

基于改进 Seq2Seq 的短时 AIS 轨迹序列预测模型



游 兰¹ 韩雪薇¹ 何正伟^{2,3,4} 肖丝雨¹ 何 渡⁵ 潘筱萌¹

1 湖北大学计算机与信息工程学院 武汉 430062

2 武汉理工大学航运学院 武汉 430063

3 武汉理工大学内河航运技术湖北省重点实验室 武汉 430063

4 国家水运安全工程技术研究中心 武汉 430063

5 湖北省科技信息研究院 武汉 430071

(yoyo@hubu.edu.cn)

摘 要 采用深度学习进行船舶轨迹序列预测对于智能航运具有重要意义。船舶自动识别系统(Automatic Identification System, AIS)蕴藏着大量船舶轨迹特征,基于 AIS 数据预测船舶轨迹是近年智能航运研究的热点之一。文中提出了一种基于改进 Seq2Seq 的短时 AIS 轨迹序列预测模型,该模型使用门控循环单元网络将历史时空序列编码为一个上下文向量,用以保留轨迹空间点间的时序关系,同时缓解梯度下降的问题。通过使用门控循环单元网络作为解码器来预测船舶轨迹的时空序列。实验采用了大规模真实船舶 AIS 数据,选取两类典型河段(重庆弯曲河段和武汉顺直河段)为实验区域,以评估和验证模型的有效性和适用性。实验证明,该模型能够有效提高短时轨迹序列预测的准确性和效率,为智能航船碰撞预警提供了一种有效可行的方法。

关键词: 轨迹预测;序列到序列模型;循环神经网络;船舶自动识别系统;时空数据挖掘

中图法分类号 TP183

Improved Sequence-to-Sequence Model for Short-term Vessel Trajectory Prediction Using AIS Data Streams

YOU Lan¹, HAN Xue-wei¹, HE Zheng-wei^{2,3,4}, XIAO Si-yu¹, HE Du⁵ and PAN Xiao-meng¹

1 School of Computer Science & Information Engineering, Hubei University, Wuhan 430062, China

2 School of Navigation, Wuhan University of Technology, Wuhan 430063, China

3 Hubei Key Laboratory of Inland Shipping Technology, Wuhan University of Technology, Wuhan 430063, China

4 National Engineering Research Center for Water Transportation Safety, Wuhan 430063, China

5 Hubei Engineering Research Center for Education Information, Wuhan 430071, China

Abstract Using deep learning to predict the vessel trajectory is of great significance for the intelligent shipping. AIS (Automatic Identification System) data contain a huge amount of information about vessel trajectory features. The prediction of ship trajectories based on AIS data becomes one of the research hotspots in the intelligent shipping realm. In this paper, an improved sequence-to-sequence model using AIS data streams is proposed for the short-term vessel trajectory prediction. The proposed model utilizes a GRU network to encode the historical spatio-temporal sequence into a context vector, which not only preserves the sequential relationship among those trail points, but also is helpful for the alleviation of the gradient descent problem. Meanwhile, a GRU network is used as a decoder to output target trail points sequence. In this paper, a large scale of real AIS data are used in the experiments. The Chongqing section and the Wuhan section of the Yangzi River are selected as typical experimental areas, which is for the evaluation of the validity and applicability of the model. Experimental results show that the proposed model improves the

来稿日期:2019-08-24 返修日期:2019-10-28 本文已加入开放科学计划(OSID),请扫描上方二维码获取补充信息。

基金项目:湖北省自然科学基金面上项目(2019CFB757);国家水运安全工程技术研究中心开放基金(A2019011);内河航运技术湖北省重点实验室基金(NHHY2017001);湖北省教育厅科学研究计划重点项目(D20161001);中央高校基本科研业务费专项资金(2019III050GX, 2019III007GX)

This work was supported by the Hubei Province Natural Science Foundation Item (2019CFB757), Open Fund of National Engineering Research Center for Water Transport Safety (A2019011), Fund of Hubei Key Laboratory of Inland Shipping Technology (NHHY2017001), Key Project of Scientific Research Plan of Hubei Ministry of Education (D20161001) and Fundamental Research Funds for the Central Universities (2019III050GX, 2019III007GX).

