

基于改进的长短期记忆神经网络交通流预测*

丁梓琼¹, 汤广李¹, 张波涛¹, 卢自宝^{1,2}

(1. 安徽师范大学 物理与电子信息学院, 安徽 芜湖 241000;

2. 安徽智能机器人信息融合与控制工程实验室, 安徽 芜湖 241000)

摘要: 针对未来时刻交通流量的预测问题, 在考虑历史时刻车流量数据、日期属性、天气、降雨量等多方面影响因素的同时, 提出一种考虑多方面影响因素的长短期记忆神经网络 (LSTM*) 模型。实验表明在对短期车流量进行预测时, LSTM* 模型的准确性优于现有的基线方法; 对长期车流量进行预测时, 基于粒子群算法改进的长短期记忆神经网络 (PSO-LSTM*) 模型的准确性优于 LSTM* 模型。

关键词: 车流量预测; 神经网络; 改进的粒子群算法; 交通流影响因素

中图分类号: TP18

文献标识码: A

DOI: 10.19358/j.issn.2097-1788.2023.08.009

引用格式: 丁梓琼, 汤广李, 张波涛, 等. 基于改进的长短期记忆神经网络交通流预测[J]. 网络安全与数据治理, 2023, 42(8): 52-58.

Traffic flow prediction based on improved long short-term memory neural network

Ding Ziqiong¹, Tang Guangli¹, Zhang Botao¹, Lu Zibao^{1,2}

(1. School of Physics and Electronic Information, Anhui Normal University, Wuhu 241000, China;

2. Anhui Provincial Engineering Laboratory on Information Fusion and Control of Intelligent Robot, Wuhu 241000, China)

Abstract: In order to predict the future traffic flow, a long short-term memory neural network (LSTM*) model is proposed, which takes into account many influencing factors such as traffic flow data, date attribute, weather and rainfall at historical time. The experimental results show that the accuracy of LSTM* model is better than the existing baseline method when predicting short-term traffic flow. When predicting long-term traffic flow, the accuracy of the long short-term memory neural network model based on particle swarm optimization algorithm (PSO-LSTM*) is better than that of LSTM* model.

Key words: flow prediction; neural network; improved PSO; influencing factors of traffic flow

0 引言

随着经济的发展, 城市机动车数量呈爆发式增长, 交通堵塞问题日益严峻。自从 2020 年我国提出“双碳”目标后, 交通领域作为第三大碳排放源, 其节能减排任重道远。交通流量预测是建设智慧城市中必须面对的重大挑战, 精准和及时的交通信息不仅可以为居民提供合理的路径规划, 帮助驾驶员高效出行, 而且可以缓解交通压力, 最大限度利用道路资源^[1]。

关于短期车流量的预测问题, 近半个世纪内有很多研究成果。因为基于统计非参数方法预测的模型大多结构简单, 鲁棒性较差, 不能精确预测, 所以深度学习的

方法慢慢占据了交通预测的主要地位, 主要包括深度神经网络 (Deep Neural Networks, DNN)、传统循环神经网络 (Recurrent Neural Network, RNN)、卷积神经网络 (Convolutional Neural Network, CNN)、长短期记忆神经网络 (Long Short-Term Memory, LSTM) 和注意力模型等。

在已有研究中, 文献 [2] 通过对比不同预测方法, 证明了基于 RNN 的深度学习方法与自回归综合移动平均模型相比, 在预测交通流上更具优势。文献 [3] 对比了多种深度神经网络, 证明基于 LSTM 的交通流量预测模型具有更好的拟合能力。

薛佳瑶等^[4] 利用 CNN 挖掘车流量在空间上的相关性, 利用 LSTM 挖掘车流量在时间上的依赖性, 所提出的模型在车流量预测上拥有较高的精度。史亚星^[5] 在预测

* 基金项目: 国家自然科学基金面上项目 (62071005); 安徽省自然科学基金项目 (2008085MF199)

路口交通流量变化时使用基于自动编码器和 LSTM 网络的模型, 并通过实验证明不同的 LSTM 层数、不同的参数选取方法、不同的迭代次数等都会对模型的准确率产生影响。宋予佳等^[6]对比了 LSTM 和向量自回归模型, 通过实验证明 LSTM 模型在对大量短期车流量预测上表现更为稳定。虽然以上研究证明 LSTM 模型可以对短期交通流进行预测, 但它们没有考虑到其他因素对车流量的影响。

为了进一步提高模型准确率, 文献 [7] 在采用 LSTM 算法的同时, 用多因素分析的思想对数据进行处理, 来预测未来时刻车流量变化。文献 [8] 考虑日期特性对车流量的影响, 将数据集划分为工作日和节假日以对道路拥堵情况做出更为准确的判断。文献 [9] 将降水量纳入交通流量预测模型; 文献 [10] 证明了考虑降雨的情况下, LSTM 模型在捕获时间序列方面也有更好的性能。

