

交通流动态预测LSTM模型设计

王迎*, 张立东#, 杨晓萌, 尚志浩

山东交通学院交通与物流工程学院, 山东 济南

收稿日期: 2023年11月25日; 录用日期: 2023年12月21日; 发布日期: 2023年12月27日

摘要

针对交通流具有周期性动态性的特点, 为提高交通流预测精度, 在充分分析交通流日波动和周波动特征规律的基础上, 构建了交通流预测LSTM模型; 以均方根误差和平均绝对误差为评价指标, 构建了LSTM模型参数寻优设计逻辑, 提出了适用于交通流动态变化的层数、批处理大小、隐藏层节点数、序列长度、学习率参数的选定准则, 并以PyTorch智能框架搭建了测试环境。研究表明, 优化后的LSTM模型在交通流量预测任务上表现出显著的优越性, 预测结果与实际值之间的差距明显缩小, 同时也为LSTM模型超参数优化提供了一种可行有效的方法。

关键词

交通流预测, 人工智能, 长短期记忆网络, 时间序列, 深度学习

Design of LSTM Model for Traffic Flow Dynamic Prediction

Ying Wang*, Lidong Zhang#, Xiaomeng Yang, Zhihao Shang

School of Transportation and Logistics Engineering, Shandong Jiaotong University, Jinan Shandong

Received: Nov. 25th, 2023; accepted: Dec. 21st, 2023; published: Dec. 27th, 2023

Abstract

To address the periodic and dynamic characteristics of traffic flow and improve the accuracy of traffic flow prediction, a traffic flow prediction LSTM model was constructed on the basis of fully analyzing the daily fluctuation and weekly fluctuation characteristics of traffic flow. Using the root mean square error and the mean absolute error as evaluation indicators, an LSTM model parame-

*第一作者。

#通讯作者。

ter search was constructed. Optimize the design logic, propose selection criteria for the number of layers, batch size, number of hidden layer nodes, sequence length, and learning rate parameters that are suitable for dynamic changes in traffic flow, and build a test environment with the PyTorch intelligent framework. The research results show that the optimized LSTM model shows significant superiority in traffic flow prediction tasks, and the gap between the prediction results and the actual values is significantly narrowed. It also provides a feasible and effective method for hyperparameter optimization of the LSTM model.

Keywords

Traffic Flow Prediction, Artificial Intelligence, Long Short Term Memory Network, Sequentially, Deep Learning

Copyright © 2023 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

随着城市化进程的加速和交通运输需求的不断增长，交通流预测成为了城市规划和交通管理领域中的一个关键问题。准确地预测交通流可以帮助决策者制定合理的交通规划方案，提高道路网络的效率，减少交通拥堵，改善出行体验，以及减少交通事故的发生。然而，由于交通系统的复杂性和不确定性，精确地预测交通流一直是一个具有挑战性的任务。

传统的交通流预测方法通常基于统计模型或时间序列分析，如 ARIMA、SARIMA 等[1]。然而，这些方法通常无法很好地捕捉交通流中的非线性关系和长期依赖性。此外，交通流数据通常具有高度的时空相关性，传统方法往往无法有效地利用这种关联信息。因此，需要开发一种新的预测方法，能够更好地处理交通流数据的复杂性和时空相关性。近年来，深度学习技术在自然语言处理和视觉处理等领域实现了重大突破，其中，LSTM 网络在自然语言处理中是一种关键的循环神经网络模型，在序列建模和预测任务中得到广泛应用。该网络具有强大的记忆能力，能够捕捉序列数据中的长期依赖关系，并具备较好的非线性建模能力。因此对 LSTM 网络进行实验设计并交通流进行预测[2]，Y Lv 等使用了 LSTM 网络来建模交通流数据中的时空特征[3]。B Yu 等提出了一种基于时空图卷积网络的交通流预测框架[4]。D Kang 等采用长短期记忆循环神经网络来分析各种输入设置对短期交通流预测性能的影响[5]。B Yang 等提出了将非常长的序列时间步的高影响值与当前时间步联系起来，并使用注意力机制捕获这些高影响的流量值的方法[6]。Y Tian 等提出了一种基于修订后的 LSTM 模型显式组合缺失模式来学习预测残差的新方法[7]。Y Xiao 等提出了一种基于 LSTM 模型的混合长短期记忆神经网络[8]。长短期记忆网络是 RNN 的一种特殊改进类型，它可以解决 RNN 中存在的梯度消失问题[9]，能够对时间序列中延迟非常长的重要事件进行有效预测。Yang 等人利用注意力机制对交通流数据进行捕捉，以提高 LSTM 模型对更长时间序列的依赖性，改善了模型的预测性能[10]。王祥雪等人通过一阶差分法先对交通流数据进行平稳化处理，再进行时间序列重构，构建时间序列预测框架，利用 LSTM 对重构后的数据进行预测，提高了模型的实用性和时效性[11]。孔文翔等提出了一种基于动态时空图卷积的多传感器路网交通流预测的方法，可以更好地捕捉交通数据的空间特征[12]等。