通信作者:何正伟(www.hzw@whut.edu.cn)

accuracy and efficiency of short-term ship trajectory prediction. The proposed model provides an effective solution for the intelligent shipping warning in the future.

Keywords Trajectory prediction, Sequence-to-sequence model, Recurrent neural network, Automatic identification system, Spatio-temporal data mining

1 引言

近年来,水上交通量显著增加,导致航道拥堵,从而提高了船舶碰撞的风险,安全保障成为船舶航行中的关键问题^[1]。船舶自动识别系统作为一种新型导航系统,开辟了水上交通监控的新纪元。AIS 提供了大量的近实时水上监控数据用于实现更高水平的水上交通状况感知,AIS 发送的信息包括水上移动通信业务标识码(Maritime Mobile Service Identify, MMSI)、船舶位置信息、船舶的对地航向和航速等^[2]。目前,船舶避碰利用 ARPA 雷达与船载 AIS 等设备作为辅助,航行态势的分析和避碰决策的制定依赖于船员经验。由于船员疲劳和初级船员缺乏经验等原因,仅依靠人工的监督和决策常常会影响航行安全。大规模的实时和历史 AIS 数据蕴含丰富的船舶驾驶规则和航运经验,对有效利用大规模 AIS 数据进行船舶轨迹预测从而达到船舶避碰的目的具有重要的现实意义。

相关学者已展开大量工作,从 AIS 数据中提取有价值的信息用于船舶轨迹预测。基于各类方法的基本实施机制,船舶轨迹的建模和预测方法可分为两类:基于物理运动模型的方法和基于学习模型的方法^[3]。

(1)基于物理运动模型的方法。早期的船舶轨迹预测依赖于船舶运动的物理模型,包括曲线模型^[4]、横向模型^[5]和船舶模型^[6]。基于物理模型的方法通过一组数学方程对船舶运动建模,该数学方程考虑了所有可能的影响因素(质量、大小、惯性和质心等)并使用物理定律计算运动特征。但是这种方法的准确性依赖于理想的环境和状态假设,这在现实世界的船舶轨迹预测任务中难以实现。

(2)基于学习模型的方法。学习模型作为一种更复杂的方法可以模拟船舶运动,并从历史 AIS 数据中学习轨迹特征,从而隐含地集成了所有可能的影响因素。

卡尔曼滤波器使用目标的动态信息,来尝试去除信息中噪声的影响并获得对目标位置的良好估计,该估计可以是对未来位置的估计(预测)^[7]。Lokukaluge 和 Carlos 通过假设与白高斯噪声相关联的系统状态和测量模型,提出了扩展卡尔曼滤波器作为自适应滤波算法,用于估计船舶轨迹的位置、速度和加速度^[8]。(扩展)卡尔曼滤波器的优点在于它是一种经过充分研究的经典方法。然而,扩展卡尔曼滤波器通常不是全局最优的。

由于深度学习有着强大的拟合复杂功能的能力,因此部分学者利用深度学习来预测船舶轨迹。Quan 等采用 RNN-LSTM 架构的深度学习模型,结合实时性强、内容丰富的海量船舶时空数据来解决船舶轨迹预测问题,实验结果显示其船舶轨迹预测效果优于 GA-BP 神经网络。但该方法旨在预测未来某个时间的轨迹点,需要采用递归的方式预测一段轨迹^[9]。Nguyen 等先将 AIS 轨迹数据转化为空间网格数据来

解决传输数据的不同时间间隔问题,将研究重点从时间相关的船舶轨迹的坐标点变化转移到船舶轨迹在网格上的变化;同时结合序列到序列模型(Sequence-to-Sequence, Seq2Seq)对历史网格轨迹点进行编码,再解码输出预测轨迹点。其研究的是较长时间的轨迹预测^[10],未能实现短时轨迹预测。