进一步, 文献 [11] 发现交通流数据会随时间变化而变化, 具有不确定性。典型的 LSTM 模型不能发现长期依赖关系, 面对长期交通流预测问题时, LSTM 模型精度有所下降。文献 [12] 提出利用粒子群算法 (Particle Swarm Optimization, PSO) 对 LSTM 模型权重进行优化, 从而在不增加模型复杂度的同时最小化预测误差。文献 [13] 以昆明市为例, 证明了 PSO-LSTM 模型是预测交通速度的优势模型, 是挖掘长时间依赖关系的有效模型。

综上所述, 本文根据已有文献确定 LSTM 模型是预测交通流的优势模型, 考虑天气、季节、降水量、节假日和用户行为等其他因素对用户出行时空数据的影响, 提出 LSTM* 模型, 以提高短期车流量预测的精度。进一步, 为了解决 LSTM* (考虑其他影响因素的 LSTM) 模型不能处理长时间依赖关系的问题, 本文引入粒子群算法并对其改进。通过改进的 PSO 优化 LSTM* 模型的输入层权值和学习率, 构建 PSO-LSTM* 预测模型, 并将其性能与 LSTM* 模型进行比较, 获得预测长期车流量的优势模型。

1 理论和方法

1.1 长短期记忆神经网络模型

LSTM 是为解决 RNN 的梯度消失和梯度爆炸而生的。LSTM 中拥有“记忆细胞”, 在处理数据上的时序关系时可以选择性忘记一些不重要的信息, 由此记住更长的序列, 在处理时间序列数据时表现出优异的性能^[14]。因此 LSTM 网络在预测方面具有较好的性能。

如图 1 所示, LSTM 与 RNN 相比, 增加了记忆状态 C 这一元素, 细胞状态通过 C_t 和 C_{t-1} 线路传递, 隐藏状态沿 h_t 和 h_{t-1} 这两个隐藏状态值所在的方向传递, 通过 LSTM 细胞的三个门结构——输入门 (Input Gate, i_t)、遗忘门 (Forget Gate, f_t) 和输出门 (Output Gate, o_t) 进行

交互, 不仅可以保存当前输入, 而且可以保留之前输入的有用信息。

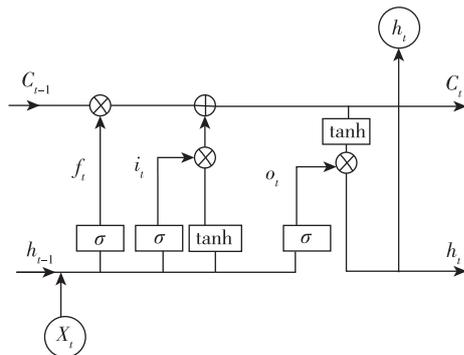


图 1 LSTM 模型

$$f_t = \sigma(\omega_f [h_{t-1}, x_t] + b_f) \quad (1)$$

$$\begin{cases} \tilde{C}_t = \tanh(\omega_g [h_{t-1}, x_t] + b_c) \\ i_t = \sigma(\omega_i [h_{t-1}, x_t] + b_i) \end{cases} \quad (2)$$

$$C_t = f_t \times C_{t-1} + i_t \times \tilde{C}_t \quad (3)$$

$$\begin{cases} o_t = \sigma(\omega_o [h_{t-1}, x_t] + b_o) \\ h_t = o_t \times \tanh(C_t) \end{cases} \quad (4)$$

其过程可以用以上式 (1) ~ (4) 表示, 其中, ω ($\omega_f, \omega_i, \omega_g, \omega_o$) 是各门的权值, 由输入维度与输出维度相乘计算得到, b (b_f, b_c, b_i, b_o) 则是各门的偏移量。 f_t 是一个闸门, 控制信息保留的比例。 \tilde{C}_t 是新的输入带来的信息, 通过 \tanh 激活函数控制信息增减的方向, 从而获得新输入信息的保留部分。式 (3) 是对 C_t 进行更新, 通过将 C_{t-1} 与 f_t 保留的信息相乘、新的信息 \tilde{C}_t 与 i_t 相乘, 再把两部分信息相加, 得到新的状态 C_t 。 C_t 被更新后, 通过 \tanh 函数缩放并与 o_t 相乘, 得到 o_t 的输出内容。

1.2 粒子群算法

粒子群算法是通过模仿鸟群飞行和寻找食物而提出的一种基于群体智能的优化算法^[15]。PSO 算法的原理相对简单, 能够防止网络陷入局部最优, 收敛速度更快, 可调整参数较少且易与其他算法结合^[16], 在处理复杂问题中表现很好, 所以十分适合在预测车流量中使用。