现有基于 LSTM 预测交通流的研究存在时间序列动态特征提取和外部影响因素整合不足的问题，难

以很好应对交通流动态复杂变化特点。为此,一些研究提出了增强型 LSTM 结构,加入注意力机制,结合图卷积网络考虑交通网络拓扑,联合多源数据共同学习等方法,目的是强化 LSTM 在捕捉交通流动态变化规律和处理大规模交通网络的能力,从而提高实际交通预测的准确性,弥补传统 LSTM 在交通流预测任务中的不足,提升了模型的实用性,提供了模型设计的新思路。

2. 交通流预测 LSTM 模型

2.1. 交通流周期性波动特点分析

2.1.1. 日交通流波动特点

分析一天内以 5 分钟为间隔的交通流波动特点,如图 1 所示,可以看到这样的数据可以捕捉到交通流量的高频波动、详细的交通趋势,以及对交通突发事件的高敏感度。与此同时,以 5 分钟为间隔的数据精度更高,能提供更为精确的交通流量分析。然而,这也意味着数据量大,需要更大的存储空间和更强大的数据处理能力。相反,更长的时间间隔,例如 15 分钟、30 分钟或 1 小时,虽然可能忽视一些短期波动,但提供了更为便捷的数据处理和分析,以及更简单的分析复杂性。因此,5 分钟的交通流量数据提供了更精细和详细的交通流量信息[13],但同时也需要更大的数据处理能力和更复杂的数据分析方法。

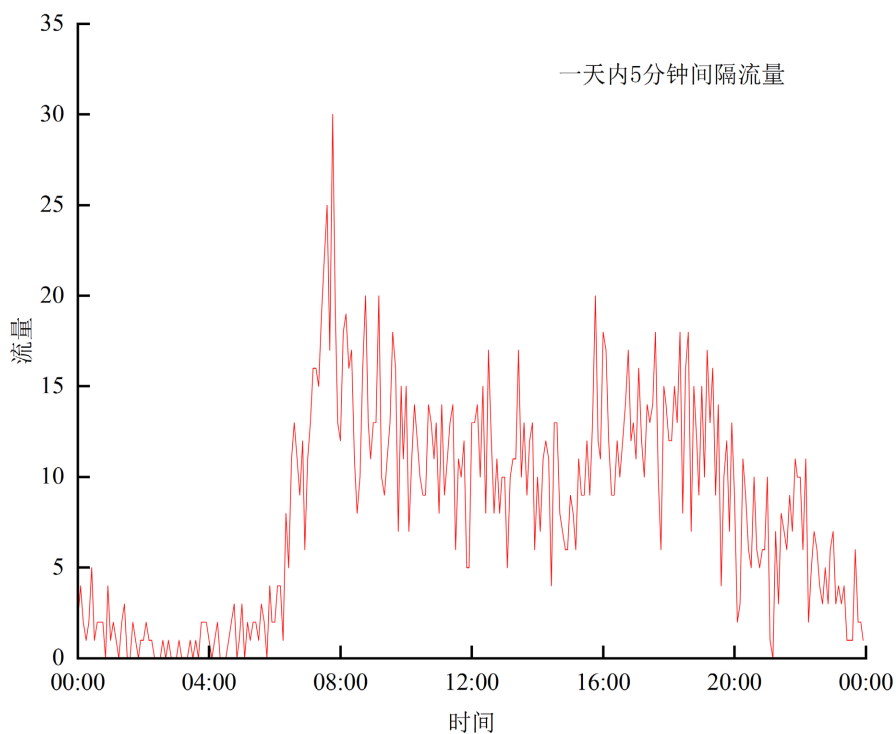


Figure 1. Traffic flow diagram at 5-minute intervals per day

图 1. 日 5 分钟间隔交通流量图

2.1.2. 周交通流波动特点

分析一周内以 5 分钟为间隔的交通流波动特点,如图 2 所示,每天的交通流量呈现周期性变化,交通流量在早晚高峰交通繁忙时出现峰值,可能导致交通拥堵,在深夜或凌晨,交通流量相对较低且稳定。




