

# 基于 GWO-LSTM 模型的道路交通事故量预测

孔维麟<sup>1</sup>,李文栋<sup>2\*</sup>,杨立柱<sup>3</sup>,张鲁玉<sup>1</sup>,王庆斌<sup>1</sup>

1. 山东建筑大学建筑工程学院,山东 济南 250101;

2. 中国市政工程西北设计研究院有限公司,甘肃 兰州 730030;

3. 云南省设计院集团有限公司,云南 昆明 650118

**摘要:**为降低道路交通事故率,减少事故损失,采用全局遍历性和收敛性较强的自适应学习策略灰狼优化(grey wolf optimizer, GWO)算法,对长短期记忆(long short term memory, LSTM)神经网络中的初始学习率、隐藏层节点数、正则化系数等参数进行优化训练,构建GWO-LSTM道路交通事故量预测模型。以2000—2019年美国道路交通致死事故数据为样本数据,分别采用月粒度、周粒度、时粒度划分交通事故数据,对比分析GWO-LSTM模型、自回归移动平均(autoregressive moving average, ARMA)模型、反向传播(back propagation, BP)神经网络和LSTM神经网络的道路交通事故预测结果。结果表明:在3种时间粒度下,GWO-LSTM模型预测结果的平均绝对百分比误差和均方根误差均最小,预测准确度较高,可用于道路交通事故量预测中。

**关键词:**交通事故;LSTM 神经网络;GWO 算法;时间粒度

中图分类号:U491.31

文献标志码:A

文章编号:1672-0032(2023)04-0060-08

引用格式:孔维麟,李文栋,杨立柱,等.基于 GWO-LSTM 模型的道路交通事故量预测[J].山东交通学院学报,2023,31(4):60-67.

KONG Weilin, LI Wendong, YANG Lizhu, et al. Road traffic accident prediction based on GWO-LSTM model[J]. Journal of Shandong Jiaotong University, 2023, 31(4):60-67.

## 0 引言

随建设交通强国的推进及智能交通技术的迅速发展,人们越来越重视道路交通安全。道路交通事故预测可降低交通事故潜在发生的影响程度,同时为事故管理部门提供相关信息,依据预测结果及时规划交通方案,对提高道路交通安全水平有重要意义<sup>[1]</sup>。

传统的交通事故预测模型有自回归移动平均(autoregressive moving average, ARMA)模型、差分自回归移动平均(autoregressive integrated moving average, ARIMA)模型和灰色预测模型等:谢华为<sup>[2]</sup>根据平稳时间序列建立ARMA道路交通事故预测模型;李心仪的<sup>[3]</sup>采用ARMA模型预测浙江省道路交通事故死亡人数;Li等<sup>[4]</sup>将ARMA模型与Apriori算法结合,预测交通状态趋势;Luo等<sup>[5]</sup>改进季节性差分自回归移动平均(seasonal autoregressive integrated moving average, SARMIA)模型,并与遗传算法相结合预测交通流;胡娟刚等<sup>[6]</sup>采用灰色预测方法预测铁路交通事故。ARMA、ARIMA模型能预测有明显趋势的数据,但无法预测非平稳性序列,灰色预测模型在处理有较少特征数据时能得到规律较强的生成序列,但预测波动变化明显的序列时误差较大。

收稿日期:2022-12-21

基金项目:交通运输部交通运输行业重点科技项目(2021-ZD2-047);山东省交通运输科技计划项目(2021B49);山东省高等学校青创科技支持计划项目(2021KJ058)