该算法中每个粒子表示一个解, 都具有速度和位置两个属性。速度决定搜索解的快慢, 位置决定移动方向。并且每个粒子都知道自己能找到的最好位置 (pbest) 和整个群体范围内能找到的最好位置 (gbest), 所以, 每个解都朝着 pbest 和 gbest 方向靠近, 更新自己的位置以获取最优解。

$$v_{id}^{t+1} = \omega \cdot v_{id}^t + c_1 \cdot r_1 \cdot (p_{id}^t - x_{id}^t) + c_2 \cdot r_2 \cdot (p_{gd}^t - x_{id}^t) \quad (5)$$

$$x_{id}^{t+1} = x_{id}^t + v_{id}^{t+1} \quad (6)$$

在式(5)、(6)中, t 表示迭代次数; ω 表示惯性权重, 可以调整粒子的搜索距离; c_1 和 c_2 为学习因子($c_1, c_2 > 0$), 表示粒子的自我学习能力和群体学习的影响程度; r_1 和 r_2 为 $[0, 1]$ 范围内的随机数; p_{id}^t 为在第 t 次迭代时第 i 个粒子自己的最优解, p_{gd}^t 为在第 t 次迭代时第 i 个粒子的全局最优解, x_{id}^t 为在第 t 次迭代时第 i 个粒子的位置。

1.3 基于粒子群算法改进 LSTM 模型

LSTM模型在短期交通流预测上具有显著的优势, 但是在预测长期车流量数据时, 精度降低、算法收敛速度变慢、容易陷入局部最优。而 PSO 算法操作简单、具有良好的全局搜索能力和收敛速度。因此, 为了进一步提升 LSTM 对长期交通流预测的精度, 引入改进的 PSO 算法对 LSTM 模型进行优化, 希望获得一个兼具泛化性和鲁棒性的交通流预测通用模型。

PSO 算法把优化后的参数赋予 LSTM 网络, 使其具有自动寻优、长期数据记忆的优势。其中, 可优化的参数包括种群规模、惯性权重、迭代次数、学习速率等。PSO 算法更新群体中每个个体对环境的适应度, 直至找出最适合与 LSTM 网络结合的惯性权重和学习率, 从而使 LSTM 网络获得一组能产生最优预测结果的最优参数值。

PSO 算子在参数寻优时将 LSTM 模型所需的参数定义为粒子群算法中的粒子, 粒子们通过调整和迭代, 自适应地获得最优种群, 找到 PSO-LSTM 模型适用的最优参数。PSO-LSTM 模型既具有 PSO 算法自适应寻找最优的优点, 又具有 LSTM 网络对长期信息表现较好的优点, 在预测交通流量上表现出优越的性能。

2 改进型 PSO-LSTM 预测模型

2.1 改进型粒子群算法

根据车流量数据的特性, 建立 PSO-LSTM 模型。传统的 PSO 算法虽然有较强的鲁棒性、参数少且收敛速度快, 但是仍存在一些问题。所以本文以隐藏层神经元数量、初始学习速率、学习速率下降因子和学习速率下降周期为优化目标, 对算法进行改进。

首先对 PSO 算法中自适应惯性权重 ω 进行改进。为避免迭代后期陷入局部最优, 采用非线性动态的惯性权重, 如式(7)所示:

$$\omega = (\omega_{\max} - \omega_{\min}) \times \left(\frac{\omega_{\min}}{\omega_{\max}} \right)^{\sqrt{\frac{t}{item_{\max}}}} \quad (7)$$

其中, ω_{\max} 是最大惯性权重, ω_{\min} 是最小惯性权重。 t 是当前迭代数, $item_{\max}$ 是最大迭代数。非线性动态的惯性权重在更新时沿着非线性曲线下降, 减少了获得次优解的概率。

其次是对学习速率的改进。为了提高粒子的搜索速度, 提升全局搜索能力, 引入正弦函数以改进学习因子 c_1 和 c_2 ($c_1, c_2 > 0$)。

$$\begin{cases} c_1 = \sqrt{\sin\left(\frac{\pi}{2} \times \frac{t}{flow_max}\right)} \\ c_2 = \sqrt{1 - \sin\left(\frac{\pi}{2} \times \frac{t}{flow_max}\right)} \end{cases} \quad (8)$$

