

DOI:10.11918/j.issn.0367-6234.201806085

GA-LSTM 模型在高速公路交通流预测中的应用

温惠英,张东冉,陆思园

(华南理工大学 土木与交通学院, 广州 510641)

摘 要: 为提高高速公路交通流预测精度,为高速公路管理部门动态控制诱导提供有效支撑,以实时交通流预测误差最小为目标,通过对高速公路数据的清洗和归一处理,分为 4 个不同时间间隔的数据集,按比例划分为训练数据集和测试数据集. 采用遗传算法(GA)对数据时间窗步长、长短期记忆(LSTM)神经网络的隐藏层数、训练次数、dropout 进行优化调参,分析 4 种参数对模型寻优影响,GA-LSTM 模型在 keras 中以 Tensorflow 为后台进行训练拟合. 结果表明:GA-LSTM 模型寻优速度快,同传统预测算法中的 SVM、KNN、BP 和 LSTM 神经网络相比较,GA-LSTM 对数据预测均方误差和均方根误差最小,模型表现出更好的预测性能.

关键词: 交通流预测;长短期记忆;循环神经网络;深度学习;遗传算法

中图分类号: U491 **文献标志码:** A **文章编号:** 0367-6234(2019)09-0081-07

Application of GA-LSTM model in highway traffic flow prediction

WEN Huiying, ZHANG Dongran, LU Siyuan

(School of Civil and Transportation, South China University of Technology, Guangzhou 510641, China)

Abstract: To improve the accuracy of highway traffic flow prediction and provide effective support for the dynamic control induction of highway management departments, this paper takes the minimum prediction error of real-time traffic flow as the goal and divides the highway data into four different time intervals by cleaning and normalizing. The data set was divided into training data sets and test data sets. Genetic algorithm (GA) was used to optimize the parameters of data time window step as well as long-term and short-term memory (LSTM) neural network of hidden layer, training times, and dropout, and analyze the influence of four parameters on model optimization. In keras, GA-LSTM model utilized Tensorflow as a background for training and fitting. Experiments show that the GA-LSTM model had a fast search speed. Compared with the SVM, KNN, BP, and LSTM neural networks in the traditional prediction algorithm, the GA-LSTM had the minimum mean square error and root mean square error for data prediction, and the model exhibited better predictive performance.

Keywords: traffic flow prediction; long-term and short-term memory; recurrent neural network; deep learning; genetic algorithm

短时交通流的预测是交通管理部门采取交通控制和诱导措施的重要依据. 通过对短时交通流的预测,可以提前调整交通管理控制手段,提高交通运行效率. 为了更好反应道路交通运行状态,交通流的短期实时预测是智能交通领域研究重点. 交通流数据是时间序列数据,随着机器学习及深度学习的推进,对交通流的预测方法也在不断改善.

早期交通流的预测是基于传统统计学理论. 对于统计模型,如将时间序列模型应用于交通流预测领域^[1]. 采用卡尔曼滤波的对交通量预测,引入线性系统状态方程对整体状态进行最优估计^[2]. 马尔科夫预测模型利用时间序列转移概率预测未来时间

序列的状态,但不适用于长期预测^[3].

在机器学习预测方法中,文献[4]利用模糊神经网络建立了每个路段及整个路网的交通流预测模型,采用模拟测试数据进行验证;文献[5]采用动态小波神经网络进行实际交通流预测,文献[6]提出采用 SVM 回归模型的交通状态实时预测. 文献[7]提出了基于时间维度、上游路段、下游路段和时空参数 4 种状态向量的 K 近邻模型,研究各参数对预测精度的影响. 文献[8]提出采用深度信念网络对数据先进行特征学习提取,再采用顶层 SVM 模型进行预测. 文献[9]提出了采用分布式梯度优化决策树筛选特征向量建立 DUTP-GBDT 模型.

当前深度学习方法广泛应用在时间序列数据预测中. 文献[10]通过对循环神经网络精细化调参实现了对城市快速路车速的实时预测. 文献[11]采用多网格搜索优化参数选取的 LSTM 模型对飞机故障

收稿日期: 2018-06-12
基金项目: 国家自然科学基金(51378222,51578247)
作者简介: 温惠英(1965—),女,教授;博士生导师
通信作者: 张东冉,zhang.dr@mail.scut.edu.cn

事件序列进行预测. 文献[12]采用 LSTM 和 ARMA 对惯性器件的随机误差进行了误差滤波拟合.