第一作者简介:孔维麟(1999—),男,山东菏泽人,硕士研究生,主要研究方向为交通运输,E-mail:839346955@qq.com。

\*通信作者简介:李文栋(1984—),男,兰州人,高级工程师,工学硕士,主要研究方向为智慧交通,E-mail:1306760294@qq.com。

与传统预测模型相比,深度学习预测模型有较强的非线性映射能力和自适应能力,能提取数据隐藏的自然结构和固有的抽象特征:Mo<sup>[7]</sup>基于反向传播(back propagation,BP)神经网络改进ARIMA模型,解决ARIMA模型不能较好拟合高维度噪声时间序列问题;Wang等<sup>[8]</sup>提出粒子群优化算法(particle swarm optimization,PSO)联合BP神经网络的PSO-BP驾驶员反应时间预测模型;吴芮<sup>[9]</sup>将BP神经网络与遗传算法相结合预测交通事故严重程度;李博豪<sup>[10]</sup>通过PSO优化BP神经网络建立多影响因素下高速公路交通事故严重程度实时预测模型;Shen等<sup>[11]</sup>采用BP神经网络预测进入高速公路休息区的车辆百分比。BP神经网络存在收敛速度慢且易陷入局部最小值等缺点。长短期记忆(long short-term memory,LSTM)神经网络通过引入门控单元机制,有效解决处理长序列数据时梯度消失和梯度爆炸的问题:Bhandari等<sup>[12]</sup>通过试验证明LSTM神经网络有优异的拟合性和较高的预测准确度;Zhang等<sup>[13]</sup>将LSTM神经网络与梯度增强回归树(gradient boosting regression tree,GBRT)算法结合,建立LSTM-GBRT的交通事故预测模型;熊晓夏等<sup>[14]</sup>将贝叶斯滤波(Bayesian filter,BF)与LSTM神经网络结合,评估高速公路事故风险状态;Oliveira等<sup>[15]</sup>将多层次感知器与LSTM神经网络结合,预测交通流量。网络结构参数的设置对预测性能有较大影响,以上研究多基于BP神经网络确定LSTM神经网络的网络参数,计算量大、复杂度高且易陷于局部最优。

灰狼优化(grey wolf optimizer,GWO)算法是一种模拟灰狼群种族习性的启发式算法,具有全局遍历性和收敛速度快的特点<sup>[16-18]</sup>。本文采用GWO算法对LSTM神经网络中的初始学习率、隐藏层节点个数、正则化系数参数进行优化训练,提出GWO-LSTM道路交通事故量预测模型,与ARMA模型、BP神经网络和LSTM神经网络预测结果对比,检验其性能与预测精度,为交通事故量预测提供参考和依据。

## 1 GWO-LSTM

### 1.1 LSTM神经网络

LSTM神经网络在隐藏层构建专门存储记忆的线性自循环存储单元,改进循环神经网络(recurrent neural network,RNN)的记忆暂时存储功能,解决预测长时间序列数据时的梯度消失问题,在神经元设置遗忘门、输入门、输出门3个控制门和1个记忆单元<sup>[19-21]</sup>。

遗忘门负责接收前一单元的记忆 $c_{t-1}$ 并对其各部分决定保留或遗忘,通过激活函数Sigmoid将 $t$ 时刻的输入 $x_t$ 与前一时刻细胞状态 $h_{t-1}$ 转换为输出 $f_t$ , $f_t$ 中的每个元素都位于[0,1],表示 $c_{t-1}$ 中保留或遗忘的信息量,0为完全舍弃,1为完全保留,公式为:

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

式中: $\sigma$ 为激活函数Sigmoid, $W_f$ 为遗忘门的连接权值矩阵,筛选 $x_t$ 和 $h_{t-1}$ 中舍弃部分的信息; $b_f$ 为遗忘门的偏置矩阵。

输入门负责将信息记录到单元模块中,由激活函数Sigmoid和双曲正切激活函数tanh共同控制,输出分别为 $i_t$ 、 $c_t$ ,公式为:

$$\begin{aligned} i_t &= \sigma(W_i [h_{t-1} \ x_t] + b_i), \\ c_t &= f_t c_{t-1} + i_t c_t', \end{aligned}$$

式中: $W_i$ 为输入门的连接权值矩阵,筛选 $x_t$ 和 $h_{t-1}$ 中记忆学习部分的信息; $b_i$ 为遗忘门的偏置矩阵; $c_{t-1}$ 为记忆单元前一时刻的输出; $c_t'$ 为临时记忆单元, $c_t' = \tanh(W_c [h_{t-1} \ x_t] + b_c)$ ,其中, $W_c$ 为记忆单元的权值矩阵, $b_c$ 为记忆单元的偏置矩阵。

通过激活函数Sigmoid将输出门当前时刻的状态 $o_t$ 中的每个元素转换为[0,1]上的数值,公式为:

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

式中: $W_o$ 为输出门的连接权值矩阵, $b_o$ 为输出门的偏置矩阵。

输出门最终决定当前状态输出哪些信息,将 $o_t$ 与经函数tanh处理的 $c_t$ 相乘,得到输出门的输出 $h_t = o_t \tanh(c_t)$ 。

LSTM 神经网络的结构如图 1 所示。

### 1.2 GWO 算法

GWO 算法模拟灰狼群的种群阶级和狩猎习性,在灰狼包围、捕捉和攻击猎物的过程中优化目标。根据等级制度将灰狼从高到低分为  $\alpha$ 、 $\beta$ 、 $\delta$  和  $\omega$  4 个阶层: $\alpha$  层级灰狼决策权力最高,其他个体灰狼均服从其指挥; $\beta$  层级灰狼是候选决策领导者,协助  $\alpha$  层级灰狼管理狼群; $\delta$  层级灰狼须遵从  $\alpha$ 、 $\beta$  层级灰狼的决策,可管理  $\omega$  层级灰狼;最底层级的  $\omega$  层级灰狼须服从其他层级的灰狼<sup>[22-23]</sup>。灰狼的狩猎过程分 3 个阶段。