式(8)中学习因子 c_1 由大变小, c_2 由小变大, 改变了粒子向最优解搜索的步长。随着迭代的进行, 粒子在后期搜索得更加细致, 精度更高。

$$fit = \frac{1}{T} \sum_{t=1}^T (flow'(t) - flow(t)) \quad (9)$$

如式(9)所示, 引入了粒子的适应度值。其中 T 是时间样本的规模, $flow'(t)$ 是交通流量的预测值, $flow(t)$ 是交通流量的真实值。

改进后的 PSO 算法容易实现、精度高、收敛速度快, 能更大空间、更迅速地寻找预测的最佳值, 从而对 LSTM 网络的参数进行优化, 得到改进型 PSO-LSTM 模型, 为预测长期车流量提供了理论模型。

2.2 改进型 PSO-LSTM 预测模型

尽管 LSTM 网络可以在一定程度上缓解梯度问题, 在处理时间序列数据上有显著优势, 但是面对更长序列的信息时还是会显得棘手。长期预测的 LSTM 网络很深, 计算量大, 参数难以确定, 不同参数的选取对结果影响巨大。针对这些问题, 本文引入改进的 PSO 算法对 LSTM 优化, 得到改进型 PSO-LSTM 神经网络模型。

改进型 PSO 算法优化 LSTM 模型的流程图如图 2 所示。

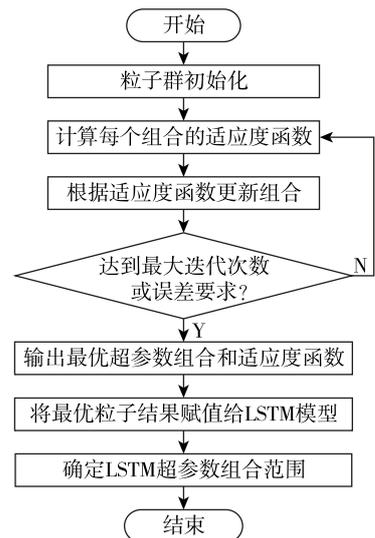


图 2 改进型 PSO 优化 LSTM 模型流程图

改进型 PSO 算法优化了 LSTM 模型初始连接权重和超参数获取不准确的问题。计算每个组合的适应度值, 并由此得出初始个体和全局极值, 然后根据公式更新粒子位置和速度以获得最优粒子。判断是否满足终止条件, 若满足, 则输出最优粒子赋值给 LSTM 网络; 否则, 重新根据适应度更新组合, 直至得到最优解。

基于对算法的改进, 本文将按照如下步骤完成对未来时间车流量的预测:

(1) 数据处理。输入数据的维数不同, 预测结果会有所差异, 本文在历史车流量数据的基础上, 考虑了天气、节假日、降水量等影响因素, 因此需要对数据样本进行归一化处理, 并按比例缩放数据, 将归一化后的实验数据按 70% 和 30% 划分训练集和测试集。

(2) 利用改进的粒子群算法对 LSTM* (LSTM* 模型是考虑车流量影响因素的 LSTM 模型) 网络的超参数进行优化。

(3) 利用优化后的 PSO-LSTM* 建立预测模型, 并训练网络, 获得车流量数据。

(4) 选取评价指标, 对模型预测效果进行评估。本文选取均方误差 (Mean Squared Error, MSE)、平均绝对误差 (Mean Absolute Error, MAE)、均方根误差 (Root Mean Squared Error, RMSE)、平均绝对百分比误差 (Mean Absolute Percentage Error, MAPE) 作为评价参数。

$$MSE = \frac{1}{T} \sum_{t=1}^T (\text{flow}'(t) - \text{flow}(t))^2 \quad (10)$$

$$MAE = \frac{1}{T} \sum_{t=1}^T |\text{flow}'(t) - \text{flow}(t)| \quad (11)$$

$$RMSE = \sqrt{\frac{1}{T} \sum_{t=1}^T (\text{flow}'(t) - \text{flow}(t))^2} \quad (12)$$

$$MAPE = \frac{1}{T} \sum_{t=1}^T \frac{|\text{flow}'(t) - \text{flow}(t)|}{\text{flow}(t)} \quad (13)$$

MSE 一般用来检测交通流量的预测值和真实值之间的偏差, 但由于值的平方会增加误差值, 因此训练模型时易受异常值影响; MAE 在作为损失函数时, 对于异常值的鲁棒性高于 MSE; RMSE 本质上是对 MSE 做了一个开根号, 使评估值的量纲和原量纲保持一致; MAPE 的取值范围为 $[0, +\infty)$, 其值为 0% 时表示完美模型, 大于 100% 则表示劣势模型。

本文的研究思路以及交通流预测流程如图 3 所示。

3 交通流预测算例分析

交通信息具有周期性的特点, 但相关参数也会受到实际路况、天气、人的因素的影响, 呈现出非线性的特征。除此之外, 预测时刻的上一时间段也会对下一时刻的交通流量预测产生影响。例如 11: 10 ~ 11: 20 的车流

