

基于 LSTM 的船舶航迹预测模型

权 波¹ 杨博辰² 胡可奇² 郭晨萱¹ 李巧勤²

(中国电子科技集团公司第 10 研究所成都天奥信息科技有限公司 成都 611731)¹

(电子科技大学信息与软件工程学院 成都 610054)²

摘 要 针对海上日趋复杂的情形,提高船舶交通服务系统(Vessel Traffic Service,VTS)的决策水平迫在眉睫。针对船舶航行轨迹多维度的特点以及对船舶航迹预测的精确度和实时性的需求,提出了结合船舶自动识别系统(Auto-matic Identification System,AIS)数据和深度学习的船舶航行航迹预测方法。构造基于 AIS 数据的航行轨迹特征,提出了循环神经网络-长短期记忆(Recurrent Neural Networks-Long Short-Term Memory,RNN-LSTM)模型,利用广州港内的船舶 AIS 数据对模型进行训练,并对未来船舶航行航迹进行预测。实验结果表明,利用 RNN-LSTM 模型的预测方法具有精确度高、易实现的特点,并且与传统处理方法相比,其在处理序列数据方面更具优越性。

关键词 循环神经网络,航迹预测,长短期记忆,船舶自动识别系统

中图法分类号 TP183 **文献标识码** A

Prediction Model of Ship Trajectory Based on LSTM

QUAN Bo¹ YANG Bo-chen² HU Ke-qi² GUO Chen-xuan¹ LI Qiao-qin²

(Chengdu Spaceon Technology Co. Ltd., 10th Institute of CETC, Chengdu 611731, China)¹

(School of Information and Software Engineering, University of Electronic Science and Technology, Chengdu 610054, China)²

Abstract It is imperative to raise the level of decision-making for vessel traffic service (VTS) system in the light of the increasingly complex maritime circumstances. Aiming at the multidimensional characteristics of the ship's navigation trajectory and the demand for the accuracy and the real-time prediction of the ship's trajectory, a prediction method combining ship trajectory automatic identification system (AIS) data and deep learning was proposed. The feature expression of vessel behavior based on AIS data was established and the recurrent neural network-long short term memory (RNN-LSTM) model was proposed. The model was trained by AIS data from the Guangzhou Harbor and used to predict vessel trajectory. The results show that the method can predict the characteristics of vessel trajectory timely with acceptable accuracy. Compared with the traditional processing method, it is more superior in processing time series data.

Keywords RNN, Ship trajectory predict, LSTM, AIS

1 引言

在交通密度大、情况繁杂的海域或港口,利用船舶交通服务系统(Vessel Traffic Service,VTS)准确、有效地对船舶的航行轨迹进行及时跟踪和预测是海上交通事故预警的重要技术支撑。目前已有不少针对船舶航迹预测的研究。文献[1]运用卡尔曼滤波算法对船舶观测数据进行最小二乘法估计,得到平滑的船舶轨迹,继而进行预测。文献[2]改进了卡尔曼滤波算法,将其应用到船舶的轨迹处理中,对船舶运动轨迹进行预测。文献[3]运用竞争神经网络对船舶航行状态进行探测和跟踪,扩展了卡尔曼滤波算法,对船舶航行状态进行估计。文献[4]使用支持向量机(Support Vector Machine,SVM)模型对目标水域内失控的船舶的航迹进行预测。文献[5]引入基于时间序列的船舶航行位置,利用灰度预测模型对船舶航行位置进行预测。文献[6]引入一种基于贝叶斯网络

的新型机器学习算法——高斯回归过程,并将其应用于抗干扰性要求较高的移动通信环境中的船舶航迹预测。文献[7]利用灰色模型结合马尔科夫链对船舶的航行轨迹进行预测。上述传统机器学习预测方法都属于线性预测方法,而且需要利用专家知识构建船舶的运动学方程,加上外部环境因素对船舶运动的影响较大,导致船舶运动轨迹具有复杂性,实时地建立数学方程较难实现,大多只适用于理想状态。文献[8]设计基于 3 层 BP(Back Propagation)神经网络的航迹预测模型,它具有用时短、通用性强的特点,适合 VTS 等管理系统对船舶航迹预测实时、高效的需求。但文献[8]仅对船舶的空间位置进行了预测。文献[9]在此基础上,利用 AIS 数据信息量大的特点,提出结合船舶 AIS 信息和 BP 神经网络对船舶航行的行为进行预测,实现了多维度的船舶航行特征预测。但针对复杂的船舶航海航迹预测问题,BP 神经网络(一般选取 3 层,增加层数会增加训练时间且容易过拟合)的映射表示

