

单全球导航卫星系统信号下基于自监督双向长短时记忆网络的车辆速度估计方法

田 婧, 马社强, 赵 丹, 陈发城

(中国人民公安大学 交通管理学院, 北京 100038)

摘 要: 单全球导航卫星系统 (GNSS) 环境下车辆速度检测存在显著噪声干扰, 且数据采样的稀疏性会加剧速度计算的不稳定性。为此, 将单 GNSS 下车辆速度估计构建为基于时空相关性的速度期望优化问题, 并提出一种自监督双向长短时记忆 (LSTM) 算法求解。首先, 该算法构建稀疏数据时空特征提取 LSTM 网络, 引入时间门和空间门控函数来分析稀疏、不等间距的车辆检测数据中速度时空关联的变化, 提取速度时空特征嵌入向量; 其次, 噪声双向抑制的车辆速度估计 LSTM 网络分别从前向、后向来分析车辆速度变化趋势, 准确实现噪声清除与速度估计; 最后, 以 GPS 信号为例对算法的车辆速度估计性能进行了实验验证, 结果表明: 提出的算法在采样间隔为 1~10 min 的稀疏数据下, 去除速度数据中的噪声平均值为 26.73 dB PSNR, 与 LWR、EnKF、Noise2Void 算法相比平均高 28.93%, 估计速度的准确度平均高 2.02%。

关键词: 交通管理工程; 车辆速度; 自监督学习; 双向 LSTM; 单 GNSS 信号

中图分类号: U149.41 **文献标志码:** A **文章编号:** 1671-5497(2025)12-3852-10

DOI: 10.13229/j.cnki.jdxbgxb.20240361

Vehicle travel speed estimation based on self-supervised long short-term memory network under single global navigation satellite system signal

TIAN Jing, MA She-qiang, ZHAO Dan, CHEN Fa-cheng

(School of Transportation Management, People's Public Security University of China, Beijing 100038, China)

Abstract: The vehicle speed detection in the single Global Navigation Satellite System (GNSS) environment is subject to significant noise interference, and the sparsity of data sampling will further exacerbate the instability of speed calculation. To address this issue, the vehicle speed estimation under the single GNSS scenario is formulated as a speed expectation optimization problem based on spatiotemporal correlation, and a self-supervised bidirectional Long Short-Term Memory (LSTM) algorithm is proposed for its solution. Firstly, a sparse data spatiotemporal feature extraction LSTM is constructed by this algorithm, where time gate and spatial gate functions are introduced to analyze the

收稿日期: 2024-04-07.

基金项目: 国家重点研发计划重点专项项目 (2023YFC3009700); 中央高校基本科研业务费专项资金项目 (2024JKF02ZK13).

作者简介: 田婧 (1995-), 女, 讲师, 博士. 研究方向: 智能交通态势感知, 交通大数据处理. E-mail: jingt202310@163.com

通信作者: 马社强 (1973-), 男, 副教授, 博士. 研究方向: 道路交通安全. E-mail: masheqiang@163.com

changes in speed spatiotemporal correlations in sparse and unequal-interval vehicle detection data, and embedded vectors for speed spatiotemporal features are extracted. Secondly, the trend of vehicle speed changes is analyzed from both forward and backward directions by the noise bidirectional suppression LSTM network for vehicle speed estimation, enabling the accurate achievement of noise elimination and speed estimation. Finally, experimental verification of the vehicle speed estimation performance of the proposed algorithm was conducted using GPS signals as an example. The results show that an average noise reduction of 26.73 dB PSNR was achieved by the proposed algorithm in sparse speed data with sampling intervals ranging from 1 minute to 10 minutes, which is 28.93% higher than that achieved by the LWR, EnKF, and Noise2Void algorithms on average. Additionally, the speed estimation accuracy of the proposed algorithm is 2.02% higher on average.