目前对于 LSTM 参数选取研究多是采用遍历多网格搜索算法、控制变量精细调参, 计算开销大. 针对高速公路交通流时间序列数据, 提出一种 GA-LSTM 循环神经网络的交通流预测方法. 采用遗传算法优化 LSTM 网络参数, 以预测误差最小为目标, 采用广深高速公路交通数据展开实验, 同其他时间序列预测模型进行对比, 结果显示 GA-LSTM 模型在交通流短时预测中适应性更好, 具有良好的预测性能.

1 长短期记忆模型介绍

循环神经网络 (recurrent neural network, RNN) 是在网络结构中以单元结构连接为有向图的神经网络^[13], RNN 神经网络可以存储神经元当前时刻的输入与之前时刻的输出关系^[14]. RNN 神经网络近年也被用在非线性时间序列数据的预测中^[15]. 图 1 为简单的 RNN 的典型链式结构.




图 1 RNN 典型链式结构

Fig.1 RNN typical chain structure

对于给定的输入序列 $x_t (i = 1, 2, \dots, N)$, 隐藏层序列模块 h_t 为

$$h_t = f_a(W_{xh}x_t + W_{hh}h_{t-1} + b_h). \quad (1)$$

其中: W_{xh}, W_{hh} 分别表示从输入 x 到隐藏状态 h 、隐藏状态 h 到自身的连接权值, 下标 t 为时间; b_h 为偏置矢量; f_a 为隐藏层的激活函数.

输出序列 y_t 为

$$y_t = f_b(W_{ho}h_t + b_y). \quad (2)$$

其中: W_{ho} 表示从隐藏状态到输出 y 的连接权值, b_y 为偏置矢量, f_b 为输出层的激活函数.

RNN 实现长期记忆计算的功能与前 n 次计算相关, 由于功能有限, RNN 的记忆能力很弱, 计算量加大导致模型训练时间增加, 并产生梯度消失和梯度爆炸问题. 基于对 RNN 神经网络进行改进, 通过在链式结构中引入 LSTM 模块, LSTM 具有复杂的动力学结构, 可以从输入数据中学习长期计算记忆信息^[16].

如图 2 所示, 在 LSTM 的计算单元中有输入门 i_t 、遗忘门 f_t 、输出门 o_t , 单元状态 c_t 、隐藏状态 h_t , 采用激活函数和逐点乘法运算形成门限, 使 LSTM 单元具有计算长距离历史信息的能力.




图 2 LSTM 计算单元内部结构

Fig.2 Internal structure of the LSTM calculation unit

输入门 i_t 决定需要更新的单元, 表示为

$$i_t = \sigma(W_{xi}x_t + W_{hi}h_{t-1} + W_{ci}c_{t-1} + b_i). \quad (3)$$

其中 W 和 b 分别为权值矩阵和偏移量.

遗忘门 f_t 决定需要保留的历史信息, 表示为

$$f_t = \sigma(W_{xf}x_t + W_{hf}h_{t-1} + W_{cf}c_{t-1} + b_f). \quad (4)$$

进而对模型的状态进行更新, 有

$$c_t = f_t c_{t-1} + i_t \tanh(W_{xc}x_t + W_{hc}h_{t-1} + b_c). \quad (5)$$

输出门 o_t 在 LSTM 单元输出计算结果为

$$o_t = \sigma(W_{xo}x_t + W_{ho}h_{t-1} + W_{co}c_t + b_o). \quad (6)$$

其中 σ 为激活函数.

获得隐藏状态信息为

$$h_t = o_t \tanh(c_t). \quad (7)$$

其中 $\tanh$ 为激活函数.

LSTM 的训练时, 首先按照前向传播计算 LSTM 单元的输出值, 计算 LSTM 单元的误差值并反向传播; 根据误差值, 计算权值梯度; 采用优化算法进行梯度下降, 实时递归^[17]并更新权值.

神经网络优化算法包括随机梯度下降 (stochastic gradient descent, SGD)、将梯度积累改造成指数加权移动平均 RMSprop 算法、自适应学习速率的 AdaGrad 算法、适应性时刻的 Adam 算法等. Adam 算法在迭代过程中采用平稳梯度代替了原始随机梯度, 并引入纠偏机制, 使学习速率保持在确定范围, 在深度学习中使用较多^[18].

