性能。

3.3　预测结果与分析

为了全面评估LSTM模型的预测性能，从模型性能对比分析、区域差异成因探讨以及政策启示3个层面，对模型训练与预测结果进行剖析。

3.3.1　模型性能对比分析

LSTM模型训练与预测结果(北京)如图5所示，LSTM模型训练与预测结果(天津)如图6所示，LSTM模型训练与预测结果(河北)如图7所示。为比较LSTM预测方法与其他预测方法的预测精度，采用BP神经网络作为对照。LSTM和BP模型的预测迭代次数均设为500。BP神经网络模型采用2层网络结构，隐含层每层10个神经元。同样随机选取

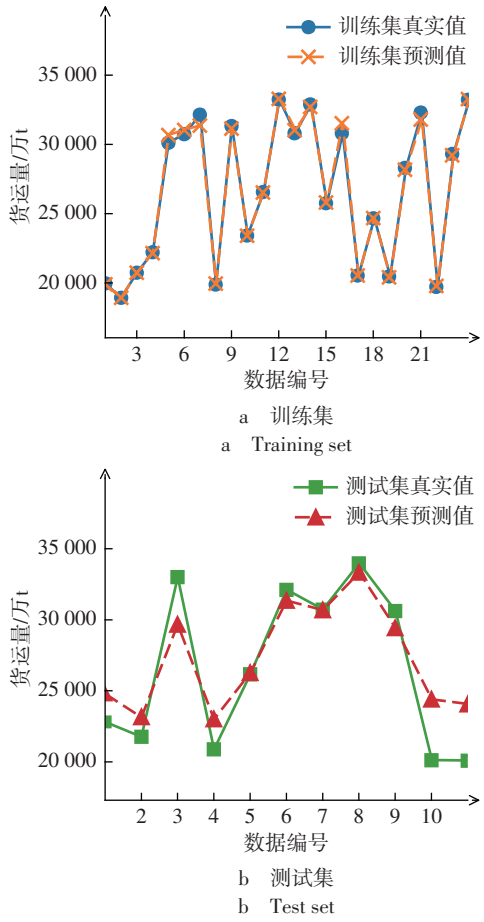

图5　LSTM模型训练与预测结果(北京)

Fig.5　Training and prediction results of LSTM model (Beijing)

数据集的70%作为训练集。

训练集预测结果对比如表3所示，测试集预测结果对比如表4所示。可以发现：对于3个地区，无论是训练集还是测试集，LSTM神经网络模型都优于BP神经网络模型，其泛化能力更优，体现了LSTM模型良好的预测性能。

采用性能更优的LSTM模型进行预测，将2025—2030年期间与物流需求相关的影响因素指标数据划分为训练集和测试集。在模型训练阶段，利用训练集数据对模型参数进行反复调优，直至模型预测性能趋于稳定。运用测试集数据对模型进行验证，评估其预测准确性。利用模型对京津冀地区未来的物流需求量展开预测，京津冀物流需求量预测结果如表5所示。

3.3.2　区域差异分析

从京津冀地区物流需求预测结果来看，整体上该区域物流需求呈波动增长态势，地区间差异明显，河北省物流需求量远超北京和天津且总体上

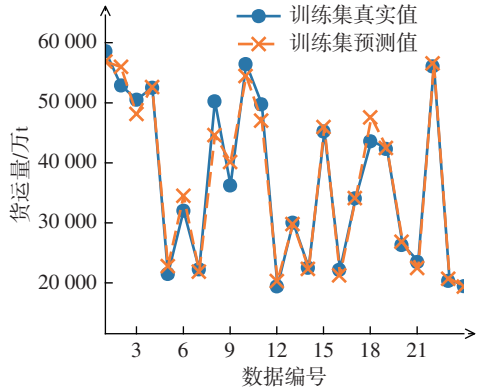

a　训练集

a　Training set

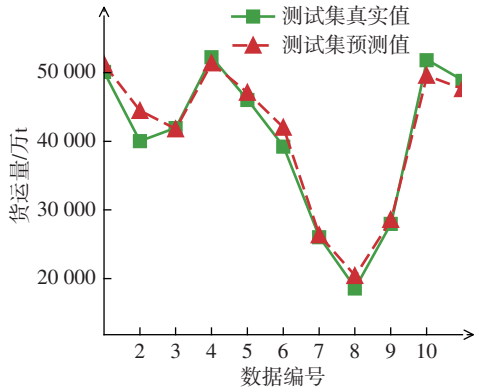

b　测试集

b　Test set

图6　LSTM模型训练与预测结果(天津)