Figure 2. Weekly traffic flow data chart (part)
图 2. 周交通流量数据图(部分)

在上述分析交通流周期性波动特性基础上，下面设计适合其变化规律的预测模型。

2.2. RNN 循环神经网络原理

循环神经网络(Recurrent Neural Network, 简称 RNN)是一种可以处理时间序列数据的神经网络，它的设计目的是为了捕捉时间序列数据中的前后时间联系，从而更好地理解 and 处理这些数据。RNN 引入了循环连接的核心思想，使网络在每个时间步处理输入时考虑了之前时间步的信息。该循环连接使 RNN 可以处理短期时间依赖，并保持对前一时间步的记忆，使其在序列数据处理方面具有优势。

RNN 的结构包含输入层、隐含层和输出层，与其他神经网络相似。但是，RNN 的隐含层节点的输入既有当前时刻输入层输入，还有上一时刻隐含层输出作为输入。这些隐含层单元承担着主要的任务。网络结构如图 3 所示[14]。




Figure 3. RNN network structure
图 3. RNN 网络结构




Figure 4. RNN signal transmission mechanism
图 4. RNN 信号传递机制

图 4 为循环神经网络的信息传递机制。 x_t 是 t 时刻输入层的输入； s_t 是隐藏层的输出； y_t 是输出层的输出。从图 4 可知，RNN 的关键一点是 s_t 的值不仅取决于 x_t ，还取决于 s_{t-1} 。循环神经网络中，在预测 y_t 时，不仅要使用 x_t 的信息，还要使用 x_{t-1} 的信息，因为水平轴路径上的隐式状态激活信息有助预测 y_t 的精度。

RNN 通过循环连接将前上一时刻信息传到当前时刻，然后传给下一时刻，进而实现信息长期传递。表达式如下式所示。

$$O_t = g(V_{s_t})$$

$$S_t = f(U_{x_t} + W_{s_{t-1}})$$

式(1) (2)中向量 X 、 S 、 O 分别表示输入层、隐藏层和输出层的数值； U_{x_t} 、 V_{s_t} 分别表示从输入层到隐藏层、隐藏层到输出层的权重矩阵， $W_{s_{t-1}}$ 则是隐藏层上一层的值作为这一次的输入值的权重矩阵； $g(\cdot)$ 与 $f(\cdot)$ 表示激活函数。

2.3. LSTM 模型结构设计

RNN 是一类具有循环连接的神经网络结构，用于处理序列数据和变长输入。它的核心思想是在每个时间步将隐藏状态作为下一个时间步的输入，并将过去的信息迭代传递到未来的时间步，使得 RNN 能够捕捉序列中的时序信息。然而，传统的 RNN 在处理长序列和长期依赖关系时存在困难，因为梯度在反向传播过程中容易消失或爆炸。LSTM 通过引入门控机制解决了该问题。LSTM 包括输入门、遗忘门和输出门，允许网络有选择性地读取信息和遗忘信息。这三门决定了细胞状态的更新和传递过程，让 LSTM 可以更好地捕捉信息的长期依赖关系，并且有效地解决了 RNN 中的梯度问题。在分析 RNN 循环神经网络基本原理基础上的结构如图 5 所示[15]：