大规模神经网络具有耗时长和容易过拟合的缺陷^[19]. 通常采用集成方法训练多个模型进行集成学习, 提高模型泛化能力. 文献[20]提出 dropout 方法在模型训练过程中, 暂时以概率 P 随机丢弃隐藏层神经元, 则每个批次数据都在训练不同的网络, 得出精度较高的预测结果.

2 基于 GA-LSTM 的交通流预测模型

2.1 模型预测流程

建立 GA-LSTM 交通流预测模型, 整体框架如图 3 所示, 包括数据处理模块、参数优化模块、网络训练模块、网络预测模块. 采用遗传算法对数据时间

窗步长 (look_back, lb)、LSTM 模型中的网络隐藏层 (lstm_nets, ls)、训练次数 (epochs, ep)、dropout (dp) 4 个参数在搜索空间优化, 确定最佳参数组合. 将交通流时间序列作为输入数据, 将下一阶段交通流的

预测值作为输出矩阵, 通过长短期记忆循环神经网络迭代自适应调整模型权重, 拟合形成 GA-LSTM 模型. 将测试数据输入进行预测, 将预测结果与实际测试数据进行误差对比并输出.




图 3 基于 GA-LSTM 的交通流预测框架

Fig.3 Traffic flow prediction framework based on GA-LSTM

2.2 交通流数据处理

交通流数据是非平稳随机序列, 本文构建的 GA-LSTM 模型对数据导入后进行归一化, 将特征映射到 (0,1) 区间里, 将交通量转化为有监督学习模式, 将上一阶段的数据作为当前阶段数据的输入^[21].

在数据处理模块中, 读取获得原始交通流时间序列 $F_D = \{f_{d1}, f_{d2}, \dots, f_{dn}\}$, 对数据归一化:

$$d_i = \frac{f_{di} - \min_{1 \leq j \leq n} \{f_{dj}\}}{\max_{1 \leq j \leq n} \{f_{dj}\} - \min_{1 \leq j \leq n} \{f_{dj}\}}. \tag{8}$$

获得新数据序列 $D = \{d_1, d_2, \dots, d_n\}$, 分为训练数据集和测试数据集分别为 $d_{tr} = \{d_1, d_2, \dots, d_m\}$ 和 $d_{te} = \{d_{m+1}, d_{m+2}, \dots, d_n\}$.

对数据进行时间窗步长处理, 设定时间窗步长 lb 设定为 S, 则处理后数据输入为

$$X = \{X_1, X_2, \dots, X_S\}. \tag{9}$$

$$X_i = \{d_i, d_{i+1}, \dots, d_{m-S+p-1}\}, 1 \leq i \leq S; i, S \in N. \tag{10}$$

实际对比数据为

$$Y = \{Y_1, Y_2, \dots, Y_S\}, \tag{11}$$

$$Y_i = \{d_{i+1}, d_{i+2}, \dots, d_{m-S+p}\}. \tag{12}$$

2.3 遗传算法优化模型参数

遗传算法是基于生物进化理论发展形成的启发式搜索算法, 将目标问题转化为生物进化过程, 通过交叉、变异、复制等操作产生新的种群, 淘汰适应度低的解. 现将问题通过二进制编码形成基因和个体, 组成种群. 通过对种群个体适应度通过轮盘赌算法进行选择, 对个体进行交叉、变异, 形成新的种群, 迭代运算至满足目标问题.

LSTM 模型的预测精度同参数取值密切相关, 需要对 ls、lb、ep、dp 在搜索空间内寻优. 多网格搜索算法和精细调参的方式, 本质都是对搜索空间的遍历寻优. 本文采用遗传算法对 LSTM 涉及到的参数进行调整优化, 获取搜索空间的最优解, 形成复合 GA-LSTM 模型. 主要流程步骤为: 1) 种群初始化并解码. 2) 将 LSTM 神经网络的均方误差作为适应度函数. 3) 将解的个体进行选择交叉变异操作. 4) 若适应度函数目标值达到最优值, 则进行下一步; 否则返回第 3 步. 5) 步获得适应度目标值和最佳参数. 6) 计算基于最佳参数的预测均方误差. 7) 终止条件判断. 若种群迭代次数满足, 则停止计算, 此时 LSTM 网络全局最优参数组合 [ls, lb, ep, dp]; 否则返回第 6 步.