本文受国家自然科学基金青年基金(61502082)资助。


权 波(1978—),男,工程师,主要研究方向为电子信息系统工程;**杨博辰**(1993—),男,硕士生,主要研究方向为移动互联网、机器学习;**胡可奇**(1993—),男,硕士生,主要研究方向为机器学习;**郭晨萱**(1978—),女,助理工程师,主要研究方向为电子信息系统工程;**李巧勤**(1972—),女,博士,副教授,主要研究方向为物联网、大数据技术,E-mail:helenli803@163.com。

能力有限, BP 参数难以调整,且在本质上 BP 算法容易使损失函数的训练结果落入局部最小点而不是全局最小点,因此该算法模型的泛化能力受到一定制约,且无法对时间序列上的变化进行建模。深度学习(Deep Learning)则可通过学习一种深层非线性网络结构,实现复杂函数逼近,具有从少数样本集中学习数据集本质特征的能力^[10]。循环神经网络 RNN 作为深度学习的一种典型模型,可用来处理时间序列数据^[11]。以船舶航行轨迹态势预测为例,未来时间的态势依赖于历史时刻的态势值。RNN 对所有节点执行相同的操作,当前时刻的输出依赖之前的计算结果。利用 RNN-LSTM 循环神经网络学会当前环境和既有时刻基础上的船舶运动规律,然后进行航迹预测。这一理念既避免了传统算法中繁杂的建模过程,又保证了所建立的模型是符合实际逻辑的。本文提出了利用 RNN-LSTM 架构的深度学习模型,结合 AIS 提供的实时性强、数据量大、数据内容丰富的信息,可更好地解决海上船舶轨迹的预测问题。


2 RNN-LSTM 循环神经网络结构

神经网络是由大量处理单元互联组成的、高度复杂的非线性、自适应信息处理系统。它由一组神经元有向连接构成,通过输入、输出接口实现与外部的数据交换,通过调整内部神经元之间的连接强度,建立输入到输出的映射,通过对样本数据的学习,形成一定精度的映射规则,其突出的学习能力省略了系统建模这一步骤,特别适合规律未知或不确定的情况,而分布性和并行性又使得神经网络具有很强的容错性和鲁棒性,多层神经网络可以任意精度逼近连续映射。

循环神经网络 RNN 也称递归神经网络,是一种深层次的神经网络模型,也是近年来深度学习领域的热点技术之一,在机器翻译、语音识别及图像识别领域都取得了巨大成功。图 1(a)展示了一个标准的循环神经网络 RNNs 的层次结构,分别为输入层、隐藏层和输出层。



(a) RNNs 的层次架构图



(b) RNNs 的展开示意图

图 1 RNN 结构示意图

网络中的各层由神经单元组成。图 1(b)是 RNNs 按照时序展开成全网络的神经元结构图。假设时间序列为 $\{t | t = 1, 2, \dots, T\}$, RNNs 包含输入单元,输入集标记为 $\{x_0, x_1, \dots, x_t, x_{t+1}, \dots\}$; o 为输出单元,标记为 $\{o_0, o_1, \dots, o_t, o_{t+1}, \dots\}$,其中 o_t 代表 t 时刻的输出。RNNs 还包含隐藏单元,记为 $\{s_0, s_1, \dots, s_t, s_{t+1}, \dots\}$,其中 s_t 为 t 时刻的隐含层状态,通过上一

时刻隐含层状态和当前时刻的输入计算得到。第一个隐含层状态 s_0 初始化为 0。隐藏单元完成了最主要的工作,是网络中的记忆单元。传统神经网络模型的每一层使用不同参数,而 RNN 的每一层在每一个时刻都使用相同的参数 U, V, W ,这 3 个参数矩阵是 RNN 模型的线性关系参数,它在整个 RNN 网络中是共享的,正是由于这种共享性,保证了 RNN 对所有节点执行相同的操作,从而减少了需要学习的参数的个数。RNN 最主要的特征则通过隐含层间相互连接的信息流实现,也就是说,记忆单元即隐含层状态 s ,包含了所有历史时刻状态信息。

普通的循环神经网络存在结点记忆快速衰弱的缺点, LSTM(Long Short-Term Memory)长短期记忆网络模型改善了这种不利状况^[12]。LSTM 模型结构包含一组相互联系的递归子网络,也就是记忆模块,它们取代了普通 RNN 中的记忆单元,并且比普通 RNN 更易于训练。每个模块包含一个或多个自相关的核心信元 cell 和 3 个用于控制信息流入存储单元以及从单元到网络的新增单元——门(gate):输入门(input gate)、输出门(output gate)和遗忘门(forget gate)。在本文实验中,它们分别对应着船舶轨迹特征数据序列的写入、读取和先前状态的重置操作。图 2 是包含一个记忆单元的 LSTM 记忆模块。3 个门是非线性汇总单元,它们汇集模块内部及外部所有的激活,并且通过附属结点(图中黑色的小圈点)控制核心信元 cell 的激活。在神经网络中,激活函数可以在模型里引入非线性因素,解决线性模型所不能解决的问题。图 2 中,门的激活函数用 f 表示,通常选取对数逻辑曲线,因此门的激活在 0(门关闭)和 1(门开启)之间取值。信元输入、输出的激活函数用 g 和 h 表示,通常选取双曲正切函数 $\tanh$ 或者 ReLU 函数。