存储单元是 LSTM 网络的关键单元，通过对门控单元操作，有选择性地添加和删除信息。LSTM 在 t 时刻具体过程如下：

1) 确定在遗忘门 f_t 中应从前一时刻的单元状态 c_{t-1} 的历史流量数据、周期性规律、流量的长期依赖关系、流量变化趋势信息中丢弃哪些时刻的交通流信息；

$$f_t = \sigma(\omega_{f_x} x_t + \omega_{f_x} x_{t-1} + b_f)$$

2) 区分当前时刻交通流量输入 x_t 的哪些交通流信息应被存储到输入门的当前单元状态 c_t 中，应在哪里更新信息 i_t ，和候选单元状态 c_{it} ；

$$i_t = \sigma(\omega_{ix}x_t + \omega_{ix}x_{t-1} + b_i)$$

$$c_{it} = \tanh(\omega_{cx}x_t + \omega_{ch}h_{t-1} + b_c)$$

3) 更新当前时刻历史流量数据、周期性规律、流量的长期依赖关系、流量变化趋势信息 c_t 的单元状态:

$$c_t = f_t c_{t-1} + i_t c_{it}$$

4) o_t 决定当前时刻细胞状态 c_t 中历史流量数据、周期性规律、流量的长期依赖关系、流量变化趋势哪些信息作为输出门中当前时刻预测流量输出结果 h_t 。

$$o_t = \sigma(\omega_{ox}x_t + \omega_{oh}h_{t-1} + b_o)$$

$$h_t = o_t \tanh(c_t)$$

以上式中, ω 表示权重值, x_t 表示当前时刻输入, h_t 表示当前时刻输出, c_t 表示当前时刻的细胞状态, b 为偏置值, σ 表示 sigmoid 函数, 下标 f, i, o 分别表示遗忘门, 输入门和输出门, 其中 Sigmoid 和 tanh 这两个激活函数表示如下。

$$\sigma(x) = \frac{1}{1 + e^{-x}}$$

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$

LSTM 单元通常是网络中的最后一个单元, 因此网络的最终输出值即为交通流量的预测结果。

$$y = \text{softmax}(W \otimes h_t + b)$$

其中, softmax 为激活函数, W 为权重矩阵, b 为偏置矩阵, \otimes 表示两个矩阵乘积。

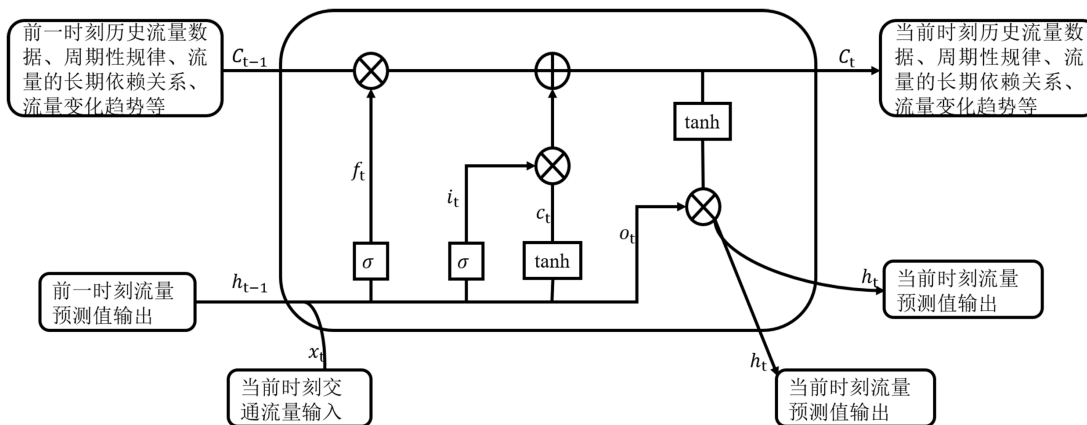


Figure 5. Traffic flow LSTM network structure
图 5. 交通流 LSTM 网络结构

2.4. LSTM 模型参数寻优设计

Step1: 数据集进行预处理,对缺失的数据用相邻数据平均法进行补充,并将补充后的十一天数据集中的前十天数据划分为训练集,最后一天数据划分为测试集,然后对划分后的数据进行归一化处理。

$$y_t = (y_{t-1} + y_{t+1})/2$$

$$M = y_t - \mu/\sigma$$

y_t 为时刻 t 缺失数据, y_{t-1}, y_{t+1} 分别是时刻 $t-1, t+1$ 数据, M 为归一化后数据, y_t 为原始数据, μ 为

原始数据平均值, σ 为原始数据的标准差。

Step2: 定义 LSTM 网络的结构, 设置 `num_layers`、`batch_size`、`hidden_size`、`seq_length` 和 `learning_rate` 常用的值作为 LSTM 网络的初始参数。