Fig.6　Training and prediction results of LSTM model (Tianjin)

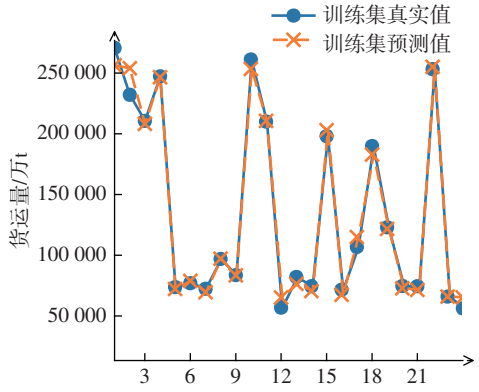

a　训练集

a　Training set

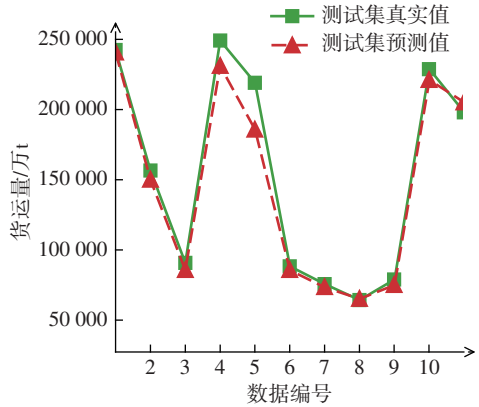

b　测试集

b　Test set

图7　LSTM模型训练与预测结果(河北)

Fig.7　Training and prediction results of LSTM model (Hebei)

升，在区域内占主导地位。三地需求结构的差异表明需制定差异化物流政策：河北需强化基础设施扩容与效率提升，京津则应注重高附加值物流服务优化。2025—2030年区域总物流需求增幅约23.7%，但在2027年需求回落，反映出区域协同发展中的不稳定性。需通过加强跨区域供应链协调等措施，提升区域抗风险能力和资源配置效率。京津冀三地物流需求存在显著差异是各地区经济发展阶段、产业结构与功能定位的不同所决定的。

（1）河北省。河北省物流需求总量远超京津两地之和，占区域总需求的80%以上，且至2030年保持增长趋势。河北省物流需求主要源于：①工业基础，河北省是传统的钢铁、建材、装备制造大省，这些产业对原材料输入和产成品输出的物流需求巨大；②重要的交通枢纽地位，河北省拥有多个重要港口(如唐山港、黄骅港)和交通干线，承担着大量的过境物流和转运功能；③承接京津产业转移，随着京津冀协同发展的深入，大量制造业企业从京津转移至河北，直接带动了当地的物流活动。

表3　训练集预测结果对比

Tab.3　Comparison of prediction results on training set

地区	BP模型		LSTM模型	
	MAPE	R^2	*MAPE*	R^2
北京	5.75	0.91	3.57	0.95
天津	5.36	0.97	3.84	0.98
河北	6.40	0.96	4.06	0.99

表4　测试集预测结果对比

Tab.4　Comparison of prediction results on test set

地区	BP模型		LSTM模型	
	MAPE	R^2	*MAPE*	R^2
北京	10.95	0.31	7.68	0.82
天津	6.03	0.93	3.95	0.97
河北	6.37	0.96	4.63	0.97

（2）北京市。北京市物流需求总量相对较小，且增长平稳，甚至在2027—2028年出现平台期。这

表5　京津冀物流需求量预测结果　　万t

Tab.5　Prediction results of logistics demand in Beijing-Tianjin-Hebei Region

年份	北京	天津	河北	合计
2025	20 747	53 871	307 047	381 665
2026	22 069	53 830	325 951	401 850
2027	23 926	53 537	311 394	388 857
2028	24 154	53 366	309 057	386 577
2029	24 644	53 061	336 863	414 568
2030	24 040	52 690	395 276	472 006

反映了北京城市功能的变化。北京正持续疏解非首都功能，产业结构向高精尖如科技创新、金融服务、文化产业转型。这些产业产生的物流需求多为小批量、高价值、时效性强的快递物流，而非大宗商品物流。因此，其物流需求的总量增长放缓，但对物流服务的质量、效率和智能化水平提出了更高要求。