图 2 含有 1 个神经元的 LSTM 记忆模块

下面给出循环神经网络 RNN-LSTM 正向传播和反向传播的过程^[12]。在正向传播过程中,输入信息通过输入层经隐含层,逐层处理并传向输出层。修正网络参数则依靠反向传播,从输出层开始逐层求出目标函数对各神经元权值的偏导数,构成目标函数对权值向量的梯度,作为修改权值的依据。误差达到期望值时,目标网络学习结束。

设定 w_{ij} 是从单元 i 到单元 j 的连接的权重,下标 τ, φ 和 ω 分别代表输入门、遗忘门和输出门。 I, H, K 分别是输入层、隐层和输出层的大小, C 表示核心信元 cell 的个数。对于前向传播,输入门的作用值受到上一时刻隐含层输出值、上一时刻所有 cell 状态值的影响。在时间序列 $\{t | t = 1, 2, \dots, T\}$ 下,输入门在时刻 t 的输入 a_t^i 为:

$$a_t^i = \sum_{i=1}^I w_{i\tau} x_i^t + \sum_{h=1}^H w_{h\tau} b_h^{t-1} + \sum_{c=1}^C w_{c\tau} s_c^{t-1} \quad (1)$$

其中, x_i 表示单元 i 关于船舶轨迹数据序列的输入; b_h^{-1} 表示上一时刻中所有不同记忆模块的输出; s_c^{t-1} 表示上一时刻同一模块所有核心信元 c 的状态。

在式(1)中, b 表示单元的非线性映射, 用于激活, 用单元激活函数 $f(\cdot)$ 表示。核心信元 cell 的输入 a_c^t 的激活如式(2)所示:

$$b_c^t = f(a_c^t) \quad (2)$$

初始条件 $b_0 = 0$, 残差 $\delta = 0$ 。单元 j 在 t 时刻的残差为:

$$\delta_j^t = \frac{\partial O}{\partial a_j^t} \quad (3)$$

其中, O 是用于训练的目标函数。

LSTM 记忆模块的遗忘门用来控制上一时刻的隐藏层状态 s_{t-1} , 类似输入门, 其输出为:

$$a_\varphi^t = \sum_{i=1}^I w_{i\varphi} x_i^t + \sum_{h=1}^H w_{h\varphi} b_h^{t-1} + \sum_{c=1}^C w_{c\varphi} s_c^{t-1} \quad (4)$$

同样地, 激活过程如式(5)所示:

$$b_\varphi^t = f(a_\varphi^t) \quad (5)$$

核心信元 cell 的输入、输出变换分别为式(6)和式(7)。

其输入状态由两部分构成, 输入门控制本次特征同时接收上一时刻中不同记忆模块的输出 b_h^{t-1} 作为输入:

$$a_c^t = \sum_{i=1}^I w_{ic} x_i^t + \sum_{h=1}^H w_{hc} b_h^{t-1} \quad (6)$$

遗忘门控制上下文的状态值, 即如果有不被遗忘的上一时刻的状态, 也就是时刻 $t-1$ 的核心信元 cell 的输出 s_c^{t-1} , 则接受它同时用于计算, 最终 cell 的输出为:

$$s_c^t = b_\varphi^t s_c^{t-1} + b_c^t g(a_c^t) \quad (7)$$

其中, 使用的激活函数为 $g(\cdot)$ 。

输出门对应的输入表示为:

$$a_\omega^t = \sum_{i=1}^I w_{i\omega} x_i^t + \sum_{h=1}^H w_{h\omega} b_h^{t-1} + \sum_{c=1}^C w_{c\omega} s_c^t \quad (8)$$

输出门对应的激活如式(9)所示:

$$b_\omega^t = f(a_\omega^t) \quad (9)$$

记忆单元作为整个记忆模块的输出, 受输出门控制, 这个输出也会作为下一时刻整个记忆模块的输入。这里的激活函数为 $h(\cdot)$, 其形式如式(10)所示:

$$b_c^t = b_\omega^t h(s_c^t) \quad (10)$$

对于 LSTM 中的每一个权重, 都需要通过反向传播计算对应的梯度进行更新。RNN-LSTM 的反向传播依然采用 BPTT(Back Propagation Through Time)算法, 首先利用链式法则(Chain Rule)定义辅助变量 ϵ_c^t 和 ϵ_s^t , 分别如式(11)、式(12)所示:

$$\begin{aligned} \epsilon_c^t &= \frac{\partial L}{\partial b_c^t} = \sum_{k=1}^K \frac{\partial L}{\partial a_k^t} \frac{\partial a_k^t}{\partial b_c^t} + \sum_{h=1}^H \frac{\partial L}{\partial a_h^t} \frac{\partial a_h^t}{\partial b_c^t} \\ &= \sum_k w_{ck} \delta_k^t + \sum_h w_{ch} \delta_h^{t+1} \end{aligned} \quad (11)$$

$$\begin{aligned} \epsilon_s^t &= \frac{\partial L}{\partial s_c^t} \\ &= b_\omega^t h'(s_c^t) + b_\varphi^{t+1} \epsilon_s^{t+1} + w_{c\omega} \delta_\omega^t + w_{c\tau} \delta_\tau^{t+1} + w_{c\varphi} \end{aligned} \quad (12)$$

