

文章编号:1671-251X(2024)S1-0048-05

基于深度学习的矿用车辆定位轨迹预测

王旭峰

(国能神东煤炭集团有限责任公司 上湾煤矿, 内蒙古 鄂尔多斯 017209)

摘要:矿用车辆轨迹预测对于煤矿井下交通系统智能化发展有重要作用,也是实现车辆自动驾驶技术的关键环节。在车辆轨迹预测方面,基于深度学习的方法比传统方法能更好地捕捉车辆轨迹的复杂规律,提高预测精度。介绍了物理机理、行为学习、深度学习在车辆轨迹预测方面的应用。采用对序列数据高度敏感的长短期记忆网络搭建预测模型,基于海量 GPS 车辆历史轨迹数据预测未来时刻车辆轨迹。通过数据清洗、轨迹压缩与分段、地图匹配等对矿卡轨迹数据进行预处理,将学习率设置为 0.001,用 Adam 优化器训练预测模型,将预处理数据输入模型进行轨迹预测。结果表明,基于长短期记忆网络的矿用车辆定位轨迹预测模型具有较高的准确度。

关键词:矿用车辆;车辆轨迹检测;深度学习;长短期记忆网络

中图分类号:TD67 文献标志码:A

Location trajectory prediction of mining vehicles based on depth learning

WANG Xufeng

(Shangwan Coal Mine, CHN Energy Shendong Coal Group Co., Ltd., Ordos 017209, China)

0 引言

煤矿井下交通系统的安全高效运行是煤矿安全生产的“生命线”。车辆轨迹预测是矿用交通系统智能化发展的基石,是实现车辆自动驾驶^[1]、交通流量控制^[2]、碰撞预警^[3]等智能化功能的基础。由于井下巷道纵横交错,辅助运输及调度无人化系统成为煤矿开采安全性及生产效率提高的瓶颈。如果能够准确预测车辆的运动轨迹,则可以利用车用 5G 通信、人车交互、交通信号优化等技术,实现车辆与周围环境的无缝连接,提高车辆智能化水平、交通效率,降低运营成本^[4]。

车辆轨迹预测是矿用车辆自动驾驶的“大脑”,可以“思考”车辆未来的运动轨迹,从而为自动驾驶系统做出合理的决策。车辆轨迹预测为矿用车辆的路径规划、碰撞预警等提供了重要依据,能够使汽车在发现安全隐患时及时调整行驶策略,避免发生碰撞,具有在复杂交通环境下安全通行的能力。

目前国内已有多个矿区具备远程遥控或自动掘进、采煤等作业能力^[5-6]。随着技术的不断进步,矿用车辆自动驾驶将成为技术发展的“风口”,为矿山行业带来变革。车辆轨迹预测技术的应用将为矿用

车辆自动驾驶提供安全可靠的保障,还可应用于矿用车辆的故障诊断^[7]、安全监控^[8]等方面,为矿用车辆的安全运行提供保障。

1 研究背景

当前业界的研究主要是在物理机理、行为和深度学习 3 个方面对车辆轨迹进行预测^[9]。

基于物理机理的预测模型是最简单的模型,这种模型具有较好的理论基础,易于理解和实现,因此在控制领域有较为成熟和广泛的应用。这类模型不涉及行为数据和场景信息,仅基于牛顿运动定律等物理原理,只计算车速、位置等简单数据来预测车辆的运动轨迹。因此,尽管基于物理机理的预测模型有较高的计算效率,但由于缺少对状态变化和不确定性的考虑,其预测结果的可靠性较差。

基于行为的预测模型通过车辆的驾驶行为,如行驶速度、变道意图等,来预测车辆的未来轨迹。在基于行为的预测^[10]中,道路上的一切物体(如车辆、行人)的运动都是一系列行为的组合。现实中的车辆会被抽象为一个个运动个体,有行驶、超车、停车、左转、右转等行为,模型会根据这些行为组合预测车辆轨迹。这种预测方法虽然相较于基于物理机理的