2.4 网络训练

将处理好的测试数据 X 输入到 GA-LSTM 隐藏层中, GA-LSTM 单元受前一阶段训练模型影响, 输出预测数据为

$$P = \{P_1, P_2, \dots, P_S\}, \quad (13)$$

$$P_p = \text{GA-LSTM}_{\text{cal}}\{X_p, C_{p-1}, H_{p-1}\}. \quad (14)$$

式中 C_{p-1} 、 H_{p-1} 分别为前一 GA-LSTM 单元的状态和输出, $\text{GA-LSTM}_{\text{cal}}$ 为循环神经网络的计算过程. 网络训练损失函数采用均方误差, 即

$$L = \sum_{i=1}^{S(m-S)} (p_i - y_i)^2 / [S(m-S)]. \quad (15)$$

在 GA-LSTM 模型中采用遗传算法选定好的参数, 优化目标为损失函数最小化, 采用 Adam 优化算法对网络迭代更新调整模型权重、降低预测误差.

2.5 网络预测

采用训练好 GA-LSTM 模型, 对输入预测数据进行预测.

在训练集中实际数据 Y 的最后一行数, 即

$$Y_f = \{d_{m-S+1}, d_{m-S+2}, \dots, d_m\}. \quad (16)$$

采用 GA-LSTM 模型对 Y_f 进行预测, 输出结果为

$$P_f = \text{GA-LSTM}(Y_f) = \{P_{m-S+2}, P_{m-S+3}, \dots, P_{m+1}\}. \quad (17)$$

GA-LSTM 网络在 $m+1$ 时刻预测数值为 P_{m+1} , 将 Y_f 的数据剔除第 1 个, 增加 P_{m+1} , 组合形成新的数据为

$$Y_{f+1} = \{d_{m-S+2}, d_{m-S+3}, \dots, P_{m+1}\}. \quad (18)$$

并将 Y_{f+1} 输入到 GA-LSTM, 以此方法得到 P_{m+2} , 进行迭代, 从而获取预测的时间序列为

$$P_{te} = \{P_{m+1}, P_{m+2}, \dots, P_n\}. \quad (19)$$

将预测结果 P_{te} 与真实数据 d_{te} 进行还原对比, 求出模型预测精度.

3 实验评估指标与环境

3.1 实验对比模型

支持向量机回归. SVM 算法在分类和回归处理中均有应用. 在处理回归问题时让所有样本点逼近超平面, 求出总偏差最小的超平面^[22]. 本文采用高斯径向基函数 (RBF), 将交通量映射到高维空间 (Hilbert 空间) 后执行线性回归运算.

最近邻算法回归. KNN 采用 K 个邻近数据来代表样本. 通过找出样本的 K 个欧氏距离邻近数据, 将这些数据的属性的平均值赋给该样本, 得到该样本的属性^[23]. 将不同距离的邻近数据对该样本产生的影响赋给不同权重^[7]. 结合网格搜索和交叉验证, 提高预测精度, 实现近似线性可分.

BP 神经网络回归. 神经网络是由一组相互连

接的神经元组成, 彼此连接有权重控制. 数据结构对特征变量比较适应度灵活, 可以设置多个非线性的隐藏层, 适合对复杂非线性数据进行预测^[24]. 在回归预测中采用非线性函数输出, 采用 Adam 和反向传播算法进行训练. 在训练数据量大的情况下预测效果好.

传统 LSTM 神经网络回归. LSTM 神经网络采用门限结构对循环神经网络进行改造, 解决了循环神经网络在较长时间序列回归预测中的梯度消失和梯度爆炸问题. 文献[10]在研究车速预测时选用 dropout 为 0.2, 文献[19]研究选用时间窗步长、网络隐藏层进行组合研究. 综合上述研究, 本文选定对比 LSTM 模型的时间窗步长为 3, 网络隐藏层数为 50, epochs 为 200, dropout 为 0.2.

3.2 实验评估指标

为了定量分析 GA-LSTM 模型性能, 采用均方误差 (E_{MS}) 和均方根误差 (E_{RMS}) 作为评估指标, 并与 SVM、KNN、BP、LSTM 算法进行对比. E_{MS} 和 E_{RMS} 的值越小, 代表预测精度越高. 均方误差和均方根误差分别为

$$E_{\text{MS}} = \frac{1}{N} \sum_{i=1}^N (Y_i - Y_i^*)^2, \quad (20)$$

$$E_{\text{RMS}} = \sqrt{\frac{1}{N} \sum_{i=1}^N (Y_i - Y_i^*)^2}. \quad (21)$$

其中: N 为数据集个数, Y_i 为真实数据集, Y_i^* 为预测数据集.