其中, L 为损失函数; s_c^t 表示 L 作用于整个记忆模块输出值的偏导数, 即 L 在整个记忆模块的梯度; ϵ_s^t 表示继续反向传播后, L 作用于核心信元 cell 输出状态值的梯度。

继续反向传播, 损失函数 L 随即先后作用于核心信元 cell 的输入、遗忘门和输入门。它们对于损失函数 L 的作用梯度如式(13)一式(15)所示:

$$\delta_c^t = \frac{\partial L}{\partial a_c^t} = \frac{\partial L}{\partial s_c^t} \frac{\partial s_c^t}{\partial g(a_c^t)} \frac{\partial g(a_c^t)}{\partial a_c^t} = \epsilon_c^t b_c^t g'(a_c^t) \quad (13)$$

$$\begin{aligned} \delta_\varphi^t &= \frac{\partial L}{\partial a_\varphi^t} = \frac{\partial L}{\partial s_\varphi^t} \frac{\partial s_\varphi^t}{\partial g(a_\varphi^t)} \frac{\partial g(a_\varphi^t)}{\partial a_\varphi^t} \\ &= f(a_\varphi^t) \sum_c s_c^{t-1} \epsilon_s^t \end{aligned} \quad (14)$$

$$\begin{aligned} \delta_\tau^t &= \frac{\partial L}{\partial a_\tau^t} = \frac{\partial L}{\partial s_\tau^t} \frac{\partial s_\tau^t}{\partial g(a_\tau^t)} \frac{\partial g(a_\tau^t)}{\partial a_\tau^t} \\ &= f(a_\tau^t) \sum_c g(a_c^{t-1}) \epsilon_s^t \end{aligned} \quad (15)$$

求得局域梯度后, 便可将其用于调节各层权重。利用式(16)更新权重 w_{ij} :

$$\Delta w_{ij}^n = m \Delta w_{ij}^{n-1} - \alpha \frac{\partial L}{\partial w_{ij}^n} \quad (16)$$

其中, $m \Delta w_{ij}^{n-1}$ 为上一次权重的更新值, $m \in [0, 1]$; α 表示学习率; $\frac{\partial L}{\partial w_{ij}^n}$ 表示式(11)一式(15)反向传播中的每一个局域梯度。

如此便可求得迭代一次后更新的各权重。

最后, 重复梯度下降法的迭代步骤减小代价函数, 确定 RNN-LSTM 模型以便将其用于舰船轨迹特征序列的训练仿真。

3 基于 RNN-LSTM 的船舶轨迹预测模型

3.1 船舶航行轨迹预测模型

当前, 各种海上交通管理系统获取表征船舶航行数据的一种重要来源是 AIS 数据, 它包括船舶标识 MMSI(Maritime Mobile Service Identity)、接收时间、经度、纬度、航速、航向角等基本信息。

船舶轨迹预测本质上是运用 RNN-LSTM 循环神经网络的回归问题。将船舶的历史轨迹特征和当前轨迹特征作为网络输入, 将未来某时刻的船舶轨迹特征数据作为网络输出, 通过与真实值相对比训练网络, 建立历史船舶轨迹与未来船舶轨迹特征数据之间的映射关系, 实现对未来船舶轨迹特征的推算和预测。对于单艘船舶, 其在 t 时刻的轨迹特征 $Y(t)$ 可表示为:

$$Y(t) = \{v, c, lng, lat, itv\} \quad (17)$$

其中, v, c, lng, lat, itv 分别表示船舶在 t 时刻的 5 项特征: 速度、航向、经度、纬度和时间间隔标识。时间间隔标识用于突破模型只能选取固定时间间隔的数据来进行训练和预测的瓶颈, 可扩展到满足预测不同时间间隔的船舶轨迹需求。