收稿日期:2024-01-25;责任编辑:李明。

作者简介:王旭峰(1984—),男,内蒙古巴彦淖尔人,工程师,主要从事煤矿机电一体化研究与应用工作,E-mail: 172324988@qq.com。

预测有一定改进,但也存在缺陷^[11],如需要大量的行为数据训练模型、可扩展性较差、对道路拓扑结构的依赖性较强、缺乏对车辆之间交互行为的考虑等。

基于深度学习的预测模型是利用深度学习算法来学习车辆轨迹的规律,可以从大量的数据中学习到的复杂的规律,因此预测结果的可靠性较高。

深度学习的不断发展和完善,给车辆轨迹预测的进一步发展提供了新的可能性。依托深度学习强大的学习能力,可以根据大量的历史轨迹数据,学习车辆的运动规律,进而对车辆的未来运行轨迹进行预测。其中,循环神经网络(Recurrent Neural Network,RNN)是一种会“记忆”的神经网络,在处理文本^[12]、语音^[13]、视频^[14]等时序相关问题上重要应用。长短期记忆(Long Short-Term Memory,LSTM)网络是RNN的变种,具备较为持久的记忆能力。因此,对于车辆轨迹预测任务来说,选用LSTM网络构建模型很合适。季学武等^[15]构建了驾驶意图识别及车辆轨迹预测模型,基于LSTM网络,能够“看清”车辆之间的相互作用和交通环境的变化,从而预测车辆的未来轨迹。孙影等^[16]提出了一种多维融合+LSTM的车辆轨迹预测方法,首先从多维度提取车辆特征,然后使用LSTM网络来学习车辆轨迹中的长期依赖关系,提高了预测精度。齐战硕等^[17]通过LSTM网络模型构建了车辆轨迹的多步预测方法,很好地解决了车路协同测试系统中的通信时延问题。S. H. Park等^[18]采用编码器-解码器架构实时生成车辆的未来轨迹序列,通过LSTM编码器对车辆的历史运行轨迹进行分析,通过LSTM解码器预测车辆的未来轨迹,得到了较高的预测精度。T. Bogaerts等^[19]提出了一种图卷积+深度学习的交通预测方法,将交通数据表示为图结构,使用图卷积来提取空间特征,通过深度学习算法进行交通预测。

2 基于 LSTM 网络的车辆轨迹预测

基于LSTM网络构建了车辆轨迹预测模型,如图1所示。该模型包括数据预处理模块、测试模块和预测模块,可以通过边学习边预测的方式,学习车辆的历史轨迹数据,并基于历史轨迹数据预测未来时刻的车辆轨迹。

2.1 数据预处理

本文采用某矿2 d内的矿卡轨迹数据作为原始数据,是由车载导航设备记录的数据。这些原始轨迹数据往往不规范,存在数据冗余、噪声、不一致等问题,影响数据质量,降低预测模型的准确性。因此,需要对矿卡轨迹数据进行预处理。




图1 基于 LSTM 网络的车辆轨迹预测模型

1) 数据清洗。轨迹数据清洗的作用是消除原始数据中的噪声和冗余点。噪声是指由于设备异常造成的错误采样,如车辆行驶至井下、巷道等路段时因定位信号弱导致定位误差,会对轨迹预测产生很大影响。车辆无论是在运动状态还是静止状态,都会产生大量冗余点,需剔除,使数据精简。本文采用噪声滤波和停留点检测2种方式对轨迹数据进行清洗。

某矿卡轨迹如图2所示。 p_5 点相对轨迹较远,是一个噪声点,需要将其过滤。通常采用中值或均值滤波、卡尔曼滤波、粒子滤波方式滤除噪声。本文采用中值滤波方式,即对于测量点 p_j ,用 p_j 和前 $n-1$ 个轨迹点的中值估计单个噪声点的真值。该方法的思路是,由于噪声点值与周围的正常点值差异较大,所以对周围的正常点值取中值,可以有效地去除噪声点。