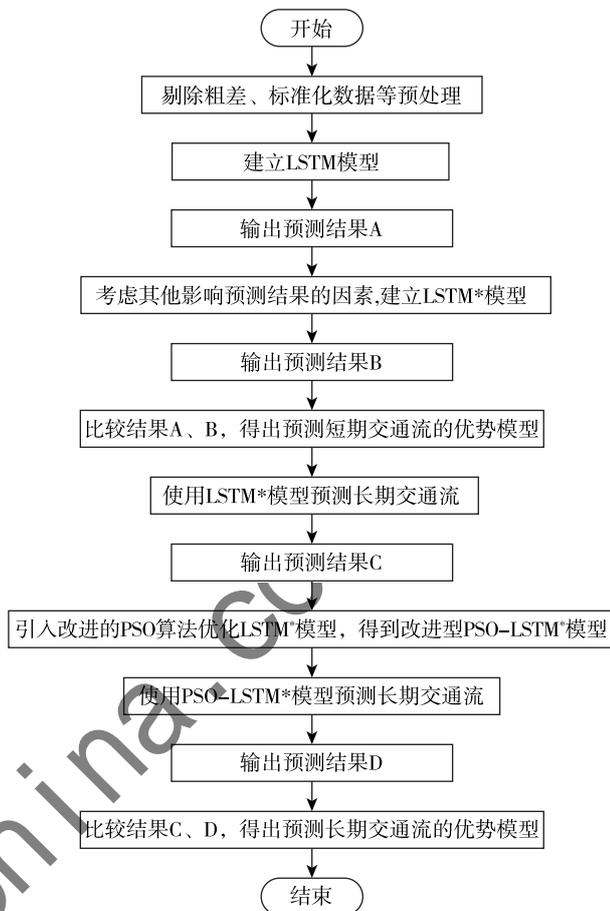


图 3 交通流预测流程图

量会影响到 11: 20 ~ 11: 30 之间的交通流量, 因此在预测交通流量时也要将上一时刻的交通信息纳入考虑范围。同时, 在历史交通流量中与预测时间相同时刻的车流量也要作为周期信息进行考虑, 并且要考虑到一个较长周期。

3.1 实验环境设置和系统描述

实验在一台采用 Intel i5 1.60 GHz 处理器、32 GB 内存和 NVIDIA GMX150 GPU 的笔记本电脑上进行。已有文献证明 LSTM 模型在交通流预测上表现良好, 故本文通过实验对比 LSTM 模型和 LSTM* 模型的性能, 验证提出的 LSTM* 模型的优越性。

实验数据采用加利福尼亚高速数据集, 对于路口的交通流量每 5 min 进行一次预测。为了保证数据集的完整性, 缺失或无效的数据使用时间顺序上相邻的数据来补齐。将原始数据集分为两个子集: 取 2016 年 5 月份的数据作为训练集, 取 2016 年 6 月份的数据作为测试集, 对未来时刻的电动汽车用户时空分布进行预测。

$$\text{flow}'(t) = \text{flow}(t+1) - \text{flow}(t) \quad (14)$$

式 (14) 所示是对下一时刻电动汽车用户时空数据

进行预测，其中 $flow'(t)$ 是交通流量的预测值， $flow(t)$ 和 $flow(t+1)$ 对应的是 t 时刻和 $t+1$ 时刻交通流量的真实数据。

为了更好地拟合时间序列中包含的周期性，避免数据丢失和受影响，需要对交通流数据进行平滑和归一化，如式 (15) 所示：

$$y = \frac{flow(t) - flow(t)_{min}}{flow(t)_{max} - flow(t)_{min}} \quad (15)$$

其中， $flow(t)_{max}$ 表示所测阶段最大车流量数据， $flow(t)_{min}$ 表示所有数据中最小车流量数据， y 为车流量数据 $flow(t)$ 归一化后的结果。

3.2 确定 LSTM* 网络预测交通流

已有文献证明基于 LSTM 的深度学习方法在预测交通流上更具有优越性。故采用 LSTM 模型对城市某路口一天 24 h 的交通流量进行预测和对比，结果如图 4 所示，其中横坐标表示时间，纵坐标为每 5 min 内经过的车辆数（下文图 5 ~ 图 7 中横纵坐标含义与此相同）。