为实现船舶轨迹预测, 将连续 n 个时刻的船舶航行轨迹特征数据 $Y(t-n+1), \dots, Y(t-1)$ 和 $Y(t)$ 作为网络输入, 将 $t+1$ 时刻的船舶航行轨迹特征数据 $Y(t+1)$ 作为输出, 其中 n 对应着输入层的 $step$ 大小。据此, 船舶航行轨迹预测模型的表达式为:

$$Y(t+1) = f(\{Y(t-n+1), \dots, Y(t-1), Y(t)\}) \quad (18)$$

3.2 RNN-LSTM 循环神经网络参数分析

3.2.1 数据归一化处理

为减小输入数据间数量级差别较大引起的网络预测误差, 对输入数据作归一化处理, 归一化数据的取值范围为 $[0, 1]$ 。采用离差标准化方法(Min-Max Normalization)进行归一化, 转换式为:

$$X^* = \frac{X - \min}{\max - \min} \quad (19)$$

其中, $\max$ 为样本数据的最大值, $\min$ 为样本数据的最小值, X 为原始训练数据; X^* 为归一化数据。经过归一化处理的数据可以消除不同量纲和数据取值范围的影响, 但仍会保留原来

数据中存在的关系。运用 RNN 神经网络对船舶航行轨迹特征进行预测之后,还需对预测的结果按式(19)进行反归一化处理,使预测得到的数据符合实际范围和意义。

3.2.2 输入层 *step* 步数的选择

神经网络所处理的单位通常是向量,而 RNN-LSTM 神经网络的输入加入了时序 *step* 的概念,处理单位从向量扩充到了张量,即增加了一阶 *time_step*。可以将 RNN 模型的横向操作视为累积已发生的事,而 LSTM 的记忆神经元会选择记忆或者忘记所积累的信息来预测某个时刻的输出。在本文实验中,可以选择输入 3~6 个时刻的历史船舶轨迹特征,即对应着输入层 *step* 的步数选择为 3~6。不同的 *step* 将对网络的精度、隐藏层神经元个数的选择以及实验的精度有不同程度的影响。

3.2.3 LSTM 层记忆神经元个数选择

神经网络的输入层和输出层神经元个数由训练数据的特征决定。在训练中,LSTM 层神经元(记忆模块)个数对网络的预测精度有较大影响。若节点数目设置得太少,则神经网络不能很好地拟合且存在学习回归问题,训练过程中需增加训练次数,网络精度低;反之,若节点数目过多,则会导致训练时间增加和过拟合,从而影响性能。对于隐藏层节点数目的确定,通常采用经验公式确定估值,以此作为初始值,通过实验进行试凑,选取训练之后识别误差最小的值作为隐藏层节点数。根据文献[13],计算隐含层节点数 *M* 的经验公式为:

$$M=\sqrt{(n+m)}+a \tag{20}$$

其中,*m* 和 *n* 分别为输入层和输出层的节点数;*a* 为[0,10]内的常数。

4 模型验证及分析

4.1 实验环境与数据

本文实验的硬件条件是:CPU 为 intel(R) Xeon(R) E5-1620,主频为 3.6 GHz,内存为 8 GB。实验平台基于深度学习框架 Tensorflow 1.1 版本的上层框架 Keras,实验编程语言使用 Python3.5。

原始实验数据均来源于广州港水域内船舶 AIS 信息,接收解码后存储在 MySQL 数据库中。按模型的输入需求设计 MMSI, TIME, LONGITUDE, LATITUDE, SOG 和 COG 等字段信息。

4.2 实验方案及评价指标

选取 200 组船舶 AIS 数据作为原始数据(180 组作为训练数据,其余 20 组作为测试数据),AIS 数据的处理如 3.1 节、3.2 节所述,对同一船舶的一组基于时间序列的数据归一化后作为单个目标的模型输入,其数据格式为二维矩阵。将时间序列的具体时刻点的数目作为实验的一个重要参数,其同时也会影响轨迹预测模型 LSTM 层的神经元个数。

由 3.1 节可知,实验所设计的 RNN-LSTM 网络为 3 层,分别为输入层、LSTM 隐藏层、输出层。其中输入层和隐藏层的规模依赖于 *step* 的选取,即目标船只的训练时刻点数目不同,网络规模不同。

采用均方误差(MSE)和最大绝对误差(Maxerr)来评估船舶轨迹预测模型。均方误差是指参数观测值 *observed* 与参数真值 *predicted* 之差的平方的期望值,MSE 的数学表达如式(21)所示。最大绝对误差表示一组测试数据中,预测偏离实际的最大误差。Maxerr 的数学表达式如式(22)所示。两

种误差指标的值越小,说明轨迹预测模型描述实验数据的精确度越高。

$$MSE=\frac{1}{N}\sum_{i=1}^N (observed_i - predicted_i)^2 \tag{21}$$

其中,*N* 表示样本数量。

$$Maxerr=\max|\frac{observed_i - predicted_i}{observed_i}| \tag{22}$$

4.3 实验结果及分析

在满足高准确度的预测效果上,实验结果分析可以分为 3 部分:1)与优化过的 BP 神经网络的预测效果以及性能对比;2)对于本文提出的 RNN-LSTM 模型,探讨不同参数对船舶航迹预测性能的影响;3)分析 RNN-LSTM 模型对输出的 5 项特征中的单个特征的预测效果。