图2 矿卡轨迹数据中的噪声

通过停留点检测可以识别出停留点,即时间上连续而空间上非常临近的点。通过去掉这些点,可消除不必要的噪声,避免其对轨迹预测造成干扰。但这些被删除的停留点往往蕴含着丰富的信息,如停留点比较密集的地方可能是工作面、设备间之类的场所,可以利用检测出的停留点进行兴趣点挖掘、事件分析等。

停留点分为静止型停留点和徘徊型停留点。如图3所示,左侧红点为静止型停留点,右侧红点为徘徊型停留点。静止型停留点可以根据速度、距离阈值等判断。对于徘徊型停留点,简单的判断思路为:
① 对于轨迹点 P ,找出与其相距特定距离的另一轨

迹点 P_1 。② 计算点 P 与点 P_1 之间的时间跨度 t 。③ 比较 t 与设定阈值的大小, t 大于阈值时, 中间点被认为是停留点。




图 3 轨迹停留点

2) 轨迹压缩与分段。从车载导航中获取的基于时间戳的车辆轨迹数据能够精确到秒, 但由于计算机的存储、计算能力有限, 另外车辆轨迹预测对数据的精细度要求不是很高, 所以可对车辆轨迹数据进行压缩。本文采取应用垂直欧氏距离方式压缩数据。如图 4 所示, 将一条包含 17 个点的轨迹通过垂直欧氏距离压缩为 3 个点, 轨迹中的每一点 p_i 都与一个时间戳 t_i 相对应。




图 4 基于垂直欧氏距离压缩轨迹

轨迹分段是将经过清洗后的长时段轨迹进行合理的截断, 将其切分成多条连续的子轨迹, 使子轨迹段代表车辆的一次出行, 如图 5 所示。




图 5 轨迹分段

常用的轨迹分段方法包括基于停留点的分段方法和基于时间间隔的分段方法。基于停留点的分段方法是先将轨迹中的停留点识别出来, 再对其进行剔除, 形成多个子轨迹。基于时间间隔的分段方法通过设定时间间隔的分段长度阈值, 对 2 个轨迹点的时间间隔进行判定, 如超过分段长度阈值, 则应在这 2 个轨迹点之间进行轨迹切分。

3) 地图匹配。地图匹配是数据预处理中的重要步骤, 起数据关联作用, 可以将车辆的 GPS 轨迹序列与电子地图的路网相关联。通过地图匹配后, 轨迹上的每一个采样点都会被映射到路网中的一个位置。受 GPS 精度限制, 定位出现误差的频次较高, 车辆的 GPS 轨迹点会遇到匹配到地图道路之外的情况, 这种场景进一步体现了地图匹配的必要性。地图匹配可以将车辆的 GPS 轨迹序列转换为路网坐标序列, 当出现定位误差时, 可通过前后轨迹点的匹配结果来修正当前点的位置, 如通过前后几个点的轨迹判断当前点更有可能位于哪条道路上。

以图 6 为例, p_a, p_b, p_c 为 3 个轨迹点, p_a 和 p_c 落在道路上, p_b 偏离了路网, 与车辆的行驶轨迹不符, 因此需要通过地图匹配方法对该异常点进行修正。




图 6 异常轨迹点

网格化方法的优点是通过将空间划分为网格, 将轨迹匹配转化成点匹配, 利用点匹配的低计算复杂度来简化地图的复杂度, 并提高轨迹匹配准确性。基于网格化方法, 本文采用两步, 将车辆轨迹与具有网格索引的路网建立匹配关系。

步骤 1: 将地图网格化并建立索引。如图 7 所示, 以地图最左上点为原点, 建立一个网格坐标系完全覆盖住地图, 并给坐标系上的每一网格建立索引。

	(x, y)	$(x+a, y)$	$(x+2a, y)$	$(x+3a, y)$
		1	1	1
	4	G_1	2 4	G_2 2 4
	3		3	3
$(x, y+a)$		1	1	1
	4	G_6	2 4	G_5 2 4
	3		3	3
$(x, y+2a)$		1	1	1
	4	G_7	2 4	G_8 2 4
	3		3	3
$(x, y+3a)$		1	1	1