（3）天津市。天津市物流需求预测值呈现小幅下降趋势。这与天津港口的转型升级和城市定位优化有关。天津正在从传统的货物吞吐量竞争转向提升港口增值服务和航运高端服务。同时，随着京津冀交通一体化的完善，部分物流环节可能直接疏解到河北的港口和物流园区，导致天津的物流需求量略有回落，但单位物流附加值在提升。

3.3.3　政策启示

根据表5的预测结果，京津冀区域物流需求总量从2025年的38.17亿t增长至2030年的47.20亿t，总体增幅达23.7%，展现了区域经济的活力。然而，增长过程并非线性，特别是2027年的需求回落(从40.19万t降至38.89万t)值得深入分析。这种波动可能由以下因素引起。

（1）宏观经济周期性调整。物流需求作为经济运行的先导指标，其波动往往领先于实体经济变化。2027年的预测回落可能反映了模型对当时宏观经济进入短周期调整期的预判，这与“十四五”规划中关于经济增速换挡期的特征描述相吻合。

（2）产业政策实施效应。随着京津冀生态协同推进，未来钢铁、化工等大宗货物运输密集型产业在此期间实施集中技改或产能调控，可能引发运输需求的阶段性收缩。

（3）模型需求周期规律验证。LSTM模型通过深度挖掘历史数据中的时序特征，识别出京津冀物流需求存在约4年左右的周期性波动模式。前两个周期峰值分别出现在2014年和2018年，2027年的回调恰处于第3个完整周期节点。

基于以上分析，提出以下政策启示。

（1）差异化战略。应实施差异化的区域物流政策。河北应重点加强物流基础设施的扩容、升级和多式联运效率，应对持续增长的量能压力。京津两地则应聚焦于发展智慧物流、绿色物流和供应链管理，提升物流服务的品质和附加值。

（2）强化区域协同以平滑波动。针对预测中出现的波动，三地应建立跨区域的物流供需协调与应急机制。通过信息共享平台，提前预判需求变化，灵活调配运力、仓储等资源，增强整个区域物流系统的抗风险能力和稳定性，避免因需求波动造成资源浪费或运力短缺。

（3）前瞻性基础设施规划。面对2030年47亿t的总体需求，现有基础设施将面临考验。需依据预测结果，提前布局关键通道、枢纽节点的建设与改造，确保物流网络的畅通与高效。

4　结束语

以京津冀区域物流需求为研究对象，针对传统预测方法在区域一体化融合不足、数据来源单一、异构性处理不强以及模型适应性差等方面的局限性，充分利用多源异构数据，提出一种基于LSTM的物流需求预测方法。通过收集和整合区域经济基础、产业特征、物流供给能力、市场需求和基础设施水平等多维度数据，运用灰色关联分析筛选关键影响因素，构建了适用于区域物流需求预测的深度学习模型。

在京津冀区域的实证分析中，灰色关联分析表明驱动京津冀物流需求的关键因素不仅限于物流规模与市场需求等直接关联维度，还体现在区域经济发展、产业结构与基础设施3个维度上，其具体表征指标因地区而异；预测结果表明，LSTM模型能有效应用于区域物流需求预测。基于预测结果提出以下三方面政策启示：一是实施差异化区域策略，河北应强化基础设施能力，京津则需聚焦高附加值物流服务；二是建立跨区域协同机制，通过信息共享与资源调配提升系统韧性；三是推进前瞻性基础设施规划，依据需求预测提前布局关键物流节点与通道，保障网络长期效能。

未来研究可以进一步拓展数据来源，考虑更多影响物流需求的因素，如政策变化、突发事件等，以进一步提升预测模型的准确性和实用性。同时，可以探索将LSTM模型与其他先进技术相结合，如大数据分析、物联网等，构建更加智能、高效的物流需求预测系统，为区域物流产业的可持续发展提供有力支持。

参考文献：

[1] 周　茵．残差灰色预测模型在物流需求预测中的应用[J]. 铁道运输与经济，2007，29(11)：59-61.
ZHOU Yin. Application of Residual Error Gray Forecast Model on Logistics Demand Forecast[J]. Railway Transport and Economy，2007，29(11)：59-61.

[2] 程肇兰，张小强，梁　越．基于LSTM网络的铁路货运量预测[J]. 铁道学报，2020，42(11)：15-21.
CHENG Zhaolan，ZHANG Xiaoqiang，LIANG Yue. Railway Freight Volume Prediction Based on LSTM Network[J]. Journal of the China Railway Society，2020，42(11)：15-21.