3.3 实现平台

实验所使用的计算机配置和软件环境如下: 处理器为 Intel i5-6500, 内存为 8.0GB; 系统是 Windows10 (64 位); 程序语言版本为 Python3.6.2; 集成开发环境为 Anaconda 包中的 spyder3.28 版本. GA-LSTM 和 BP、LSTM 在 Keras 库中以 Tensorflow 为后端实现, 预测效果对比所用的 SVM 和 KNN 模型在 scikit-learn 库中实现.

4 实验结果及分析

4.1 交通流数据采集

本文选取广州某段高速公路 2017 年 9 月 20 日—2017 年 9 月 27 日车道高清卡口检测器的交通流数据作为预测样本. 高速公路作为封闭式通行系统, 交通流信息真实性高. 高速公路管理部门在对车辆进行控制和诱导时, 需要提前预估短时间交通流数据, 本文数据采集间隔分别为 5、15、30、60 min 4 种. 实验以前 7 天数据为训练样本, 第 8 天数据为测试样本. 图 4 为以 30 min 为间隔的 8 d 交通流数据. 高速公路周末同工作日流量相当, 数据具有周期性

特征. 采用前一阶段数据进行下一阶段数据预测.




图 4 交通流时间序列

Fig.4 Traffic flow time series

4.2 模型参数优化与分析

4.2.1 遗传算法设置参数

采用遗传算法优化 LSTM 模型参数取值, 设置种群中个体为 50, 迭代次数为 100, 变异概率 p_m 为 0.1, 交叉概率 p_c 为 0.6, 以 60 min 交通流数据为样本进行分析.

1) 搜索空间. ls 为网络层数, 10~160, 步长为 10; 采用 4 位二进制, 0000 代表 10. lb 为时间窗步长, 1~16, 步长为 1; 采用 4 位二进制, 0000 代表 1. ep 为训练次数, 10~320, 步长为 10; 采用 5 位二进制, 00000 代表 1. dp 为 dropout, 0.2~0.51, 步长为 0.01; 采用 5 位二进制, 00000 代表 0.20.

2) 编码. 根据参数性质, 采用二进制编码, 个体中含有 18 个基因. [0101, 0101, 01010, 01010] 表示为某个体, 则 4 段染色体分别表示为参数 ls 、 lb 、 ep 、 dp 基因型.

4.2.2 遗传算法训练最优值

经过训练, 结果如图 5 所示, 在 GA-LSTM 模型中, 可以在搜索空间快速找到近似最优解. 随着迭代步数增加, 如图 6 所示, 其最优解的均方误差在减少, 实现搜索空间最优解.




图 5 GA-LSTM 神经网络训练曲线

Fig.5 GA-LSTM neural network training curve




图 6 GA-LSTM 神经网络收敛曲线

Fig.6 GA-LSTM neural network convergence curve

4.2.3 参数对模型寻优影响

经过 100 次迭代, 对预测误差进行统计描述见表 1. 在 100 次迭代产生的最优值数据中, ls 的搜索覆盖范围为 10~160; lb 的搜索覆盖范围为 1~16; ep 的搜索覆盖范围为 20~320; dp 的搜索覆盖范围为 0.21~0.52. 4 种参数的搜索范围接近全搜索空间, 所得误差近似最优解. 其中最小均方误差为 0.003 508, 前 25% 位的均方误差为 0.004 328.

表 1 100 个最优参数组合信息统计描述

Tab. 1 Statistical description of 100 optimal parameter combination information

参数	E_{MS}	ls	lb	ep	dp
平均值	0.011 129	75.40	9.24	180.1	0.37
标准值	0.007 116	46.93	4.15	92.1	0.10
最小	0.003 508	10	1	20	0.21
25%	0.004 328	30	6.75	100	0.29
50%	0.010 21	70	10	200	0.36
75%	0.013 665	110	12	260	0.45
最大	0.034 549	160	16	320	0.52

对 100 个最优个体进行统计, 如图 7 所示, lb 、 ep 与 E_{MS} 相关性系数分别为 -0.68, -0.52, 在 0.01 的水平上显著性相关; ls 、 dp 与 E_{MS} 的相关系数分别为 -0.031、0.037, 相关性不大.