4.3.1 RNN-LSTM 模型与 BP 神经网络模型的对比

传统 BP 神经网络受限于本身的反向传播算法的原理,权值和阈值的调整过程比较随意,收敛速度慢,无法解决训练落入局部最小点的问题。遗传算法是一种模拟生物进化的算法,它经过若干代遗传、交叉变异和选择,达到 BP 神经网络初始权值的一个较优解,然后继续通过反向传播算法在此基础上修正 BP 网络参数以达到全局最优解。因此,结合遗传算法可以克服原有 BP 网络的缺陷^[14]。本文选取经过遗传算法优化过的 GA-BP 神经网络作为参考对比。本文设计 BP 神经网络为 3 层,输入层长度为 3 个时刻,即长度为 15 的矢量,对应前 3 次实测的航迹;隐藏层的节点数为 12 个;输出节点数为 1 个时刻,即长度为 5 的矢量,表示下一个时间间隔内的航迹特征。隐藏层的激活函数设计为双曲正切函数。设置目标误差为 10^{-6} ,学习率为 0.06,最大训练次数为 3000。遗传算法部分参数的选取如下:种群规模设为 90,交叉概率设为 0.25,变异概率设为 0.1,进化代数数为 150 代。

RNN-LSTM 网络模型中输入层 *step* 选为 3,表示用于训练和测试的数据输入规模为 3×5 的矩阵,对应前 3 次实测的航迹;每个航迹点的数据是长度为 5 的向量,对应着输入点的航迹特征。LSTM 层节点数为 12,输出节点数为 1 个时刻,即长度为 5 的矢量,为下一个时间间隔内的航迹特征。设置目标误差为 10^{-6} ,学习率为 0.06,最大训练次数为 3000。

RNN-LSTM 模型与优化的 BP 模型各自完成训练后,输入相同的测试数据,均输入相同格式的 3 个时刻 (*t*−2, *t*−1, *t*) 的船舶轨迹特征,数据格式如式(17)所示,并在模型训练后以递归方式连续预测 5 个时刻,查看两个模型预测的均方误差变化,结果如图 3 所示。




图 3 模型均方误差曲线图

由图 3 可以看出,在测试集上递归测试的第一次,即预测的第一个时刻上,BP 神经网络预测模型测试的均方误差就已大于 RNN-LSTM 模型,随着连续预测多个时刻的输出,BP 神经网络预测模型的均方误差曲线陡峭增大,而 LSTM 模型

的均方误差曲线虽也由于时序的积累呈正增长,但增长速度却远远小于前者。由此可以分析出,LSTM 模型方法较浅层次的 BP 神经网络模型有更好的预测精度,均方误差更低。且 BP 神经网络的连续多个时刻的预测性能也不尽如人意。这也充分说明了 LSTM 模型具有对时间序列本身强化记忆能力的特点,其轨迹的趋势是基于之前时刻序列的综合作用的结果,而浅层次的 BP 神经网络则没有此记忆特点。除此之外,浅层次 BP 神经网络解决此问题多采用选取固定时间间隔且间隔时间很小的序列进行训练和测试,本身受限程度也更大,如果时间间隔选取较大,则 BP 神经网络的预测性能将会随着递归预测而大幅度下降。而 RNN-LSTM 模型在考虑船舶轨迹的预测问题时加入了一个时间维度,使 RNN-LSTM 模型也能学习到关于不同时间间隔的船舶轨迹的运动趋势,更契合船舶预测回归问题。

下面讨论 BP 神经网络和 RNN-LSTM 两个模型具体的预测特征误差的统计结果,实验精度如表 1 所列。其中包括所有的单个属性:经纬度、航向、航速、预测时间间隔。统计结果用均方误差和最大绝对误差两种评价指标给出。

表 1 两个模型的预测精度

模型	特征名	最大绝对误差	均方误差
BP	经度	7.6734e-004	5.7354e-005
	纬度	4.7275e-004	8.0496e-005
	航向	2.6465e-003	7.8567e-004
	航速	8.0497e-005	6.9621e-005
	时间间隔	2.2435e-003	7.0023e-004
LSTM	经度	5.5542e-004	5.3538e-005
	纬度	5.7834e-004	6.0184e-005
	航向	2.0453e-003	6.7268e-004
	航速	7.1733e-005	5.3583e-005
	时间间隔	1.9859e-003	6.2564e-004

由表 1 可看出,两种模型预测误差虽然均在可接受的范围,但 LSTM 模型对海上船舶的轨迹预测误差均明显减少,其预测的精度更高,说明利用深度学习技术的 LSTM 模型更能满足船舶航行轨迹监控的需求。