1) 包围猎物。灰狼与目标猎物的距离

$$\mathbf{D} = |\mathbf{C} \odot \mathbf{X}_p(k) - \mathbf{X}(k)|,$$

式中: $\mathbf{C}$  为包围猎物时的协同向量, $k$  为迭代次数, $\mathbf{X}_p(k)$  为猎物的位置, $\mathbf{X}(k)$  为灰狼的位置, $\odot$  为矩阵的哈达玛积。

灰狼位置更新

$$\mathbf{X}(k+1) = \mathbf{X}_p(k) - \mathbf{A} \odot \mathbf{D},$$

式中: $\mathbf{A}$  为位置更新时的协同向量。

2) 捕捉猎物。灰狼包围猎物后,设  $\alpha$ 、 $\beta$ 、 $\delta$  层级灰狼距猎物距离依次增大,灰狼的位置随迭代不断更新,带领其他灰狼不断向猎物逼近,不同灰狼间的距离计算公式为:

$$\mathbf{D}_i = |\mathbf{C}_j \odot \mathbf{X}_i(k) - \mathbf{X}(k)|, i = \alpha, \beta, \delta, j = 1, 2, 3,$$

式中: $\mathbf{D}_i$  分别为  $\alpha$ 、 $\beta$ 、 $\delta$  层级灰狼与其他灰狼的距离, $\mathbf{X}_i(k)$  分别为  $\alpha$ 、 $\beta$ 、 $\delta$  层级灰狼的位置, $\mathbf{C}_j$  为捕捉猎物时协同向量。

迭代  $k+1$  次后,灰狼的位置

$$\mathbf{X}(k+1) = \frac{1}{3} \sum_{j=1}^3 [\mathbf{X}_i(k) - A_j \odot \mathbf{D}_i],$$

式中  $A_j$  为灰狼对猎物的攻击系数。

3) 攻击猎物。当猎物无法移动逃走时,灰狼发起攻击。逼近猎物的过程中, $A$  在  $[-a, a]$  中变化,其中  $a$  为收敛因子, $a$  在迭代过程中由 2 线性减小为 0。GWO 算法根据  $A$  确定搜寻范围:  $|A| < 1$  时,灰狼群逼近猎物,进行局部搜寻;  $|A| > 1$  时,灰狼群远离猎物,进行全局搜寻;  $|A| = 1$  时,灰狼群停止搜寻。

## 2 交通事故预测模型

### 2.1 模型参数优化

道路交通事故预测过程包括数据处理、模型参数优化、模型训练、模型预测与评价。通过 GWO 算法对 LSTM 神经网络中的参数进行调整优化,获取最优参数,提高模型预测准确度。

确定初始学习率、隐藏层节点数、GWO 算法的迭代次数及灰狼群数等参数。采用随机分布函数初始化灰狼群,确定其位置向量并分解为 LSTM 神经网络的权值矩阵和偏置矩阵。以均方根误差为适应度函数,将参数输入 LSTM 神经网络,计算输出及灰狼个体的适应度,将适应度最佳的 3 个位置依次标记为  $\mathbf{X}_\alpha$ 、 $\mathbf{X}_\beta$ 、 $\mathbf{X}_\delta$ ,随迭代次数的增加,此 3 个位置将被适应度更优的个体位置更新替换,直至迭代结束。

$\mathbf{X}_\alpha$  即为 LSTM 神经网络参数的最优解,将测试集数据通过输入层→隐藏层→输出层正向传递输入 LSTM 神经网络进行预测,采用均方误差(mean squared error, MSE)损失函数计算偏差,将其反向传递,神经元中相关参数得到更新并采用 Adam 优化函数调整网络梯度。迭代更新直至满足收敛条件终止后,输出 GWO-LSTM 道路交通事故预测模型参数,进行预测与评估。

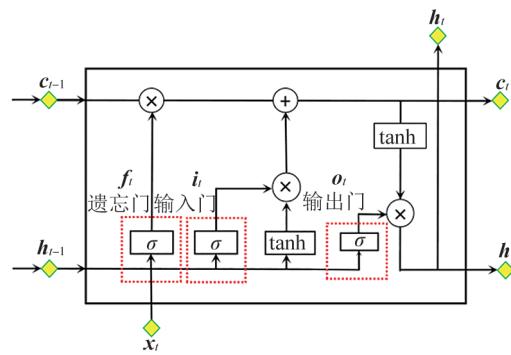


图 1 LSTM 神经网络结构示意图

GWO-LSTM交通事故预测模型框架如图2所示,图中 $k_{\max}$ 为最大迭代次数, $x_1 \sim x_n, y_1 \sim y_n$ 分别为第1~n个网络单元输入的样本数据和训练输出的数据, $L_1 \sim L_n$ 为第1~n个LSTM神经网络单元。