图 7 100 个最优组合参数相关性

Fig.7 100 optimal combination parameter correlation

对 25 个最优个体统计参数精细对比,如图 8 所示,lb 和 E_{MS} 的相关系数为-0.77,具有强相关性;ls、ep 分别为 -0.23、0.25,具有弱相关性;dp 仅为 -0.001 7,相关性不大。




图 8 25 个最优组合参数相关性

Fig.8 25 optimal combination parameter correlation
通过对大规模寻优和精细化调参对比,发现在 100 次迭代大范围调参过程中,lb、ep 对 E_{MS} 的影响显著性相关,ls、dp 对 E_{MS} 影响不大. 在对 25 最优个体参数精细对比中,lb 对 E_{MS} 具有强相关性,ls、ep 对 E_{MS} 有弱相关性,dp 对误差的影响不大。

4.3 预测结果及分析

由参数选取分析可得,最佳时间窗步长为 13,网络隐藏层数为 100,epochs 为 200,dropout 为 0.37,随机种子选取 7,分别绘制在 5 种预测模型对 4 种数据样本的预测结果。
为了清晰对比 5 种算法预测性能,本文以 30 min 和 60 min 的数据进行展示. 如图 9、10 所示,

5 种算法均能较好拟合真实数据,相比 SVM、KNN、BP、LSTM 算法,GA-LSTM 在交通流数据突变处表现的更加优越,趋势转变迅速,模型适应性强,预测精度更高。




图 9 5 种模型 30 min 数据预测结果

Fig.9 30 min data forecast results of five models




图 10 5 种模型 60 min 数据预测结果

Fig.10 60 min data forecast results of five models

经过 5 种不同模型的预测 4 种间隔数据所得 E_{MS} 和 E_{RMS} 见表 2. 在 E_{MS} 统计中,次优模型比 GA-LSTM 模型在 4 个数据集的预测中分别大 6.47%、5.09%、6.16%、29.5%;在 E_{RMS} 统计中,次优模型比 GA-LSTM 模型分别大 3.18%、7.07%、3.03%、13.8%。

表 2 不同模型对 4 种间隔数据预测结果对比

Tab.2 Comparison of prediction results of four interval datum by different models

模型	E_{MS}				E_{RMS}			
	5 min	15 min	30 min	60 min	5 min	15 min	30 min	60 min
SVM	0.003 749	0.004 048	0.004 646	0.005 848	0.061 227	0.063 621	0.068 159	0.076 470
KNN	0.005 017	0.003 941	0.004 208	0.004 956	0.070 829	0.062 781	0.064 869	0.070 400
BP	0.004 399	0.003 854	0.005 400	0.005 468	0.066 325	0.062 080	0.073 487	0.073 946
LSTM	0.003 798	0.003 544	0.004 105	0.004 543	0.061 628	0.059 534	0.064 070	0.067 401
GA-LSTM	0.003 521	0.003 373	0.003 866	0.003 508	0.059 338	0.055 602	0.062 184	0.059 228

本文所用的 GA-LSTM 模型同 SVM、KNN、BP、LSTM 等方法预测精度如图 11、12 所示. 在 5 种不同时间间隔数据的预测中,GA-LSTM 表现出的均方差和均方根误差均最小. SVM 模型在 5 min 间隔样本中,预测精度和 GA-LSTM 模型都较小,随着训练数据量的减少,预测误差在增大,SVM 模型更适

合交通流短期预测. KNN、BP 神经网络、GA-LSTM 模型在 15 min 间隔样本中取得最小误差. GA-LSTM 在 60 min 间隔数据样本预测中优势最大,显示出在数据量较小情况下的优越性. GA-LSTM 模型在 5 种间隔数据中均体现良好的预测性能,显示了模型良好的适用性和扩展性。




图 11 5 种模型对不同数据预测均方误差对比

Fig.11 Comparison of mean square error of five models for different data predictions




图 12 5 种模型对不同数据预测均方根误差对比

Fig.12 Comparison of root mean square error of five models for different data predictions

5 结 论

1)在介绍 LSTM 循环神经网络的概念和训练过程基础上,采用遗传算法对时间窗步长、LSTM 模型的网络隐藏层、训练次数、dropout 四个参数进行取值优化,采用 GA-LSTM 模型在高速公路交通流预测方面展开研究。