船舶轨迹预测主要用于船舶碰撞的预警,如果两个预测轨迹有交叉,则碰撞风险非常大并且可能发生碰撞,此类轨迹预测任务的时间粒度在 15 min 以内。因此文中利用大规模 AIS 数据预测未来 5~15 min 内的船舶轨迹用于船舶避碰。在预测任务中有两个复杂的因素非常具有挑战性:AIS 数据的不规则时间采样和轨迹序列预测的精度。为了解决这些问题,本文提出了基于改进 Seq2Seq 的短时 AIS 轨迹序列预测模型。本文的主要贡献如下:1)提出一种基于时空数据的 Seq2Seq 模型,能够准确预测短时内的船舶轨迹序列;2)使用基于一阶梯度的随机目标函数 Adam 算法和 dropout 机制来优化 Seq2Seq 模型的训练过程;3)通过重采样解决 AIS 轨迹点的时间间隔不均匀问题,并利用相对时空特征(包括时间间隔和相对位置)替代传统方法中的绝对时空特征(包括时间戳和经纬度),以优化模型的数据结构。

本文第 2 节介绍相关背景知识;第 3 节重点描述基于 Seq2Seq 的船舶 AIS 轨迹即时预测模型;第 4 节描述和分析对比实验及结果;最后给出工作总结与展望。

2 背景知识

轨迹预测是一个热点问题,已经在各个领域进行了不同的尝试,包括预测人类^[11]、飞行器^[12]和车辆^[13]的轨迹。轨迹是一种特殊的时间序列,除了时间维度之外还需要关注空间纬度^[14]。前人的工作经常应用马尔可夫链和整合移动平均自回归模型。随着深度学习的发展,循环神经网络(Recurrent Neural Network, RNN)和变分自动编码器(Variational Auto-Encoder, VAE)等方法在轨迹预测任务中也具有良好的泛化性能。本节简要介绍轨迹数据模式和 Seq2Seq 模型。

2.1 轨迹模式

轨迹表示随着时间的推移,物体在空间中移动的路径。轨迹数据通常通过在移动物体上安装传感器来收集,该传感器周期性地传输关于物体位置的信息,如 AIS 周期性地传输船舶位置信息。基于不同的轨迹数据挖掘任务,轨迹模式一般分为 4 种:共同移动模式、轨迹聚类、轨迹挖掘序列模式和轨迹挖掘周期模式^[15]。其中,轨迹挖掘序列模式表示移动目标在相似时间间隔内行进的位置点序列,这种模式常用于预测下一个位置,包括自由空间中的轨迹序列模式和道路网格中的轨迹序列模式。

2.1.1 自由空间中的轨迹序列模式

自由空间中的轨迹序列模式一般表示为时空序列(Spatio-Temporal sequence, ST-sequence),时空序列是一段由多

个元组组成的序列,其表达式如下:

$$S = \langle (x_0, y_0, t_0), \dots, (x_k, y_k, t_k) \rangle \quad (1)$$

其中, $t_i (i=0, \dots, k)$ 表示时间戳, 且 $\forall_{0 \leq i < k} t_i < t_{i+1}$, (x_i, y_i) 表示位置。

2.1.2 道路网格中的轨迹序列模式

当轨迹序列模式中的位置信息需用道路网格表示时, 首先使用地图匹配算法将每个轨迹映射到道路网格上, 然后轨迹由一系列路段 ID 表示, 可将其视为字符串, 如图 1 所示, 轨迹 T_r 用字符串表示为 $r_1 \rightarrow r_2 \rightarrow r_6$ 。




图 1 空间网格

Fig. 1 Spatial grid

2.2 Seq2Seq 模型

近年来, 序列到序列模型 (Seq2Seq) 被广泛用于处理可变长度输入和输出序列的相关任务, 包括语音识别和机器翻译等, 其核心思想是使用循环神经网络将可变长度的输入序列映射到可变长度的输出序列。Cho 等提出一种新的神经网络结构——RNN 编码器解码器模型 (RNN Encoder-Decoder)^[16], 该模型由两个循环神经网络组成, 模型结构如图 2 所示。随后, Google 团队提出了与 RNN Encoder-Decoder 结构类似的 Sequence to Sequence 模型用于机器翻译^[17]。上述研究提出了相似的解决思路, Seq2Seq 模型也由此产生。