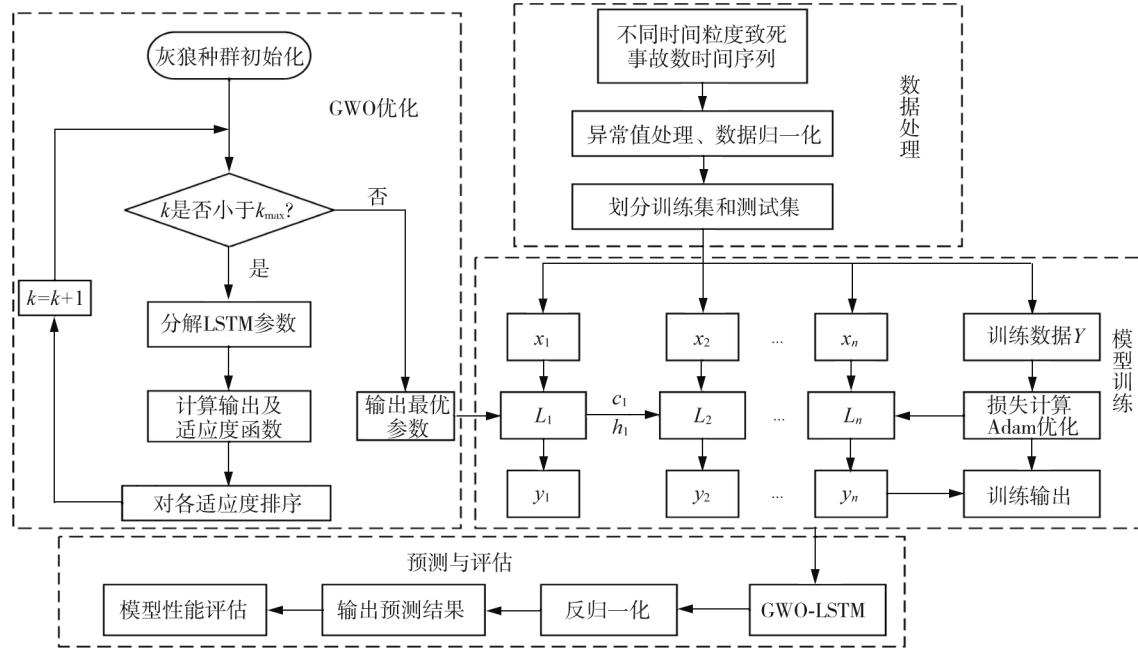


图2 GWO-LSTM交通事故预测模型框架

## 2.2 试验数据与预处理

采用2000—2019年美国道路交通致死事故数据为样本数据源,样本数据记录了每起致死事故的完整信息,主要字段包括:STATE、ST\_CASE、MONTH、DAY\_WEEK、HOURNAME、ROUTE、FATALS,对应的内容分别为:事故发生所在州编号、事故唯一标识编号、事故发生月份编号、事故发生日期、事故发生时刻、路线编码、死亡人数。

采用平均值修正法修正样本数据中的异常值,时间粒度事故统计样本数据的特征受各因素影响而上下波动,为平滑时间序列,采用离差标准化归一化法将数据线性转换到[0,1],缩放后值域长度较小,模型收敛速度和预测准确度提高。归一化后的样本数据

$$x'_i = (x_i - x_{\min}) / (x_{\max} - x_{\min}),$$

式中: $x_i$ 为原始样本数据, $x_{\max}, x_{\min}$ 分别为样本数据的最大值、最小值。

## 2.3 时间粒度及滑动窗口划分

时间粒度即划分子数据单元的度量单位,如年、月、周、时等,每个绝对时间区间由有限个时间粒度单元组成,受样本数据特征影响,适当的时间粒度可反映事故特性<sup>[24-25]</sup>。根据道路交通事故历史数据序列的特征和周期确定以月粒度、周粒度、时粒度3种时间粒度统计样本数据。