2)实验结果表明:遗传算法可以快速实现搜索空间参数最优化的取值,寻优效率高;时间窗步长同误差相关性大,训练次数在大范围寻优中影响较大,隐藏层数在精细寻优中有影响,dropout 对误差影响小;与常用机器学习算法相比,GA-LSTM 在数据预测中的适应性更广、精确度更高,可用于高速公路交通流的预测。

3)本文虽然是研究短时交通流预测,但该算法也可应用在中长期的交通流预测中. 随着深度学习的进一步应用,多源数据的挖掘、考虑多状态交织影响的交通流预测将会成为下一步研究方向。

参考文献

[1] SMITH B L, DEMETSKY M J. Traffic flow forecasting: comparison of modeling approaches[J]. Journal of Transportation Engineering, 1997, 123(4): 261

[2] VYTHOULKAS P C. Alternative approaches to short term traffic forecasting for use in driver information systems[J]. Transportation & Traffic Theory Proceedings of International Symposium on Traffic Flow Theory & Transportation, 1993, 12:485

[3] CHAN K Y, DILLON T S, SINGH J, et al. Neural-network-based models for short-term traffic flow forecasting using a hybrid exponential smoothing and Levenberg-Marquardt algorithm[J]. IEEE Transactions on Intelligent Transportation Systems, 2012, 13(2): 644

[4] QUEK C, PASQUIER M, LIM B B S. POP-TRAFFIC: a novel fuzzy neural approach to road traffic analysis and prediction[J]. IEEE Transactions on Intelligent Transportation Systems, 2006, 7(2): 133

[5] JIANG Y, ADELI H. Dynamic wavelet neural network model for traffic flow forecasting[J]. Journal of Transportation Engineering, 2005, 131(10): 771

[6] 姚智胜, 邵春福, 高永亮. 基于支持向量回归机的交通状态短时预测方法研究[J]. 北京交通大学学报, 2006, 30(3): 19

YAO Zhisheng, SHAO Chunfu, GAO Yongliang. Research on short-term traffic state prediction based on support vector regression[J]. Journal of Beijing Jiaotong University, 2006, 30(3): 19

[7] 于滨, 鄢珊华, 王明华, 等. K 近邻短时交通流预测模型[J]. 交通运输工程学报, 2012, 12(2): 109

YU Bin, WU Shanhua, WANG Minghua, et al. Short-term traffic flow prediction model for K-nearest neighbors[J]. Journal of Transportation and Engineering, 2012, 12(2): 109

[8] 罗向龙, 焦琴琴, 牛力瑶, 等. 基于深度学习的短时交通流预测[J]. 计算机应用研究, 2017, 34(1): 91

LUOXianglong, JIAO Qinqin, NIU Liyao, et al. Short-term traffic flow prediction based on deep learning[J]. Journal of Computer Applications, 2017, 34(1): 91

[9] 黄廷辉, 王玉良, 汪振, 等. 基于 Spark 的分布式交通流数据预测系统[J]. 计算机应用研究, 2018(2): 405

HUANG Tinghui, WANG Yuliang, WANG Zhen, et al. Spark-based distributed traffic data forecasting system[J]. Research on Application of Computers, 2018(2): 405

[10] 王祥雪, 许论辉. 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

WANG Xiangxue, XU Lunhui. Short-term traffic flow prediction based on deep learning[J]. Journal of Transportation Systems Engineering and, 2018, 18(1): 81

[11] 王鑫, 吴际, 刘超, 等. 基于 LSTM 循环神经网络的故障时间序列预测[J]. 北京航空航天大学学报, 2018, 44(4): 772

WANG Xin, WU Ji, LIU Chao, et al. Exploring LSTM based recurrent neural network for failure time series prediction[J]. Journal of Beijing University of Aeronautics and Astronautics, 2018, 44(4): 772

[12] 杨其, 陈水忠, 沈淑梅, 等. LSTM 网络和 ARMA 模型对惯性器件随机误差预测适应性分析[J]. 光电与控制, 2018, 25(3): 68

YANG Qi, CHEN Shuizhong, SHEN Shumei, et al. Adaptive analysis of random error prediction of inertial devices based on LSTM network and ARMA model[J]. Electronics Optics and Control, 2018, 25(3): 68

[13] PASCANU R, GULCEHRE C, CHO K, et al. How to construct deep recurrent neural networks[C]// International Conference on Learning Representations. Piscataway, NJ: IEEE Press, 2014: 1235

[14] DONG Y, LI D. Automatic Speech Recognition[M]. London: Springer Verlag, 2015: 237