图 2 RNN Encoder-Decoder 模型

Fig. 2 RNN Encoder-Decoder

如图 2 所示, Seq2Seq 模型由编码器和解码器两个部分组成。编码器是一个循环神经网络, 它按顺序读入输入序列 $\{x_1, x_2, x_3, \dots, x_t\}$ 的每个符号, 在读入每个符号时, 隐藏状态也会相应变化, 最后形成语义向量 c 作为解码器的输入。解码器也是一个循环神经网络, 该循环神经网络在给定隐藏状态条件下, 通过预测下一个符号来生成输出序列 $\{y_1, y_2, \dots, y_{t'}\}$, 不同于传统 RNN 中隐藏状态的计算, 解码器中的隐藏状态计算还要考虑语义向量 c , 其计算式如下:

$$h_t = f(h_{t-1}, y_{t-1}, c) \quad (2)$$

Seq2Seq 模型的两个部分联合训练的目标是使条件似然函数最大化:

$$\max_{\theta} \frac{1}{N} \sum_{n=1}^N \log p_{\theta}(y_n | x_n) \quad (3)$$

其中, θ 为模型参数, N 为训练集的样本个数。

3 基于改进 Seq2Seq 的短时 AIS 轨迹序列预测模型

3.1 AIS 数据的预处理

3.1.1 原始数据的轨迹分割

AIS 播发和接收信息的方式是自动连续的, 原始 AIS 数据流按 AIS 报文的接收时间排列。故数据预处理要将原始的 AIS 数据流分割成船舶轨迹, 其具体过程分为两步:

(1) 分离不同船只的轨迹数据。MMSI 号是船舶的唯一标识, 因此利用 AIS 数据的 MMSI 号信息来分离不同船只的船舶轨迹。

(2) 分离同一船只的轨迹数据。在通航密集水域, 由于船舶数量多且受 AIS 工作机制的制约, 会导致网络通信阻塞, AIS 无法预约或侦听到空闲时隙, 从而导致发送 AIS 信息延迟, 同一船只的轨迹数据上会出现较大的时间间隔。因此, 原始的轨迹数据需要利用时间戳信息进行分离, 得到连续的船舶轨迹数据。

3.1.2 输入轨迹的序列结构

模型的输入为船舶的历史轨迹序列, 输出为未来时间段内的船舶轨迹序列。其中船舶轨迹 V 是 T 个时刻轨迹点观测状态向量 v_i 的时间序列:

$$V = \{v_1, v_2, \dots, v_t\} \quad (4)$$

t 时刻的状态向量 v_t 是从 AIS 数据中分离出的特征信息, 轨迹特征包括位置特征、速度和航向等, 表示为:

$$v_t = [x_t, y_t, \overline{x_t}, \overline{y_t}, z_t]^T \quad (5)$$

其中, x_t 和 y_t 表示相对经度和相对纬度, $\overline{x_t}$ 表示对地航速 (Speed Over Ground, SOG), $\overline{y_t}$ 表示的对地航向 (Course Over Ground, COG), z_t 表示时间间隔。

3.1.3 归一化

RNNs 在训练过程中使用梯度下降的方法求解最优化问题, 因此本文对输入数据做归一化处理, 将输入数据映射到 $[0, 1]$ 范围内, 从而加快梯度下降的求解速度, 提升模型的收敛速度。使用离差标准化 (Min-Max Normalization) 方法对对地航向、对地航速和时间间隔 3 个轨迹点特征进行归一化处理, 具体公式为:

$$X^* = \frac{X - \min}{\max - \min} \quad (6)$$

其中, $\max$ 为样本数据中的最大值, $\min$ 为样本数据中的最小值, X 为原始数据, Y 为归一化后的数据。

3.2 改进 Seq2Seq 轨迹序列预测模型

改进 Seq2Seq 轨迹序列预测模型结合了时空序列数据和 Seq2Seq 模型的特点, 如图 3 所示, 基于 Seq2Seq 的船舶 AIS 轨迹即时预测模型主要由两个 RNNs 模块组成。该模型可以看作对历史船舶 AIS 轨迹输入数据编码并获取轨迹特征之后对特征解码, 以助于预测未来的船舶 AIS 轨迹。该模型的目标在于估算条件概率 $p(y_1, \dots, y_m | x_1, \dots, x_n)$, 其中 $x_1, \dots, x_n$ 表示输入的历史轨迹序列, $y_1, \dots, y_m$ 表示输出的预测轨迹序列。以武汉顺直河段的 AIS 轨迹数据为例, 具体分析模型中各个模块的作用及处理数据时各模块之间的关联性。




图 3 基于 Seq2Seq 的船舶 AIS 轨迹即时预测模型

Fig. 3 Seq2Seq neural network model for vessel real-time trajectory prediction

3.2.1 编码器

编码器部分采用由单层 GRU 单元组成的循环神经网络,来获取轨迹点序列的上下文特征信息,并将船舶轨迹输入序列(历史轨迹)编码为抽象上下文向量 c 其公式如下:

$$c=f(h_1,\cdots,h_n)$$
 (7)

其中, $h_1,\cdots,h_n$ 表示 RNNs 中每一步的隐藏状态值,上下文向量 c 直接由最后一个隐藏状态 h_n 赋值。

3.2.2 解码器

解码器部分使用由单层 GRU 单元组成的循环神经网络。传统的 Seq2Seq 用于机器翻译,解码器中的初始输入值是序列起始符(BOS)。模型从当前位置开始预测未来轨迹,故使用 x_n 作为解码器部分的初始输入值。由图 4 可以看出,解码器部分 RNNs 利用上下文向量 c 和初始输入值 x_n 来生成预测的船舶轨迹序列,即解码器利用编码器提取的轨迹特征和当前轨迹点位置来预测船舶的未来轨迹。第一个隐藏状态 h_1 的计算式如下:

$$h_1=f(c,x_n)$$
 (8)

船舶预测轨迹点序列是随着编码器的时间步一个接一个生成的。每一个 RNN 单元的输入由上一个单元隐藏层的输出和上一个单元的输出组成,其表达式如下:

$$y_t=f(h_{t-1},y_{t-1})$$
 (9)

3.3 模型训练

基于 Seq2Seq 的船舶 AIS 轨迹即时预测模型是一个平滑的、相互连接的模型,并且模型中的编码器和解码器部分都是可微的,即模型中可训练的参数都能使用梯度下降的方法进行更新。本文使用自适应学习率优化算法 Adam 对网络参数进行更新。

采用均方根误差(Root Mean Square Error, RMSE)来评估船舶轨迹预测模型,均方根误差公式如下:

$$loss=\sqrt{\frac{\sum_{i=1}^n(\bar{y}_i-y_i)^2}{n}}$$
 (10)

其中, $\bar{y}$ 表示真实值, y 表示预测值, n 表示样本数量。

4 实验设计与结果分析

实验使用顺直武汉航段和重庆弯曲航段内的真实 AIS 数据集来评估模型的优势。

4.1 实验数据

引入真实的长江航道 AIS 数据进行实验比较与验证。由于长江航道在不同区域间存在差异,如图 4 所示,武汉位于

长江中游,航道较顺直,重庆位于长江上游,航道较弯曲,卡口多,因此本文使用重庆段和武汉段两个数据集对模型的精度和训练速度进行验证性研究。




图 4 重庆航段-武汉航段

Fig. 4 Chongqing waterway-Wuhan waterway

原始的 AIS 数据是由大量元组构成的数据流,每个元组由一艘船发出,其包含在 AIS 编码规范下的某时刻的位置和行为(包括 MMSI、经度、纬度、速度、航线、时间戳和出发港口等),AIS 数据的预处理如 3.1 节所述。对重庆段和武汉段两个航段数据集进行数据预处理,则每个航段的数据由若干条 15 min 的轨迹序列组成,其中前 10 min 为历史轨迹序列,后 5 min 为预测轨迹序列。每条轨迹序列由若干个轨迹点组成,每个轨迹点由 5 个轨迹特征组成。重庆段数据集有 41 535 条轨迹序列,武汉段数据集有 162 643 条轨迹序列。实验数据详情如表 1 所列。