采用滑动窗口预测法预测不同时间粒度的事故样本数据,将特征值按时间序列排列,根据设定的时间粒度划分为不同窗口单元,窗口以1个单位步长向前滑动,反复向前,得到特征值的变化趋势,原理如图3所示。由图3可知: $n_1 \sim n_5$ 包含4个窗口单元,由时间粒度决定滑动窗口的长度,即 $n_{i-1}$ 与 $n_i$ 间的时间。以月粒度、周粒度、时粒度3种时间粒度划分子数据后,可确保特征值向后滚动预测时的滑动窗口长度,也可保留数据间的相关性。

## 2.4 模型性能评价指标

选取平均绝对百分比误差(mean absolute percentage error, MAPE) $E_{\text{MAPE}}$ 、均方根误差(root mean square

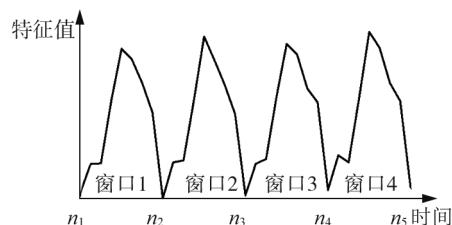


图3 滑动窗口示意图

error, RMSE)  $E_{\text{RMSE}}$  为评价 GWO-LSTM 交通事故预测模型性能的指标, 公式分别为:

$$E_{\text{MAPE}} = \sum_{i=1}^n |(e'_i - e_i)/e_i|/n \times 100\% ,$$

$$E_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (e'_i - e_i)^2} ,$$

式中: $e'_i$  为预测值, $e_i$  为实际值, $n$  为样本容量。

### 3 模型训练与评价

试验平台采用 Windows10 64 位操作系统, 试验环境为 AMD Ryzen 7 5800HS Creator Edition 3.20 GHz, RAM 为 16 GB, 采用软件 MATLAB R2019a 编程。

#### 3.1 模型参数设置

在 GWO-LSTM 交通事故预测模型训练过程中输入事故数据字段为: 事故发生月份编号、事故发生日期、事故发生时刻、死亡人数, 结构由输入层、1 层隐藏层和输出层构成, 输出维数为 1; 在 GWO 算法中设置灰狼群个体数为 30, 迭代次数为 20, 初始学习率搜索范围为 [0.001, 0.500], 隐藏层节点数的搜索范围为 [1, 30], 正则化系数的搜索范围为 [0.001, 0.050]。为达到收敛并防止出现过拟合现象, 将 LSTM 神经网络的训练次数设为 200, 学习率下降因子为 0.1, 激活函数为 Relu, 采用优化函数 Adam 调节梯度下降。采用 GWO 算法对 LSTM 神经网络 3 种时间粒度的样本数据进行参数优化, 得到不同时间粒度下的最优参数如表 1 所示。

GWO 算法参数寻优时适应度函数随迭代次数的变化曲线如图 4 所示。由图 4 可知: 月粒度划分的事故样本数据的适应度函数收敛速度最快, 适应度函数值最大, 周粒度划分的事故样本数据的适应度函数值最小。GWO-LSTM 模型训练过程中的  $E_{\text{RMSE}}$  随训练次数的变化曲线如图 5 所示。由图 5 可知周粒度划分的事故样本数据的  $E_{\text{RMSE}}$  最小。

表 1 不同时间粒度下 LSTM 神经网络的最优参数

时间粒度	初始学习率	隐藏层节点数	正则化系数
月	0.007 541	24	0.009 204
周	0.060 986	15	0.018 703
时	0.113 005	19	0.007 381

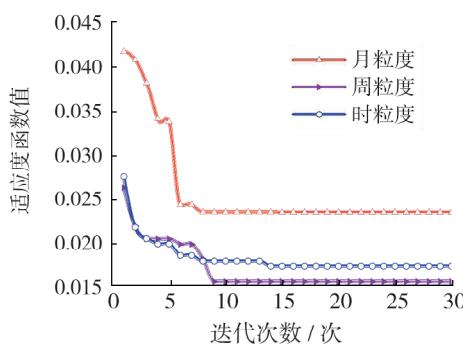


图 4 适应度函数随迭代次数的变化曲线

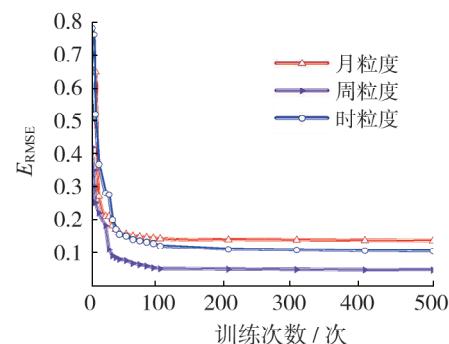


图 5  $E_{\text{RMSE}}$  随训练次数的变化曲线

将事故样本数据序列按 8 : 2 划分为训练集和测试集, 即将预处理后的样本序列的前 80% 作为训练集训练优化模型并调试参数, 后 20% 作为测试集。取不同时间粒度滑动窗口进行采样, 采用训练好的 GWO-LSTM 模型进行事故预测。