Step3: 训练集训练 LSTM 网络, 得到交通流预测模型。

Step4: 验证训练好的模型, 使用测试集测试交通流预测模型的训练效果。

Step5: 模型超参数寻优, 对 `num_layers`、`batch_size`、`hidden_size`、`seq_length` 和 `learning_rate` 五种超参数分别进行验证选择, 选出最优的超参数组合。

Step6: 交通流量预测, 利用验证选出的最优超参数组合进行交通流量的预测, 将交通流量预测值与实际值进行比较。

通过上述的 6 个步骤可实现 LSTM 模型超参数寻优设计和交通流的动态预测。

3. 实验分析

3.1. 数据来源

实验的数据来自济南市交通运输局, 选取建国小经三-岔路街西进口流量被用来进行实验, 交通流量的统计日期为 2021-05-20 至 2021-05-30 共 11 天内的流量, 交通流量的统计间隔每 5 分钟统计一次, 数据总条数为 3168 条。

考虑到数据大小对预测精度有影响, 采用标准差归一化的方法对数据进行归一化处理, 归一化处理后的数据的相对大小和整体变化趋势不会发生改变。然后使用归一化后的数据进行交通流预测, 将预测后的数据再进行反归一化处理, 得到最初的交通流量量级数据。

3.2. 建立实验

首先对 11 天内 3168 个数据进行划分为训练集和测试集, 训练集和测试集划分的比例为前十天的数据为训练集, 最后一天的数据为测试集。实验的预测目标是根据前十天的历史交通流信息预测接未来一天内每 5 分钟一个间隔的车流量。

实验使用 Python 语言、PyTorch 人工智能框架实现预测, 并使用图形单元(GPU)加速模型的迭代过程。LSTM 网络的训练基于 adam 优化器[16], 因其在 RNN 模型的训练中表现良好[17], tanh 作为激活函数被用在状态和输出上。开发时所使用的环境、开发工具和软件配置环境如表 1 所示:

Table 1. System environment

表 1. 系统环境

软硬件环境	
处理器	Intel Core i7-8550U @ 1.80GHz~2.40GHz
内存	16GB
显卡	NVIDIA GeForce MX150
操作系统	Windows 10
开发工具	PyCharm Community Edition 2023.2
开发语言	Python 3.7
Pytorch	Version 1.13.1
CUDA	Version 10.2
Pandas	Version 1.3.5
Numpy	Version 1.21.5

3.3. 评价指标

交通流的预测效果由实际值和预测值的差来反映。目前在交通流预测中,采用均方根误差(RMSE)和平均绝对误差(MAE)作为评价指标[18],用于描述预测结果的准确性。计算公式如下:

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |y_o - y_p|$$

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_o - y_p)^2}$$

上式中, y_o 、 y_p 分别表示预测时间的真实值和预测值, N 表示交通流数据的数量。评价指标值低意味着模型预测时误差低,即该模型预测精度高。

3.4. 模型主要参数选择

一般而言,神经网络的性能往往与网络参数设置有关。因此,实验分析 LSTM 层数(layers_num)、批处理大小(batch_size)、隐藏层节点个数(hidden_size)、序列长度(seq_length)、学习率(learning_rate)等决定网络架构的主要超参数对模型预测结果的影响,从而选择出最优的网络结构参数设置,迭代次数(num_epochs)固定为 50 次。

3.4.1. 网络层数选择

实验只用到 LSTM 神经网络进行交通流量的预测,所以整个网络的性能好坏与 LSTM 网络层数息息相关,本小节主要讨论了实验中 LSTM 网络层数的选择。

在实验中,其他 LSTM 网络超参数保持不变,改变 LSTM 网络层数进行实验,并对实验结果进行对比。如图 6、图 7 所示的比较结果,横坐标轴表示 LSTM 网络层的层数,纵坐标表示对应网络层数预测的均方根误差和平均绝对误差的值。共选择 7 层作为实验,从图中可以清晰的看到折线的最低点均落在了 4 层的 LSTM 网络层数上[19][20],RMSE 值和 MAE 值均在 4 层的情况下值最小,都达到了最佳性能。增加 LSTM 的层数可以提高模型的复杂性和预测能力,但同时也可能增加过拟合的风险,层数的增加也会导致计算量的增加。综合考虑,不再考虑增加 LSTM 的层数进行实验,选择 4 层作为实验的 LSTM 层数。