4.3.2 模型参数分析

对训练数据作离差归一化处理,设定不同隐含层神经元节点,将 $t-4,t-3,t-2,t-1$ 和 t 连续 5 个时刻的船舶行为表征数据作为网络输入,将 $t+1$ 时刻的船舶行为表征数据 $Y(t+1)$ 作为输出,以此训练 RNN-LSTM 神经网络的各项参数。在实验中,可设置不同的 LSTM 隐含层神经元节点数,通过比较神经网络均方误差值,选择误差最小的记忆神经元个数作为参数,实验过程中不同隐含层神经元节点下神经网络的均方误差如图 4 所示。




图 4 LSTM 神经元均方误差分布

当 LSTM 层神经元节点数为 12 时神经网络的均方误差最小,表示对应于当前规模的数据输入($step$ 为 5),训练效果

在测试集上已最优。而当神经元个数为 8 时,虽也暂时出现训练效果较好的情况,但个数为 7 和 9 时,训练效果很差,因此选取个数为 8 的训练效果良好仅是在当前测试集上的偶尔表现。综上,此时神经网络的最佳隐含层 LSTM 层的神经元节点数目设置为 12。

输入层不同的 $step$ 对神经网络模型的预测精度也有影响,在将 $step$ 从 3 个时刻依次扩充到 7 个时刻的过程中,隐含层 LSTM 层神经元选取个数都为同一 $step$ 下的最优值。实验过程中不同 $step$ 对应的神经网络的均方误差如图 5 所示。




图 5 LSTM 输入时序 $step$ 的均方误差分布

如图 5 所示,输入层维度 $step$ (即输入多个时刻)为 X 轴(分别为 3,4,5,6,7),均方误差 MSE 为 Y 轴。由于输入的维度越大,模型越复杂,拟合程度越高也越可能过拟合,因此在 X 为 6 时均方误差最小(此时 LSTM 层记忆神经元最优数量为 14),大致为 0.0009。

4.3.3 单个特征的预测效果

为定量表达预测轨迹与期望轨迹之间的误差,在此分析单个特征的预测效果。根据确定的 RNN-LSTM 最佳网络结构及训练好的神经网络参数,将 3 个时刻的船舶行为数据作为初始输入,通过递归的方法逐步预测接下来的 4 个点的船舶轨迹,得到的预测值及误差结果如图 6 所示。以 MMSI 为 357051000 的船只为例,从图 6 可看出,在经纬度的预测上,预测的轨迹值(黑色折线 4 个点)与期望轨迹值(灰色折线)近乎重叠。




图 6 经纬度预测

表 2 为各项单一特征在测试集上单次预测的结果统计。由表 2 可看出,仅在时间间隔较大(比如 5 min 以上)时,预测的下一个特征时间偏差会较大(18 s),而在平均情况或短时间间隔下,船舶轨迹的经度、纬度、航向、航速以及下一个轨迹点的时间标识等船舶轨迹特征值和预测误差均在可接受的范围内,预测结果的精度满足船舶航行轨迹监控和航海实践的需求。

表 2 单个特征值的预测结果

特征	测试最大误差	平均误差
速度 SOG/(节/小时)	0.2	0.12
航向角 COG/(°)	1	0.35
经度 longitude/(°)	0.1068	0.0623
纬度 latitude/(°)	0.0872	0.0476
时间间隔 interval/s	18	3.8

结束语 通过对船舶航行轨迹预测进行研究,结合船舶 AIS 信息的特点,构建基于 AIS 信息的船舶航行轨迹表达模型,提出结合 AIS 信息和 RNN-LSTM 模型的船舶航行轨迹预测方法。运用提出的方法对目标水域内上百条船舶航行轨迹数据进行实验,利用训练好的 RNN-LSTM 模型对后续船舶轨迹特征进行预测。通过对预测值和原有的真实航行数据进行误差对比分析,得到随时间发展变化,该 RNN-LSTM 模型能对船舶的经度、纬度、航速及航向等船舶轨迹特征值进行有效的学习和辨识,从而对未来船舶航行轨迹进行精确、实时的预测。目前在船舶轨迹的预测上,基于时间序列的深度学习 RNN 模型在实际使用中还存在诸多不足,例如连续预测多个时刻的轨迹点还需要递归形式上的多次预测,因此下一步工作将深入研究序列预测(sequence to sequence),即可以在此基础上考虑使用 RNN 的自动编码解码器(AutoEncoder)等模型。

参 考 文 献

[1] 徐铁,蔡奉君,胡勤友,等. 基于卡尔曼滤波算法船舶 AIS 轨迹估计研究[J]. 现代电子技术,2014(5):97-100.

[2] 赵帅兵,唐诚,梁山,等. 基于改进卡尔曼滤波的控制河段船舶航迹预测[J]. 计算机应用,2012,32(11):3247-3250.

[3] PERERA L P, OLIVEIRA P, SOARES C G. Maritime Traffic Monitoring Based on Vessel Detection, Tracking, State Estimation, and Trajectory Prediction[J]. IEEE Transactions on Intelligent Transportation Systems, 2012, 13(3): 1188-1200.