#### 3.2 预测结果

将 ARMA 模型、BP 神经网络和 LSTM 神经网络作对比, 验证 GWO-LSTM 交通事故预测模型的性能。GWO-LSTM 模型、ARMA 模型、BP 神经网络和 LSTM 神经网络对 3 种时间粒度下交通致死事故量的预测

结果如图6所示。

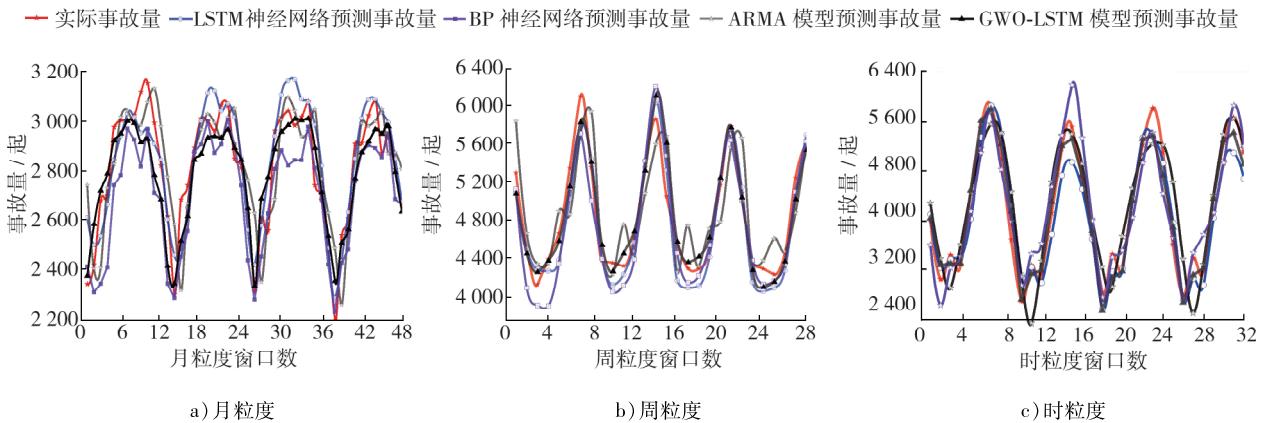


图6 不同模型在不同时间粒度下交通致死事故量的预测结果

由图6可知:相比月粒度预测结果,4种模型对周粒度和时粒度的交通致死事故量预测结果更准确,这与时间粒度划分更细,模型数据起伏较大,周期性特征明显,更易被模型捕捉有关。ARMA模型和BP神经网络预测数据的峰值趋势时与实际数据存在一定偏差,LSTM神经网络和GWO-LSTM模型捕捉事故数据峰值的能力较强。

根据不同模型在不同时间粒度下交通致死事故量的预测结果,计算 $E_{RMSE}$ 和 $E_{MAPE}$ ,评价对比模型的预测准确度,结果如表2所示。

表2 不同模型的性能评价指标

模型	$E_{RMSE}$			$E_{MAPE}/\%$		
	月粒度	周粒度	时粒度	月粒度	周粒度	时粒度
ARMA	165.7	333.9	441.9	6.84	4.96	8.48
BP	153.1	232.7	339.8	7.76	7.12	8.11
LSTM	113.1	190.2	284.9	5.20	3.28	4.70
GWO-LSTM	109.4	165.6	202.5	2.96	2.48	2.62

由表2可知:不同时间粒度下GWO-LSTM模型的 $E_{RMSE}$ 和 $E_{MAPE}$ 均最小,模型预测准确度最高,LSTM神经网络次之,BP神经网络和ARMA模型预测准确度较低。ARMA模型捕捉平稳时间序列数据间线性关系的能力较强,但捕捉非线性时间序列数据峰值的灵敏性较差;BP神经网络采用误差逆传播算法进行网络训练,模型预测时忽略输入与输出间的滞后和延迟性,导致预测误差较大;相比于传统模型,GWO-LSTM模型和LSTM神经网络考虑到预测的滞后效应,能更好解决长期依赖问题,捕捉数据信息间的规律和关系的能力更佳,在处理序列数据和非线性问题中优势更显著,与LSTM网络参数调节相比,GWO-LSTM优化参数寻优方式,预测准确度较好。