Figure 6. RMSE value of experimental results with different LSTM layers

图 6. 不同 LSTM 层数实验结果 RMSE 值




Figure 7. MAE value of experimental results with different LSTM layers
图 7. 不同 LSTM 层数实验结果 MAE 值

3.4.2. 批处理大小选择

批处理大小是深度学习中的一个重要超参数，它可以影响模型的训练速度和质量，对于批处理大小的选择取决于多个方面。

确定好网络层数之后，将网络层数固定，来对批处理的大小进行实验调优，从一个较小的批处理大小开始，然后逐渐增大，直到找到能够在训练速度和模型质量之间达到最佳平衡的值。实验结果如图 8 所示。




Figure 8. Experimental results of different batch sizes RMSE value and MAE value

图 8. 不同批处理大小实验结果 RMSE 值和 MAE 值

批处理大小的取值一般为 2^n 的形式，因为 CPU 和 GPU 的内存架构是 2^n 形式。CPU 和 GPU 在读取内存时是以块为单位进行读取，块的大小为 2 的倍数。所以，选择 2^n 形式作为批处理大小取值的原因是方便 GPU 对数据进行并行处理。批处理大小可以根据训练数据集的大小和硬件计算能力来确定。使用较大的批处理大小可以加快训练速度，特别是在处理大型数据集时。对于较小的数据集，使用较大的批处理大小可能会导致模型过拟合，因此需要选择较小的批处理大小。硬件的计算能力是选择批处理大小的另一个重要因素。如果内存资源充足，可以选择较大的批处理大小，这样可以更快地进行模型训练。但是，如果内存资源有限，需要选择较小的批处理大小。通常来说，随着批处理大小的值增大，训练速度提高，会导致过拟合问题。随着批处理大小值减小，则训练速度减慢，但对于较大的数据集和计算机内存限制的情况下更为稳定[21]。综合考虑数据集的大小和计算机配置，不再考虑增加 `batch_size` 进行实验，选择 16 作为实验的批处理大小。

3.4.3. 隐藏层节点个数选择

选择适当的 `hidden_size` 值是一个相对问题，没有一个固定的最佳值。它的选取取决于数据集的复杂性、模型的深度、硬件计算能力以及是否需要防止过拟合等因素。一般来说，较小的 `hidden_size` 适用于简单的问题，而较大的 `hidden_size` 适用于复杂的问题。比较结果如图 9 所示：




Figure 9. RMSE value and MAE value of experimental results with different number of hidden layer nodes

图 9. 不同隐藏层节点数实验结果 RMSE 值和 MAE 值

通常来说，较小的 `hidden_size` 选取依据是时间序列问题相对简单，数据集不是特别大，计算资源有限，数值通常在 32~128 之间。较小的 `hidden_size` 会更容易训练，但在复杂问题上的表现受限。中等的 `hidden_size` 选取依据是数据集规模中等，并且计算资源充足，数值通常在 128~256 之间。这通常是一个比较合理的起点，适用于大多数中等规模的时间序列问题。较大的 `hidden_size` 选取的依据是复杂的时间序列问题和大规模的数据集，数值通常在 256~512 之间，甚至可以更大。较大的 `hidden_size` 通常具有更

强的表示能力，能够更好地捕捉复杂的模式，但需要更多的计算资源。综合考虑实验所用数据集比较简单和计算机硬件计算能力有限，选择较小的 `hidden_size` 进行试验[22]，RMSE 和 MAE 值均在 `hidden_size` 为 32 时值最小，选择 32 作为实验的隐藏层节点个数。

3.4.4. 序列长度选择

时间序列长度也是深度学习中一个重要的超参数，它决定了模型每次输入的数据量以及模型可以记住的历史信息长度。时间序列长度较短时，模型每次只能看到很有限的历史数据，难以捕捉交通流的长期趋势和周期性模式。但计算量较小，训练速度较快。时间序列长度较长时，模型可以利用更多的历史数据进行模式学习，能够更好地捕捉交通流的周期性和趋势信息，从而提高预测准确率。但是计算量会大大增加，训练速度下降。

实验从给定的集合为{2,4,6,8,10,12,14,16}中逐个取值进行实验验证，实验的同时固定其他超参数不变，来比较模型的训练和验证效果，选择一个验证误差较低、计算速度可以接受的序列长度作为最终的超参数[23] [24]。实验的对比结果如图 10 所示。