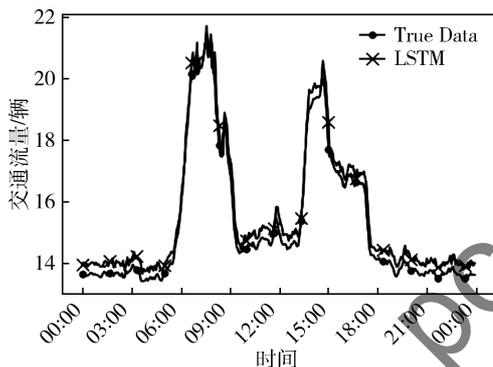


图 4 基于 LSTM 的预测结果与真实数据比较

从图 4 可以观察到，在一天内，从早上 6:00 左右车流量开始缓慢增加，7:00 左右达到最高峰，8:00 左右开始减少；下午 14:00 左右车流量又开始增加。根据预测图可以看出电动汽车用户的出行是有规律的，一天会出现早高峰和午高峰。LSTM 模型对短期车流量预测的 MSE、MAE、RMSE 和 MAPE 分别为 0.306、0.321、0.553、2.00%。

此外，除了历史时刻的交通流数据会影响对未来时刻流量的预测外，天气、节假日、周期性、用户行为等因素也是影响用户出行数据的重要因素。故在考虑多种因素影响下，对用户的出行数据进行分析，得到考虑多种因素的长短期记忆神经网络模型（LSTM*）。基于 LSTM* 的预测结果及其真实数据的比较如图 5 所示。

由图 5 可见，LSTM* 模型的车流量预测曲线与真实数据基本重合，MSE、MAE、RMSE 和 MAPE 分别为

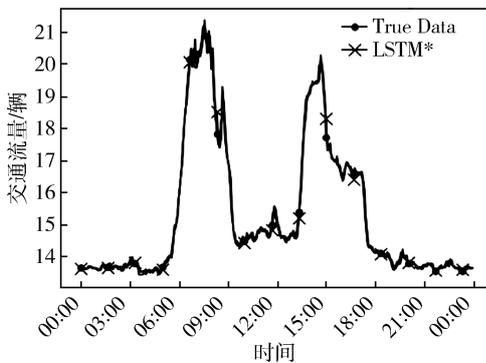


图 5 基于 LSTM* 的预测结果与真实数据比较

0.055、0.108、0.234、0.757%。可以看出，LSTM* 模型在四种误差评价标准上都比传统的 LSTM 模型低，证明了加入天气、节假日、用户特征等影响因素，可以提升模型的预测精度。

3.3 确定改进型 PSO-LSTM* 预测模型

实验发现，当对较远时间，如对 2016 年 11 月某一天车流量进行预测时，预测精确度会大幅度降低。而且每一个 LSTM* 网络都很深，计算量大，耗时长。对此，本文引入改进的 PSO 算法对 LSTM* 优化，得到改进型 PSO-LSTM* 神经网络模型。

图 6 和图 7 分别是用 LSTM* 模型和 PSO-LSTM* 模型对 2016 年 11 月（半年后）某一天车流量预测的结果。

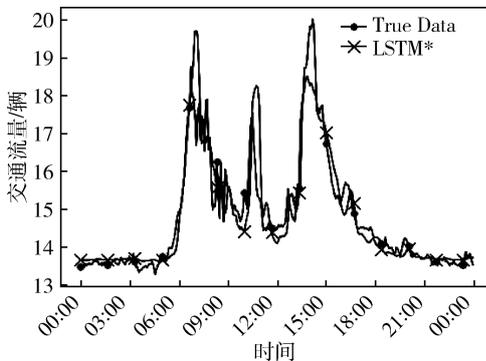


图 6 LSTM* 模型对半年后某天车流量预测

由图 6 可以发现，LSTM* 模型对长时间范围内的预测值与真实值间的拟合程度不是很好，不能精确地预测交通流数据。与之相比，在图 7 中，PSO-LSTM* 模型对长期车流量数据的预测拟合程度较好，能够更好地拟合长时间范围内车流量的变化趋势。证明 PSO-LSTM* 模型对长期信息的抓取能力更好，相较于 LSTM* 模型有所改善。