## 4 结论

采用GWO算法替代标准LSTM神经网络中的BP神经网络算法,优化初始学习率、隐藏层节点数、正则化系数等参数,提出基于GWO-LSTM的道路交通事故量预测模型。采用月粒度、周粒度和时粒度3种时间粒度划分交通事故样本数据,分别采用传统ARMA模型、BP神经网络、标准LSTM神经网络和GWO-LSTM模型预测交通事故量,并与实际数据对比。结果表明:在3种时间粒度下,与ARMA模型、BP神经网络和LSTM神经网络相比,GWO-LSTM模型的全局遍历性和收敛性速度最快,预测结果的平均绝

对百分比误差和均方根误差均较小,预测结果更准确。

道路交通事故的发生具有随机性等特点且受多种环境因素影响,参数优化和训练中缺乏表征环境因素的相关数据,未来考虑在环境多因素条件下预测交通事故量,进一步提高模型的预测性能。

### 参考文献:

- [1] 刘志,王锦梦,孔祥杰.基于时空图卷积网络的交通事故预测研究[J].浙江工业大学学报,2022,50(2):128-135.  
LIU Zhi, WANG Jinmeng, KONG Xiangjie. Research on traffic accident prediction based on spatio-temporal graph convolutional network [J]. Journal of Zhejiang University of Technology, 2022, 50(2): 128-135.
- [2] 谢华为.基于ARMA平稳时间序列的道路交通事故预测[J].宁德师范学院学报(自然科学版),2018,30(3):268-272.  
XIE Huawei. Prediction of road traffic accidents based on ARMA stationary time series [J]. Journal of Ningde Normal University(Natural Science), 2018, 30(3): 268-272.
- [3] 李心仪的,叶佳欣,林爽,等.基于ARMA模型的浙江省道路交通事故死亡人数预测探究[J].新型工业化,2021,11(4):67-69.
- [4] LI R H, CHEN W J, XU W H, et al. Prediction on the value trends of bitcoin and gold-on account of ARMA time series forecasting model[J]. Academic Journal of Computing & Information Science, 2022, 5(7): 79-84.
- [5] LUO X L, NIU L X, ZHANG S R. An algorithm for traffic flow prediction based on improved SARIMA and GA[J]. KSCE Journal of Civil Engineering, 2018, 22(10): 4107-4115.
- [6] 胡哨刚,孔祥芳,旷利平,等.基于灰色理论的铁路交通一般事故数据预测模型[J].交通科技与经济,2021,23(4):27-31.  
HU Shaogang, KONG Xiangfang, KUANG Liping, et al. Data forecast model of general railway traffic accidents based on grey theory [J]. Technology and Economy in Areas of Communications, 2021, 23(4): 27-31.
- [7] MO L H. An improved ARIMA method based on hybrid dimension reduction and BP neural network[J]. Academic Journal of Computing & Information Science, 2022, 5(10): 41-47.
- [8] WANG D, HONG L, ZHANG C, et al. Prediction model for driver reaction time based on PSO-BP neural network model [J]. Security and Communication Networks, 2022, 2022: 6100702.
- [9] 吴芮.基于BP神经网络的道路交通事故严重程度分析预测[D].成都:西华大学,2020.  
WU Rui. Analysis and prediction of road traffic accident severity based on BP neural network [D]. Chengdu: Xihua University, 2020.
- [10] 李博豪.基于PSO-BP的高速公路事故实时预测模型[D].石家庄:石家庄铁道大学,2021.  
LI Bohao. Real-time highway accident based on PSO-BP predictive model [D]. Shijiazhuang: Shijiazhuang Tiedao University, 2021.
- [11] SHEN X Y, LIU H X, LIU J. Prediction for percentage of vehicle entering expressway rest area based on BP neural network[J]. Applied Mechanics and Materials, 2012, 1802(359): 178-181.
- [12] BHANDARI H N, RIMAL B, POKHREL N R, et al. Predicting stock market index using LSTM[J]. Machine Learning with Applications, 2022, 9: 100320.
- [13] ZHANG Z H, YANG W Z, WUSHOUR S. Traffic accident prediction based on LSTM-CBRT model[J]. Journal of Control Science and Engineering, 2020, 2020: 4206919.
- [14] 熊晓夏,刘擎超,沈钰杰,等.基于LSTM-BF的高速公路交通事故风险模型[J].中国安全科学学报,2022,32(5):170-176.  
XIONG Xiaoxia, LIU Qingchao, SHEN Yujie, et al. Study on risk model of highway traffic accidents based on LSTM-BF [J]. China Safety Science Journal, 2022, 32(5): 170-176.
- [15] OLIVEIRA D D, RAMPINELLI M, TOZATTO G Z, et al. Forecasting vehicular traffic flow using MLP and LSTM[J]. Neural Computing and Applications, 2021, 33(24): 17245-17256.
- [16] RASHID T A, FATTAH P, AWLA D K. Using accuracy measure for improving the training of LSTM with metaheuristic algorithms[J]. Procedia Computer Science, 2018, 140: 324-333.
- [17] 鲍伟,任超.基于GWO-BP神经网络的电池SOC预测方法研究[J].计算机应用与软件,2022,39(9):65-71.  
BAO Wei, REN Chao. Research on prediction method of battery SOC based on GWO-BP network [J]. Computer Applications and Software, 2022, 39(9): 65-71.