表 1 实验数据详情
Table 1 Experimental data details

数据集	武汉航道	重庆航道
时间范围	6/1/2017-6/10/2017	6/1/2017-6/10/2017
轨迹点间 时间间隔/s	30	30
经度范围/(°)	114.05-114.5	106.00-106.61
纬度范围/(°)	30.22-30.70	29.00-29.62
轨迹点特征	时间间隔、相对经度、相对 纬度、对地航速、对地航向	时间间隔、相对经度、相对 纬度、对地航速、对地航向

4.2 实验参数设置

模型优化器使用基于一阶梯度的随机目标函数优化算法 Adam^[18],用于在训练过程中更新参数。其中学习率设置为 0.001;decay 设置为 0.0,表示每次参数更新后学习率的衰减。此外,为了防止过拟合,训练过程中使用 dropout^[19] 机制,其值设为 0.1。由于实验的训练数据集较大,因此本文实验使用的 batch-size 为 100。

4.3 实验设计与分析

将基于 Seq2Seq 的船舶 AIS 轨迹即时预测模型与典型的循环神经网络模型在武汉顺直航段和重庆弯曲航段进行对比实验,以验证所提模型的有效性。

4.3.1 LSTM-RNNs,GRU-RNNs 与 Seq2Seq 模型的对比

将以下 3 个模型在武汉段和重庆段数据集上进行对比实验,输入 10 min 的历史轨迹序列(20 个轨迹点),预测未来 5 min(10 个轨迹点)的轨迹序列,实验结果如表 2 所列。

(1)LSTM-RNNs,基于文献[9]提出的一种基于 LSTM 的船舶轨迹预测模型,使用历史轨迹点序列作为网络的输入,输出一个时刻的轨迹点。它无法一次性地预测多个连续时刻的轨迹点序列,只能采用递归的方式多次预测。

(2)GRU-RNNs,使用神经元为 GRU 构成的循环神经网络。相比 LSTM,GRU 的收敛时间及模型训练时间更短。与 LSTM 相同,GRU 无法一次性地预测多个连续时间的轨迹点序列,只能通过递归的方式多次预测。

(3)Seq2Seq,本文提出的基于 Seq2Seq 的船舶 AIS 轨迹即时预测模型。该模型使用单层 GRU 单元构成的 RNNs 记忆历史轨迹点序列信息,再使用单层 GRU 单元构成的 RNNs 记忆对历史信息进行解码,然后预测未来一段时间内的轨迹点序列。

表 2 不同模型的性能比较

Table 2 Performance comparison of different models

模型	指标	数据集	
		武汉航段	重庆航段
LSTM	RMSE	0.01607	0.01229
GRU	RMSE	0.01918	0.01536
Seq2Seq	RMSE	0.00386	0.00849

从表 2 可以看出,Seq2Seq 模型在重庆段和武汉段两个数据集上都取得了最好的短时轨迹序列预测效果。由于基础的 LSTM 网络和 GRU 网络采用递归的方式预测连续轨迹点序列,因此当预测的轨迹点增多时,预测效果也随之降低。图 5 显示了 3 种模型在武汉航段和重庆航段数据集上,预测递增的轨迹点序列时的误差变化情况。




图 5 3 种模型误差对比

Fig. 5 Comparison of loss of three models

从图 5 可以看出,当预测一个轨迹点时,LSTM 网络和 GRU 网络的预测效果优于 Seq2Seq;但预测连续的轨迹点序列时,随着预测的轨迹点数的增加,LSTM 网络和 GRU 网络预测结果的误差也不断增大,而 Seq2Seq 模型的预测误差变化较小。综合表 2 和图 5 的对比结果可以看出,Seq2Seq 模型比较适用于预测连续的轨迹点序列,在船舶短时轨迹序列预测的任务中表现较好。