通过 MATLAB 仿真实验对相同的数据进行分析，分别获得了 LSTM* 模型（如图 8 所示）和 PSO-LSTM* 模型（如图 9 所示）的收敛曲线图。

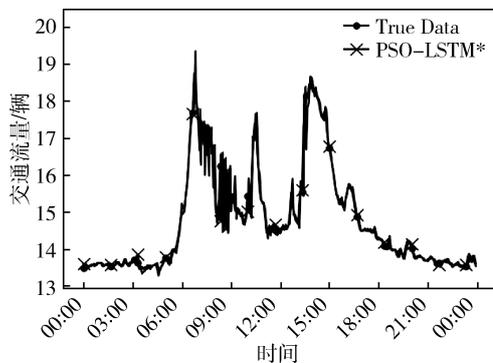


图7 PSO-LSTM*模型对半年后某天车流量预测

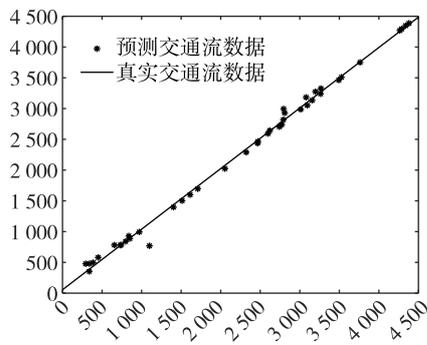


图10 LSTM*模型所有样本拟合图

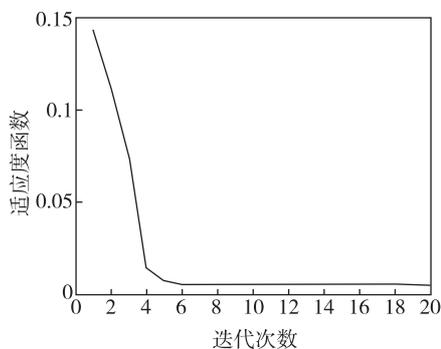


图8 LSTM*模型的收敛曲线图

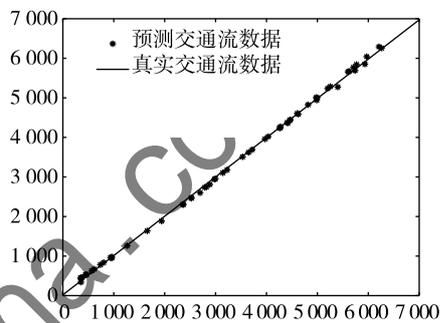


图11 PSO-LSTM*模型所有样本拟合图

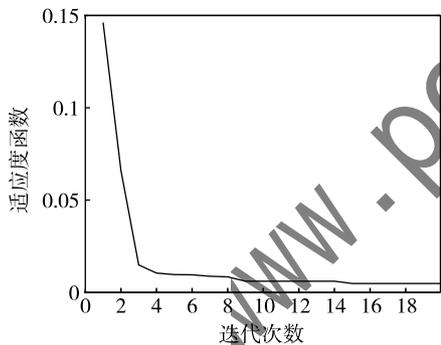


图9 PSO-LSTM*模型的收敛曲线图

从图8可以看出LSTM*模型的曲线在第四代开始收敛,而从图9可以看出PSO-LSTM*模型在第四代之前就收敛。故PSO-LSTM*模型具有更好的收敛特性。

图10、图11分别为LSTM*模型和PSO-LSTM*模型对半年后某天数据预测的拟合图。可以看出两种模型的数据都基本拟合,达到了不错的预测结果,但通过对比可以看出,PSO-LSTM*模型对于长期车流量预测具有优越性。

为了评价LSTM*和PSO-LSTM*模型对于长期车流量数据的预测结果,本文分别计算了两种模型的评价指标,二者的预测结果对比如表1所示。

表1 LSTM*和PSO-LSTM*模型预测长期车流量的精度对比

| 模型 | MSE/s | MAE/s | RMSE/s | MAPE/% |
|-----------|-------|-------|--------|--------|
| LSTM* | 0.515 | 0.400 | 0.717 | 2.396 |
| PSO-LSTM* | 0.322 | 0.291 | 0.276 | 2.106 |

从表1可以看出,PSO-LSTM*模型的各个评价指标相比于LSTM*模型都有所下降,表明PSO-LSTM*模型是一种有效的长期交通流预测模型。

4 结论

本文提出了考虑日期属性、天气、降雨量等多方面影响因素的LSTM*模型对短期交通流量进行预测,实验表明LSTM*模型在短期交通流预测方面相较于传统的LSTM模型有更好的效果。但是LSTM*模型在预测更长序列的信息时存在精度降低的问题,故引入改进的PSO-LSTM*神经网络模型对长期序列信息进行预测。通过同一个开源数据集的案例,证明了改进的PSO-LSTM*模型在预测长期交通流方面具有显著的竞争力,即使对很长一段时间后的车流量进行预测,也可以得到较为准确的预测结果。

参考文献

- [1] DUAN P B, MAO G Q, LIANG W F, et al. A unified spatio-temporal model for short-term traffic flow prediction [J]. IEEE