- [18] 石彪,王海燕,焦品博. 基于改进 GWO-LSTM 的船舶主机性能预测模型[J]. 上海海事大学学报,2022,43(2):96–102.  
SHI Biao, WANG Haiyan, JIAO Pinbo. Prediction model of marine main engine performance based on improved GWO-LSTM[J]. Journal of Shanghai Maritime University, 2022, 43(2): 96–102.
- [19] 吉兴全,曾若梅,张玉敏,等. 基于注意力机制的 CNN-LSTM 短期电价预测[J]. 电力系统保护与控制,2022,50(17):125–132.  
JI Xingquan, ZENG Ruomei, ZHANG Yumin, et al. CNN-LSTM short-term electricity price prediction based on an attention mechanism[J]. Power System Protection & Control, 2022, 50(17): 125–132.
- [20] 谭海旺,杨启亮,邢建春,等. 基于 XGBoost-LSTM 组合模型的光伏发电功率预测[J]. 太阳能学报,2022,43(8):75–81.  
TAN Haiwang, YANG Qiliang, XING Jianchun, et al. Photovoltaic power prediction based on combined XGBoost-LSTM model[J]. Acta Energiae Solaris Sinica, 2022, 43(8): 75–81.
- [21] 谷妙春. 基于噪声统计的 EMD-LSTM 网络流量预测方法[J]. 计算机测量与控制,2023,31(2):21–27.  
GU Miaochn. Method of an EMD-LSTM network traffic prediction based on noise statistics[J]. Computer Measurement & Control, 2023, 31(2): 21–27.
- [22] MIRJALILI S, MIRJALILI S M, LEWIS A. Grey wolf optimizer[J]. Advances in Engineering Software, 2014, 69:46–61.
- [23] PAN J X, JING B, JIAO X X, et al. Analysis and application of grey wolf optimizer-long short-term memory[J]. IEEE Access, 2020, 8:121460–121468.
- [24] 陈碧瑶. 基于 Bi-LSTM 的道路交通事故数预测研究[D]. 西安:长安大学,2021.  
CHEN Biyao. Research on forecast of road traffic accidents based on Bi-LSTM[D]. Xi'an: Chang'an University, 2021.
- [25] 黄曜. 考虑时间粒度的城市越江隧道交通事故随机参数模型研究[D]. 哈尔滨:哈尔滨工业大学,2021.  
HUANG Yao. Random parameters crash prediction model for urban cross-river tunnels with multi-time aggregation data [D]. Harbin: Harbin Institute of Technology, 2021.

## Road traffic accident prediction based on GWO-LSTM model

KONG Weilin<sup>1</sup>, LI Wendong<sup>2\*</sup>, YANG Lizhu<sup>3</sup>, ZHANG Luyu<sup>1</sup>, WANG Qingbin<sup>1</sup>

1. School of Traffic Engineering, Shandong Jianzhu University, Jinan 250101, China;

2. CSCEC AECOM Consultants Co., Ltd., Lanzhou 730030, China; 3. Yunnan Design Institute Group Co., Ltd., Kunming 650118, China

**Abstract:** In order to reduce the road traffic accident rate and minimize accident losses, the gray wolf optimizer (GWO) algorithm, which has strong global traversal and convergence properties, is used to optimize the initial learning rate, hidden layer nodes, regularization coefficient and other parameters in the long short term memory (LSTM) neural network. The GWO-LSTM road traffic accident prediction model is constructed. Taking the road traffic fatal accident data from 2000 to 2019 as the sample data, the traffic accident data is divided into monthly granularity, weekly granularity, and hourly granularity. The road traffic accident prediction results of the GWO-LSTM model, autoregressive moving average (ARMA) model, back propagation neural network (BPNN) model, and standard LSTM model are compared and analyzed. The results show that under the three time granularities, the GWO-LSTM model has the smallest average absolute percentage error and root mean square error, and high prediction accuracy. It can be used for road traffic accident prediction.

**Keywords:** traffic accident; LSTM neural network; GWO algorithm; time granularity

(责任编辑:赵玉真)