4.3.2 不同结构的 Seq2Seq 模型的对比

基于 Seq2Seq 的船舶 AIS 轨迹即时预测模型中的编码器和解码器均由循环神经网络构成,因此在预测一段船舶轨迹时,解码器和编码器中循环神经网络的结构会影响轨迹的预测效果。本实验比较不同结构的 Seq2Seq 模型的船舶轨迹预测效果,结果如表 3 所列。其中输入序列均为 10 min 的历史轨迹序列,输出序列均为 5 min 的预测轨迹序列。

- (1)编码器为单层 LSTM 单元构成的循环神经网络。
- (2)编码器为单层 GRU 单元构成的循环神经网络。

表 3 不同结构的 Seq2Seq 的性能比较

Table 3 Performance comparison of different structures of Seq2Seq

数据集	编码器网络 类型	解码器网络 类型	均方根 误差	训练时间/s
武汉航段	LSTM	LSTM	0.003971	1067
	GRU	GRU	0.003823	997
重庆航段	LSTM	LSTM	0.008079	304
	GRU	GRU	0.007765	261

从表 3 可以看出,当编码器和解码器均为 GRU 网络时,轨迹预测效果较好。且在相同的环境下,编码器和解码器均为 GRU 网络时,模型完成一次迭代的训练时间更短,这主要是因为 GRU 的结构比 LSTM 的结构更简单,GRU 比 LSTM 少一个细胞状态。图 6 显示了两种结构的模型在武汉航段训练集和重庆航段训练集上预测船舶轨迹序列时的训练过程。





图 6 不同结构的 Seq2Seq 模型在训练阶段中的对比

Fig. 6 Comparison of Seq2Seq model with different structures

从图 6 可以看出,基于 Seq2Seq 的船舶轨迹预测模型在武汉航段和重庆航段都能有效地预测未来短时间内的船舶轨迹。其中,编码器和解码器都使用 GRU 网络时,收敛速度更快。

综合表 3 和图 6 的对比结果可以看出,编码器和解码器均为 GRU 网络时,预测效果更好,训练的时间更短。

如图 7 所示,采用 Seq2Seq 模型预测轨迹点序列时,随着预测的轨迹点数的增加,误差变化较小,且武汉航段的预测结果稍优于重庆航段的预测结果。



(a) 武汉段

(b) 重庆段

图 7 预测结果

Fig. 7 Forecast result

结束语 本文提出了一种基于改进 Seq2Seq 的短时 AIS 轨迹序列预测模型用于预测较短时间内的船舶轨迹任务。通过实验对比了 LSTM-RNNs, GRU-RNNs 和本文方模型, 以及不同结构的 Seq2Seq 模型在两个不同训练集上的预测效果, 验证了所提方法的有效性。在目前的船舶轨迹预测任务中, 预测轨迹的时间范围往往较大, 预测结果难以运用到船舶航行避碰任务中, 而部分能预测短时间内的船舶轨迹的模型无法一次性连续地预测多个时间的轨迹点, 只能采用递归的方式多次预测, 从而使得预测的轨迹点与真实轨迹点间的误差不断增大。本文提出的模型能通过编码器对历史 AIS 轨迹序列进行编码, 有效地提取历史轨迹特征; 并采用编码后的历史轨迹作为解码器端的初始输入; 同时, 解码器端的设计采用 feedback 模式输出连续的预测轨迹序列, 从而减小预测轨迹点序列时的误差。当前, 本文模型在 5 min 内的时空轨迹预测效果较好, 但在超过 5 min 的轨迹预测中效果不佳。因此, 下一步工作将优化编/解码器网络结构来继续改进模型, 从而为基于稍长时间的船舶轨迹预测的智能航运提供依据。