- Transactions on Intelligent Transportation Systems, 2018, 20 (9): 3212–3223.
- [2] CHU Q, LI G, ZHOU R, et al. Traffic flow prediction model based on LSTM with finnish dataset [C]// 2021 6th International Conference on Intelligent Computing and Signal Processing (IC-SP), 2021, China (Xi'an): 389–392.
- [3] HOU C H. Prediction method of oil production of new wells in oilfield based on long-term and short-term memory neural network [J]. Oil and Gas Geology and Recovery Factor, 2019, 26 (3): 105–110.
- [4] 薛佳瑶, 陈海勇, 周刚. 基于卷积循环神经网络的城市区域车流量预测模型 [J]. 信息工程大学学报, 2019, 20 (2): 236–241.
- [5] 史亚星. 基于深度学习的车流量预测方法研究 [J]. 计算机与数字工程, 2019, 47 (5): 1160–1163.
- [6] 宋予佳, 张健, 邢珺. 基于长短期记忆网络构建短时车流预测模型 [J]. 公路, 2019, 64 (7): 224–229.
- [7] 王钰, 郭兰英, 程鑫. 结合深度学习的短时车流量预测优化方法 [J]. 计算机工程与应用, 2020, 56 (16): 211–217.
- [8] 魏健, 赵红涛, 加鹤萍. 基于改进模型的短期车流量预测 [J]. 科技创新与应用, 2021, 11 (12): 25–27.
- [9] PENG H, BOBADE S U, COTTERELL M E, et al. Forecasting traffic flow: short term, long term, and when it rains [C]//International Conference on Big Data, 2018: 57–71.
- [10] JIA Y H, WU J P, XU M. Traffic flow prediction with rainfall impact using a deep learning method [J]. Journal of Advanced Transportation, 2017 (2017): 1–10. DOI: 10.1155/2017/6575947.
- [11] FANG W, ZHUO W, YAN J, et al. Attention meets long short-term memory: a deep learning network for traffic flow forecasting [J]. Physica A: Statistical Mechanics and its Applications, 2022, 587. DOI: 10.1016/j.physa.2021.126485.
- [12] GUNDU V, SIMON S P. PSO-LSTM for short term forecast of heterogeneous time series electricity price signals [J]. Journal of Ambient Intelligence and Humanized Computing, 2021, 12 (2): 2375–2385.
- [13] MAO Y, QIN G, NI P, et al. Analysis of road traffic speed in Kunming plateau mountains: a fusion PSO–LSTM algorithm [J]. International Journal of Urban Sciences, 2021 (7): 1–21.
- [14] 戴晓峰, 戈艺澄. 基于深度学习的节假日高速公路交通流预测方法 [J]. 系统仿真学报, 2020, 32 (6): 1164–1171.
- [15] FU Y, YANG A G, YAO Z A, et al. Inversion of rayleigh wave dispersion curves via long short-term memory combined with particle swarm optimization [J]. Computational Intelligence and Neuroscience, 2022. DOI: 10.1155/2022/2640929.
- [16] SONG G, ZHANG Y F, BAO F X, et al. Stock forecasting model based on particle swarm optimization LSTM [J]. Journal of Beijing University of Aeronautics and Astronautics, 2019, 45 (12): 2533–2542.

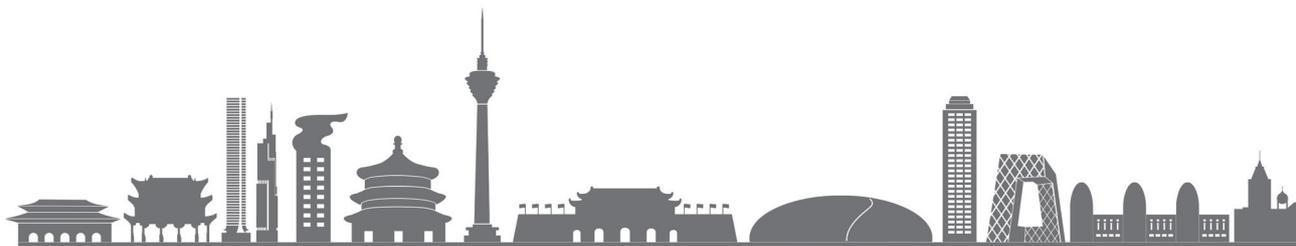
(收稿日期: 2023–06–01)

作者简介:

丁梓琼 (1999–), 女, 硕士研究生, 主要研究方向: 智能交通预测。

汤广李 (2000–), 男, 硕士研究生, 主要研究方向: 电池余能预测。

卢自宝 (1985–), 通信作者, 男, 博士, 副教授, 硕士生导师, 主要研究方向: 微电网控制技术。E-mail: luzibao@163.com。



版权声明

凡《网络安全与数据治理》录用的文章，如作者没有关于汇编权、翻译权、印刷权及电子版的复制权、信息网络传播权与发行权等版权的特殊声明，即视作该文章署名作者同意将该文章的汇编权、翻译权、印刷权及电子版的复制权、信息网络传播权与发行权授予本刊，本刊有权授权本刊合作数据库、合作媒体等合作伙伴使用。同时，本刊支付的稿酬已包含上述使用的费用，特此声明。

《网络安全与数据治理》编辑部

www.pcachina.com