图 7 网格索引

步骤 2: 匹配原始轨迹与网格。把车辆的 GPS 轨迹数据代入网格, 使每个轨迹点对应一个网格索引, 根据轨迹坐标 (x, y) 计算相应的网格索引 $G(x, y)$ 。

$$G(x, y) = \frac{x - x_{\min}}{b} + \frac{y - y_{\min}}{b} \frac{x_{\max} - x_{\min}}{b} + 1 \quad (1)$$

将经过网格化的数据分别以 2.5, 5, 10 min 的采样频率整理出不同的数据集。

2.2 模型调参

对于 LSTM 预测模型, 改变参数能直接影响其效率和预测精度, 因此, 进行模型优化离不开参数调整。

1) 损失函数。采用交叉熵损失函数对模型进行训练。交叉熵损失函数通过描述 2 个概率分布之

间的距离来度量模型预测结果的准确度,其数学表达式为

$$\text{CrossEntropyLoss} = - \sum_{i=0}^n (y_i \ln y_i^{\times}) \quad (2)$$

式中: y_i 为真实值; $y_i^{\times}$ 为预测的标签值。

将模型输出的 n 维向量的损失进行累加,计算出真实损失值。

对于分类任务,交叉熵计算公式为

$$h = \sum_j y_i \log_2 \frac{y_i}{o_i} = - \log_2 o_i \quad (3)$$

式中: h 为损失值; o_i 为真实值的预测概率。

模型的损失值 h 只取决于预测概率 o_i , o_i 越大, h 越小, 预测结果越接近真实值。若考虑极端情况, 当 $o_i=1$ 时, h 取最小值 0, 意味着模型预测出了完全正确的结果。

2) 学习率。学习率是最影响 LSTM 网络性能的参数之一, 主要用来度量模型的信息累积速度, 即训练中更新参数的步长。如果学习率太小, 模型会收敛得很慢, 还有可能无法跳出局部最优点或鞍点; 如果学习率太大, 损失函数可能会越过最小值, 导致模型不稳定、无法收敛。因此, 选择一个合适的学习率对于模型性能而言至关重要, 学习率的逻辑表达式为

$$\text{new_weight} = \text{old_weight} - \text{learning_rate} \times \text{gradient} \quad (4)$$

本文采用学习率退火对学习率进行设置。先选择一个较大的学习率作为初始值, 以快速降低模型的损失值。在迭代过程中, 逐步减小学习率, 避免模型越过最优点。一般情况下, 初始学习率的范围为 $1 \times 10^{-6} \sim 1$ 。对于小数据集, 学习率可以设置得更大一些; 对于大数据集, 学习率可以设置得更小一些。随着模型迭代, 初始学习率逐步衰减。常用的衰减策略有轮数衰减、指数衰减、分数衰减等。本文采用指数衰减方法, 计算公式为

$$l_r^{\times} = l_r d_r^{\frac{g_1}{g_1}}$$

式中: $l_r^{\times}$ 为经过更新的学习率; l_r 为原学习率; d_r 为衰减指数; g_1 为全局步数。

本文将学习率分别设为 0.000 01, 0.000 1, 0.001, 并比较当学习率取这 3 个值时模型的表现 (主要通过损失值和预测精度衡量), 发现当学习率取 0.001 时, 损失函数的收敛速度最快, 且精度曲线上快而平稳, 模型表现良好, 因此将学习率设为 0.001。

3) 优化器。在深度学习反向传播过程中, 优化器可对参数进行指导, 将参数向正确的方向调整至合适值, 使模型的输出逐渐逼近乃至达到最优解。

因此, 选择不同的优化器, 将会导致模型具有不同的收敛速度和最终性能。目前常用优化器的普遍思路是通过梯度下降进行优化, 具体而言: 一方面要决定优化方向, 对应于优化器中的动量或者梯度; 另一方面要决定步长, 对应优化器中的学习率。