参考文献

- [1] PALLOTTA G, VESPE M, BRYAN K. Vessel Pattern Knowledge Discovery from AIS Data: A Framework for Anomaly Detection and Route Prediction[J]. *Entropy*, 2013, 15(6): 2218-2245.
- [2] IALA. An Overview of AIS[M/OL]. [2019-08-31]. <https://www.iala-aism.org/product/an-overview-of-ais-1082/>.
- [3] TU E, ZHANG G, RACHMAWATI L, et al. Exploiting AIS data for intelligent maritime navigation: a comprehensive survey from data to methodology[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2017, 19: 1559-1582.
- [4] 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.
- [5] CAVENEY D. Numerical integration for future vehicle path prediction[C]// *Proceedings of the 2007 American Control Conference*. IEEE, 2007: 3906-3912.
- [6] SEMERDJIEV E, MIHAYLOVA L, SCIENCE C. Variable-and fixed-structure augmented interacting multiple model algorithms for manoeuvring ship tracking based on new ship models[J]. *International Journal of Applied Mathematics*, 2000, 10(3): 591-604.
- [7] GREWAL M S. Kalman filtering[M]. Springer, 2011.
- [8] PERERA L P, SOARES C G. Ocean vessel trajectory estimation and prediction based on extended kalman filter[C]// *Proceedings of the The Second International Conference on Adaptive and Self-Adaptive Systems and Applications*. Citeseer, 2020: 14-20.
- [9] QUAN B, YANG B C. Prediction Model of Ship Trajectory Based on LSTM[J]. *Computer Science*, 2018, 45(S2): 136-141.
- [10] NGUYEN D D, VAN C L, ALI M I. Vessel Trajectory Prediction using Sequence-to-Sequence Models over Spatial Grid[C]// *Proceedings of the 12th ACM International Conference on Distributed and Event-based Systems*. Hamilton, New Zealand, 2018: 258-261.
- [11] ALAHI A, GOEL K, RAMANATHAN V, et al. Social lstm: Human trajectory prediction in crowded spaces[C]// *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2016: 961-971.
- [12] FFRANCISCO A, NAVARRO F, et al. Predicting aircraft trajectory: U. S. 9020662[P]. 2015-04-28. <http://www.freepatentsonline.com/9020662.html>.
- [13] WIEST J, HÖFFKEN M, KRESEL U, et al. Probabilistic trajectory prediction with Gaussian mixture models[C]// *Proceedings of the 2012 IEEE Intelligent Vehicles Symposium*. IEEE, 2012: 141-146.
- [14] YAN Z X. Traj-ARIMA: a spatial-time series model for network-constrained trajectory[C]// *Proceedings of the Proceedings of the Third International Workshop on Computational Transportation Science*. ACM, 2010: 11-16.
- [15] ZHENG Y. Trajectory data mining: an overview [J]. *ACM Transactions on Intelligent Systems Technology*, 2015, 6(3): 29.
- [16] CHO K, VAN MERRIËNBOER B, GULCEHRE C, et al. Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation[C]// *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*. 2014.
- [17] SUTSKEVER I, VINYALS O, LE Q V. Sequence to sequence learning with neural networks[C]// *Proceedings of the Advances in Neural Information Processing Systems*. NIPS, 2014: 3104-3112.
- [18] KINGMA D P, BA J. Adam: A Method for Stochastic Optimization[C]// *Proceedings of the the 3rd International Conference for Learning Representations*. ICLR, 2015: 1139-1154.
- [19] SRIVASTAVA N, HINTON G E, KRIZHEVSKY A, et al. Dropout: a simple way to prevent neural networks from overfitting[J]. *Journal of Machine Learning Research*, 2014, 15: 1929-1958.



YOU Lan, born in 1978, Ph.D, associate professor. Her main research interests include spatio-temporal data, deep learning and knowledge engineering.



HE Zheng-wei, born in 1977, Ph.D, associated professor. His main research interests include traffic big data processing and mining, maritime information systems and traffic environment simulation, artificial intelligence application technology, deep learning and smart navigation.