[7] MOSKEWICZ M W, MADIAN C F, ZHAO Y, et al. Chaff: Engineering an Efficient SAT Solver[C]//Proceedings of the 38th Design Automation Conference. United States: IEEE Press, 2005:530-535.

[8] LIANG J H, GANESH V, ZULKOSKI E, et al. Understanding VSIDS Branching Heuristics in Conflict-Driven Clause-Learning SAT Solvers[C]//Proceedings of the 11th International Haifa Verification Conference on Verification and Testing of Hardware and Software. Haifa (Israel): Springer International Publishing, 2015:225-241.

[9] DERSHOWITZ N, HANNA Z, NADEL A. A Clause-based Heuristic for SAT Solvers[C]//Proceedings of the 8th International Conference on Theory and Applications of Satisfiability Testing. Intel Corporation: Springer-Verlag, 2005:46-60.

[10] BIERE A, FROHLICH A. Evaluating CDCL Variable Scoring Schemes[C]//Proceedings of the 18th International Conference on Theory and Applications of Satisfiability Testing. Bioinformatics: Springer International Publishing, 2015:405-422.

[11] CHEN J. A Dynamic Phase Selection Strategy for Satisfiability Solvers [J]. Computer Science, 2012, 13(5):208-213.

[12] CHEN J. Phase Selection Heuristics for Satisfiability Solvers [J]. Computer Science, 2011, 36(6):312-320.

[4] 王艳锋,李红祥. 桥区水域失控船舶的航迹预测[J]. 武汉船舶职业技术学院学报, 2011, 10(4):36-38.

[5] 刘锡铃,阮群生,龚子强. 船舶航行 GPS 定位轨迹的新预测模型[J]. 江南大学学报(自然科学版), 2014, 13(6):686-692.

[6] 茅晨昊,潘晨,尹波,等. 基于高斯过程回归的船舶航行轨迹预测[J]. 科技创新与应用, 2017(31):28-29.

[7] TONG X, CHEN X, SANG L, et al. Vessel trajectory prediction in curving channel of inland river[C]//International Conference on Transportation Information and Safety. IEEE, 2015: 706-714.

[8] 徐婷婷,柳晓鸣,杨鑫. 基于 BP 神经网络的船舶航迹实时预测[J]. 大连海事大学学报, 2012, 38(1):9-11.

[9] 甄荣,金永兴,胡勤友,等. 基于 AIS 信息和 BP 神经网络的船舶航行行为预测[J]. 中国航海, 2017, 40(2):6-10.

[10] 孙志远,鲁成祥,史忠植,等. 深度学习研究与进展[J]. 计算机科学, 2016, 43(2):1-8.

[11] GRAVES A, MOHAMED A R, HINTON G. Speech recognition with deep recurrent neural networks[C]//IEEE International Conference on Acoustics, Speech and Signal Processing. IEEE, 2013:6645-6649.

[12] GRAVES A. Supervised Sequence Labelling with Recurrent Neural Networks[M]. Springer Berlin Heidelberg, 2012.

[13] 张庆庆,贺兴时. BP 神经网络结点数选取的改进方法及其应用[J]. 西安工程大学学报, 2008, 22(4):502-505.

[14] 谭伟,陆百川,黄美灵. 神经网络结合遗传算法用于航迹预测[J]. 重庆交通大学学报(自然科学版), 2010, 29(1):147-150.

[13] CHEN J. A Bit-Encoding Phase Selection Strategy for Satisfiability Solvers[C]//Proceedings of the 11th Annual Conference on Theory and Applications of Models of Computation. New York: Springer Verlag, 2014:158-167.

[14] PIPATSRISAWAT K, DARWICHE A. A Lightweight Component Caching Scheme for Satisfiability Solvers[C]//Proceedings of the 10th International Conference on Theory and Applications of Satisfiability Testing. Lisbon Portugal: Springer Verlag, 2007:294-299.

[15] 刘志明,吴明芬,许勇. 一种基于遗传算法的权重的确定方法[J]. 五邑大学学报(自然科学版), 2006, 20(3):45-48.

[16] LIANG J H, GANESH V, POUPART P, et al. Exponential Recency Weighted Average Branching Heuristic for SAT Solvers [C]//Proceedings of the 30th AAAI Conference on Artificial Intelligence. Infosys: AAAI Press, 2016:3434-3440.

[17] SILVA J, MARQUES O P. The Impact of Branching Heuristics in Propositional Satisfiability Algorithms[C]//Proceedings of the 9th Portuguese Conference on Artificial Intelligence. Berlin Heidelberg: Springer Verlag, 1999:62-74.

[18] LIU Y, WANG J, XU C, et al. An Effective Branching Strategy Based on Structural Relationship among Multiple Forbidden Induced Subgraphs [J]. Journal of Combinatorial Optimization, 2015, 29(1):257-275.