应用较广泛的优化器有随机梯度下降法^[20]、RMSprop^[21]、Adam^[22]。随机梯度下降法计算量小, 适用于大规模数据集, 易于实现, 但对于非凸函数的收敛速度较慢, 容易陷入局部最优。RMSprop 在处理稀疏或平稳数据时可更快地收敛到最优解, 对超参数调整的敏感性更低, 可以有效处理噪声梯度。Adam 是 AdaGrad、RMSprop 和动量法的集大成者, 在 Adam 方法中, 一阶动量与二阶动量都得到了使用, 可以对梯度方向和学习率步长进行更好的控制, 但其更新公式较 RMSprop 复杂, 计算成本更高。

本文对 SGD, RMSprop, Adam 3 种优化器训练模型进行评估后, 采用 Adam 优化器对模型进行优化。

2.3 模型输出与可视化

设定好参数后, 训练模型进行轨迹预测实验, 将经过预处理的轨迹数据转换成数组, 通过 fit 函数输入 LSTM 模型, 并指定迭代次数 epochs、每批数据量的大小和验证集比例, 对模型进行训练。训练完成后, 将前一时刻的车辆历史轨迹数据输入模型, 得到下一时刻的预测轨迹数据输出。

图 8 为控制台输出结果, 其中每一行代表 1 条轨迹, 每一列代表 1 个时间切片, 一个矩阵代表 1 个轮次的训练预测。

```
Epoch 47, Step 396 loss:0.948 acc:0.802
[[382 331 407 ... 221 221 221]
[298 272 194 ... 221 221 221]
[302 300 300 ... 221 221 221]
:
[373 400 400 ... 221 221 221]
[299 299 298 ... 221 221 221]
[531 504 479 ... 221 221 221]
[[331. 382. 460. ... 0. 0. 0.]
[272. 220. 194. ... 0. 0. 0.]
[300. 300. 300. ... 0. 0. 0.]
:
[373. 400. 400. ... 0. 0. 0.]
[300. 299. 298. ... 0. 0. 0.]
[531. 504. 479. ... 0. 0. 0.]]
Epoch 47, loss_avg:1.372, val_loss_avg:1.961
acc_avg:0.621, val_acc_avg:0.485, Training Time 47.579 s
```

图 8 控制台输出结果

为了更直观地了解 LSTM 模型的预测效果, 使用 python 中的 matplotlib 函数对模型训练过程的损失和准确率进行可视化, 如图 9 所示。损失曲线在训练过程中逐渐减小, 且验证集的损失曲线在一定程度上收敛, 表明模型正在有效学习。准确率曲线在训练过程中逐渐增大, 且验证集的准确率曲线

在一定程度上收敛,表明模型正在有效地提高预测准确性。




图 9 模型预测的损失和准确率曲线

3 结语

基于 LSTM 网络构建了车辆轨迹预测模型,通过车辆历史轨迹数据预测车辆未来时刻的运行轨迹。模型训练和预测过程采用数据预处理和模型参数调整等步骤,以提高模型性能。将模型训练和预测过程中的损失值和准确度进行可视化,以更直观地观察模型的预测效果。该模型在车辆未来时刻运行轨迹预测方面表现良好,具有一定的可行性和有效性,对煤矿自动驾驶、智能交通等技术的发展具有一定的参考意义。

参考文献:

[1] 李雪松,张锬石,宋呈群,等. 自动驾驶场景下的轨迹预测技术综述[J]. 计算机工程,2023,49(5):1-11.

[2] 樊振宇. 基于深度学习的自动驾驶汽车周边车辆轨迹预测方法研究[D]. 镇江:江苏大学,2023.

[3] 王孜健,李心怡,景峻,等. 高速公路跟车场景的碰撞时间改进方法及应用案例研究[J]. 科技与创新,2023(11):123-125.