Figure 10. RMSE values of experimental results with different sequence lengths

图 10. 不同序列长度实验结果 RMSE 值

由对比结果可知，序列长度的值在 2~6 的范围内，RMSE 值越来越小，模型性能的表现逐渐上升，序列长度的值在 6~16 的范围内，RMSE 值越来越大，模型性能的表现逐渐下降。所以，序列长度的值为 6 时，模型的性能表现最佳，选取 6 作为实验的序列长度。

3.4.5. 学习率选择

学习率是决定 LSTM 网络学习速度的超参数。学习率的值设置过大会导致模型无法收敛，学习率的值设置过小会导致模型训练速度减慢。在实践中，可以通过反复尝试不同的学习率来找到最优值。首先需要确定学习率的合理取值范围，通常建议将初始学习率设置为较小的值，因数值太多，实验取 0.0001、0.0005、0.001、0.005、0.01 作为实验的学习率取值[25]。实验对比结果如图 11 所示。




Figure 11. Experimental results of different learning rates RMSE value and MAE value

图 11. 不同学习率实验结果 RMSE 值和 MAE 值

由实验结果可知，RMSE 值和 MAE 值均在学习率为 0.001 时达到最小，模型的性能最佳。因此选择 0.001 作为实验的学习率。

3.5. 结果分析

以上通过对 LSTM 网络超参数的选择，选取网络层数为 4，批处理大小为 16，隐藏层节点数为 32，序列长度为 6 和学习率为 0.001 作为实验的最优参数组合。实验结果的误差值如表 2 所示，预测结果如图 12 所示。




Figure 12. Comparison of LSTM model prediction results and actual values

图 12. LSTM 模型预测结果与实际值对比

Table 2. LSTM model prediction results
表 2. LSTM 模型预测结果

Model	RMSE	MAE
LSTM	3.51	2.63

分析图 12 可知 LSTM 模型的预测结果和实际交通流数据误差在一个小的范围内,基本反映了 5 分钟间隔的交通流在一天内随时间变化的规律。当交通流量出现突变时,预测值和实际值之间可能会存在较大的差距,导致误差增大。该交通流动态预测 LSTM 模型的预测结果可近似表示出真实交通流一天内的变化趋势,预测结果值与真实数据值接近。

4. 结束语

提出了一种基于适用于交通流动态预测的 LSTM 的交通流预测模型。该模型考虑了交通流动态波动的特点,很好地处理时间序列问题,适用于短时交通流预测。通过实验尝试不同的超参数,能够更好地理解每个超参数对模型性能的影响。实验结果表明,在交通流预测任务中,使用 4 层 LSTM、批处理大小为 16、隐藏层节点数为 32、序列长度为 6 以及学习率为 0.001 的超参数组合获得了最佳的性能。城市道路交通流既包括时间特征,还包括空间特征。在未来的研究中将考虑交通流数据中的空间特征和天气等其他因素,提高交通流预测的精度。