[3] 汪　岗，马　亮，陈奕霖．基于EMD与Attention-LSTM的铁路货运站短期装车量预测研究[J]. 铁道货运，2023，41(12)：60-69.
WANG Gang，MA Liang，CHEN Yilin. Short-Term Prediction of Car Loading Quantities for Railway Freight Station Based on EMD and Attention-LSTM[J]. Railway Freight Transport，2023，41(12)：60-69.

[4] 张海山，王文斌，周　瑾．基于异质时空图注意力网络的铁路车站货运量预测[J]. 铁道货运，2024，42(6)：52-59.
ZHANG Haishan，WANG Wenbin，ZHOU Jin. Freight Volume Prediction of Railway Station Based on Heterogeneous Spatial-Temporal Graph Attention Network[J]. Railway Freight Transport，2024，42(6)：52-59.

[5] 郭红霞．基于BP神经网络的物流需求量预测框架设计[J]. 铁道运输与经济，2007，29(11)：68-70.

[6] 赵文德，黄丽娟，胡子瑜．基于BP神经网络组合模型的广东省区域物流需求能力预测[J]. 物流技术，2020，39(12)：49-56，66.
ZHAO Wende，HUANG Lijuan，HU Ziyu. Forecasting of Regional Logistics Demand Capacity in Guangdong Province Based on BP Neural Network Combination Model[J]. Logistics Technology，2020，39(12)：49-56，66.

[7] 张建涛，施少杰，贾琳瑜．基于BP神经网络模型的北京市区域物流需求能力预测研究[J]. 物流工程与管理，2025，47(1)：28-33.
ZHANG Jiantao，SHI Shaojie，JIA Linyu. A Study on the Forecasting of Regional Logistics Demand Capacity in Beijing Based on BP Neural Network Model[J]. Logistics Engineering and Management，2025，47(1)：28-33.

[8] 阮俊虎．基于GA-SVM的区域物流需求预测研究[D]. 邯郸：河北工程大学，2010.

[9] 王　娜，李晏丞．基于GA-SVR的江苏省区域物流需求预测研究[J]. 物流科技，2025，48(5)：101-105.
WANG Na，LI Yancheng. Optimization GA-SVR Logistics Demand of Jiangsu Province Prediction Model on Genetic Algorithm[J]. Logistics Sci-Tech，2025，48(5)：101-105.

[10] 左　雷，徐柏安．区域物流需求影响因素实证分析及总量预测：以湖北省孝感市为例[J]. 物流技术，2020，39(12)：39-44.
ZUO Lei，Xu Boan. Empirical Analysis of Influencing Factors and Total Volume Forecasting of Regional Logistics Demand：In the Case of Xiaogan，Hubei[J]. Logistics Technology，2020，39(12)：39-44.

[11] 张雅淇．A县现代农业产业园区物流需求预测研究[D]. 北京：北京交通大学，2024.

[12] 尹　玥，陈宇婷．基于灰色预测的京津冀地区农产品物流需求分析[J]. 湖北农业科学，2023，62(1)：214-218，223.
YIN Yue，CHEN Yuting. Analysis of Agricultural Products Logistics Demand in Beijing-Tianjin-Hebei Region Based on Grey Forecast[J]. Hubei Agricultural Sciences，2023，62(1)：214-218，223.

[13] 郑兴彤．福建省生鲜农产品冷链物流需求预测研究[D]. 漳州：闽南师范大学，2024.

[14] 王　辉．基于LSTM模型的环渤海地区可再生能源预测研究[D]. 天津：天津理工大学，2020.

[15] 何西健．胶州铁路物流中心运量预测研究[J]. 铁道运输与经济，2020，42(7)：97-102.
HE Xijian. Freight Volume Forecast of Jiaozhou Railway Logistics Center[J]. Railway Transport and Economy，2020，42(7)：97-102.

[16] DOMBI J，JÓNÁS T，TÓTH Z E. Modeling and Long-Term Forecasting Demand in Spare Parts Logistics Businesses[J]. International Journal of Production Economics，2018，201：1-17.

[17] MITRA A，JAIN A，KISHORE A，et al. A Comparative Study of Demand Forecasting Models for a Multi-Channel Retail Company：A Novel Hybrid Machine Learning Approach[J]. Operations Research Forum，2022，3(4)：58.

(责任编辑　汪沁萱)