[4] 贾硕. 面向智能网联的驾驶行为识别与预测预警方法研究[D]. 西安:长安大学,2023.

[5] 王建. 掘进机可视化远程控制系统的设计及试验研究[J]. 西部探矿工程,2023,35(11):162-164.

[6] 李文枫. 煤矿井下智能化高效掘进控制体系的构建与应用[J]. 内蒙古煤炭经济,2023(11):127-129.

(上接第 47 页)

[17] 杨承志,张晓明,张鸽. 基于 WLS-KF 的 UWB 室内定位滤波算法研究[J/OL]. 电子测量与仪器学报;1-8 [2024-03-26]. <http://kns.cnki.net/kcms/detail/11.2488.TN.20240301.1054.040.html>.

[18] 陈伟. 基于 UWB 技术的煤矿精确定位系统[J]. 煤矿机械,2023,44(5):177-180.

[7] 李朋. 面向控制安全冗余的智能车辆轨迹规划与跟踪研究[D]. 武汉:武汉理工大学,2023.

[8] 姚振鑫. 基于深度学习的车辆跟踪与轨迹预测研究[D]. 上海:上海工程技术大学,2023.

[9] 章璐璐,李思照. 基于深度学习的智能体轨迹预测文献综述[J]. 无线电工程,2023,53(3):644-656.

[10] 谢枫,娄静涛,赵凯,等. 基于行为识别和曲率约束的车辆轨迹预测方法研究[J]. 汽车工程,2019,41(9):1036-1042.

[11] 胡灵. 基于 LSTM 的自动驾驶车辆轨迹预测方法研究[D]. 桂林:桂林电子科技大学,2022.

[12] 李名城,张博通,陈溢铭,等. 卷积增强循环神经网络在文本分类中的应用[J]. 咸阳师范学院学报,2021,36(2):24-29.

[13] 王丽,涂冰花,王伟,等. 长短期记忆循环神经网络在自动语音识别中的应用[J]. 单片机与嵌入式系统应用,2023,23(10):49-52.

[14] 董于春. 基于循环神经网络和可形变卷积的视频超分方法[D]. 上海:华东师范大学,2022.

[15] 季学武,费聪,何祥坤,等. 基于 LSTM 网络的驾驶意图识别及车辆轨迹预测[J]. 中国公路学报,2019,32(6):34-42.

[16] 孙影,王铁. 基于时间序列的目标车辆轨迹预测算法[J]. 汽车实用技术,2020(6):31-33.

[17] 齐战硕,高彦东. 面向消除通信时延的车辆轨迹多步预测方法[J]. 计算机与现代化,2022(5):114-118.

[18] PARK S H, KIM B D, KANG C M, et al. Sequence-to-sequence prediction of vehicle trajectory via LSTM encoder-decoder architecture [C]. IEEE Intelligent Vehicles Symposium,2018.

[19] BOGAERTS T, MASEGOSA A D, ANGARITA-ZAPATA J S, et al. A graph CNN-LSTM neural network for short and long-term traffic forecasting based on trajectory data[J]. Transportation Research Part C:Emerging Technologies,2020,112:62-77.

[20] 孙娅楠. 梯度下降法在机器学习中的应用[D]. 成都:西南交通大学,2018.

[21] 叶美彤. 非凸随机设定下两类 RMSProp 算法的收敛性[D]. 长春:东北师范大学,2021.

[22] 雷剑. 基于 Adam 优化神经网络的电梯群控算法的研究[D]. 衡阳:南华大学,2022.

[19] 方文浩. 基于 UWB 的煤矿井下高精度定位技术研究[D]. 合肥:合肥工业大学,2018.

[20] 霍振龙. 5G 专网技术及煤矿 5G 专网方案分析[J]. 工矿自动化,2022,48(11):6-10,19.

[21] 李明锋,李葵,刘用,等. 基于 5G+UWB 和惯导技术的井下人员定位系统[J]. 工矿自动化,2024,50(1):25-34.