基金项目

国家自然科学基金(61773243); 山东省交通运输厅科技计划项目(2020B89-01)。

参考文献

- [1] Williams, B.M., Durvasula, P.K. and Brown, D.E. (1998) Urban Freeway Traffic Flow Prediction: Application of Seasonal Autoregressive Integrated Moving Average and Exponential Smoothing Models. *Transportation Research Record*, **1644**, 132-141. <https://doi.org/10.3141/1644-14>
- [2] 吴兴宇, 刘雅, 王陈炜, 等. 基于 SUE 模型的区域交通配流问题[J]. 实验科学与技术, 2017, 15(5): 1-5.
- [3] Lv, Y., Duan, Y., Kang, W., et al. (2014) Traffic Flow Prediction with Big Data: A Deep Learning Approach. *IEEE Transactions on Intelligent Transportation Systems*, **16**, 865-873. <https://doi.org/10.1109/TITS.2014.2345663>
- [4] Yu, R., Yin, H.T. and Zhu, Z.X. (2018) Spatio-Temporal Graph Convolutional Networks: A Deep Learning Framework for Traffic Forecasting. *27th International Joint Conference on Artificial Intelligence and 23rd European Conference on Artificial Intelligence: IJCAI-ECAI 2018*, Stockholm, 13-19 July 2018, 3634-3640.
- [5] Kang, D., Lv, Y. and Chen, Y. (2017) Short-Term Traffic Flow Prediction with LSTM Recurrent Neural Network. *2017 IEEE 20th International Conference on Intelligent Transportation Systems (ITSC)*, Yokohama, 16-19 October 2017, 1-6. <https://doi.org/10.1109/ITSC.2017.8317872>
- [6] Yang, B., Sun, S., Li, J., Lin, X.X. and Tian, Y. (2019) Traffic Flow Prediction Using LSTM with Feature Enhancement. *Neurocomputing*, **332**, 320-327. <https://doi.org/10.1016/j.neucom.2018.12.016>
- [7] Tian, Y., Zhang, K., Li, J., et al. (2018) LSTM-Based Traffic Flow Prediction with Missing Data. *Neurocomputing*, **318**, 297-305. <https://doi.org/10.1016/j.neucom.2018.08.067>
- [8] Xiao, Y. and Yin, Y. (2019) Hybrid LSTM Neural Network for Short-Term Traffic Flow Prediction. *Information*, **10**, Article No. 105. <https://doi.org/10.3390/info10030105>
- [9] 熊涛. 基于长短时记忆网络的多标签文本分类[D]: [硕士学位论文]. 杭州: 浙江大学, 2017.
- [10] Xie, Y.C. and Zhang, Y.L. (2006) A Wavelet Network Model for Short-Term Traffic Volume Forecasting. *Journal of Intelligent Transportation Systems*, **10**, 141-150. <https://doi.org/10.1080/15472450600798551>
- [11] 王祥雪, 许伦辉. 基于深度学习的短时交通流预测研究[J]. 交通运输系统工程与信息, 2018, 18(1): 81-88.
- [12] 孔文翔, 杨雪驰. 基于动态时空图卷积的多传感器路网交通流预测[J]. 运筹与模糊学, 2023, 13(3): 2339-2354. <https://doi.org/10.12677/ORF.2023.133234>

-
- [13] Chen, C., Wang, Y., Li, L., *et al.* (2012) The Retrieval of Intra-Day Trend and Its Influence on Traffic Prediction. *Transportation Research Part C: Emerging Technologies*, **22**, 103-118. <https://doi.org/10.1016/j.trc.2011.12.006>
- [14] 薛亚鑫. 基于 LSTM 深度神经网络的短期交通流预测[D]: [硕士学位论文]. 北京: 北京交通大学, 2019.
- [15] 张海静. 深度学习框架下的短时交通流预测及数据补全技术研究[D]: [硕士学位论文]. 西安: 长安大学, 2020.
- [16] Schaul, T., Antonoglou, I. and Silver, D. (2013) Unit Tests for Stochastic Optimization. arXiv: 1312.6055.
- [17] Sturm, L.B., Santos, F.J., Ben-Tal, O. and Korshunova, I. (2016) Music Transcription Modelling and Composition Using Deep Learning. arXiv: 1604.08723.
- [18] 张维, 袁绍欣, 陶建军, 周晨蓉, 阿合提·杰恩斯. 基于多元因素的 Bi-LSTM 高速公路交通流预测[J]. 计算机系统应用, 2021, 30(6): 184-190.
- [19] 任艺柯. 基于改进的 LSTM 网络的交通流预测[D]: [硕士学位论文]. 大连: 大连理工大学, 2019.
- [20] 林福海. 基于 LSTM 的短时交通流预测研究[D]: [硕士学位论文]. 西安: 长安大学, 2020.
- [21] Masters, D. and Luschi, C. (2018) Revisiting Small Batch Training for Deep Neural Networks. arXiv: 1804.07612.
- [22] 王苗苗. 基于机器学习的短时交通流预测方法研究[D]: [硕士学位论文]. 西安: 长安大学, 2017.
- [23] 鹿天柱, 钱晓超, 何舒, 等. 一种基于深度学习的时间序列预测方法[J]. 控制与决策, 2021, 36(3): 645-652.
- [24] 张威威, 李瑞敏, 谢中教. 基于深度学习的城市道路旅行时间预测[J]. 系统仿真学报, 2017, 29(10): 2309-2315, 2322.
- [25] 韩小雷, 冯润平, 季静, 等. 基于深度学习的 RC 梁集中塑性铰模型参数研究[J]. 工程力学, 2021, 38(11): 160-169.