Key words: traffic management engineering; vehicle speed; self-supervised learning; bidirectional long short-term memory network; single global navigation satellite system signal

0 引 言

车辆速度是智能交通系统中的重要信息基础,其准确性对车辆调度与路线规划、重点车辆动态监管与风险预警等应用的开展有着重要影响。全球导航卫星系统(Global navigation satellite system, GNSS)(如北斗、GPS等)是目前车辆定位与测速应用最为广泛的系统。近年来,为保障智能交通建设的数据安全,推广单GNSS系统成为必然趋势,如应用单北斗终端提供重载货车、公共交通高精度定位导航和授时服务等。然而,在单GNSS系统环境下,车辆速度的计算极易受到建筑物遮挡信号、电磁干扰通信设备的影响而包含大量噪声数据。因此,研究单GNSS下的车辆速度估计方法,去除数据中的噪声,对保障交通运输系统的数据安全与提高服务水平具有重要意义,也可为车辆监管和调度奠定高精度数据基础。

目前,车辆运动参数的估计主要集中于传统统计模型,如基于卡尔曼滤波等的时间序列预测方法^[1,2]、基于神经网络的INS误差纠正方法^[3]等。这些模型通过分析数据的变化特征来估算车辆速度、位移等参数,结构轻便,易于计算。然而,单源GNSS下车辆速度噪声干扰的产生具有非线性、随机性和多样性。在随机噪声干扰下,线性、浅层的模型结构难以充分分析车辆速度特征,精度有限。

为提升随机噪声干扰下的数据真值估计精度,自监督学习思想被引入数据降噪算法^[4-6]。此类算法依托噪声零均值等假设,通过挖掘数据时

空相关性以去除噪声,在图片数据降噪领域已取得了良好效果。道路交通流具有显著的时变特性,且受地理兴趣点吸引呈现出空间不均衡分布。显然,充分分析交通流时空变化特征是准确估算车辆速度的前提。因此,基于自监督学习的深度学习算法对解决车辆速度准确估计具有较大潜力。然而,自监督学习算法要应用于单GNSS系统下的车辆速度计算,至少需要针对单GNSS采样稀疏性进一步改进。

受限于设备算力与安装成本,目前北斗、GPS等GNSS系统的采样间隔设置较大(通常为30 s或200 m)。相邻GNSS数据点记录的车辆速度相差较大,表征的交通流时空相关性较弱。在此情况下,车辆速度的解不是唯一的,估算易受干扰而出现严重偏差,具有不稳定性。因此,在单源GNSS系统下,对车辆速度的时空相关性挖掘不充分,将导致现有的自监督学习算法难以实现车辆速度中噪声的准确判别并去除。考虑到交通流的时空相关性以及单GNSS系统采样间隔的稀疏性,基于长短时记忆(Long short-term memory, LSTM)^[7-9]网络的方法通过引入记忆单元能够同时挖掘序列数据长期与短期的依赖关系,对单GNSS系统稀疏采样下车辆速度准确估计具有很大的潜力。

综上,单GNSS系统下车辆速度数据包含大量噪声干扰,且由于数据采样稀疏性导致噪声的判别与去除具有不稳定性。因此,研究车辆速度准确估计对保障交通安全、高效运行具有重要意义。本文将构建一种自监督双向LSTM网络

(Self-supervised bidirectional LSTM network, SSB-LSTM), 通过构建时间门控与空间门控函数, 实现稀疏采样下不同间隔车辆速度数据点间相关性的挖掘; 采用交通流前向-后向的推理过程来判别噪声, 避免稀疏数据下车辆速度求解不稳定; 依据交通流上下文的时空相关性, 构建不依赖于先验信息的算法自监督学习训练策略, 提升降噪算法的可实践性; 并以浮动车 GPS 数据为例, 验证算法对单 GNSS 系统下车辆速度估计的有效性和实用性。

1 自监督双向 LSTM 的车辆速度估计算法

为实现稀疏的单 GNSS 系统下车辆速度准确估计, 本文依据自监督思想^[9,10]构建车辆速度估计优化问题, 并提出一种 SSB-LSTM 算法进行优化求解, 能够适应实际中难以获取车辆速度或噪声真值的情况。

1.1 车辆速度估计问题定义

为便于分析车辆速度时空特征, 将 GNSS 检测的车辆速度记为沿车辆行驶轨迹的时空向量 $\mathbf{g} = [g_1, g_2, \dots, g_q]$, 其中 q 为车辆轨迹数据的时间步数。相邻速度数据点的时间、空间间隔分别记作 $\Delta t = [\Delta t_1, \Delta t_2, \dots, \Delta t_{q-1}]$ 和 $\Delta x = [\Delta x_1, \Delta x_2, \dots, \Delta x_{q-1}]$ 。

受建筑物遮挡、大气延迟等因素影响, GNSS 检测的车辆速度数据中包含不同类型、水平的噪声干扰。依据加性噪声模型^[11], 车辆速度数据 $\mathbf{g}$ 可表达为数据真值 $\mathbf{v}$ 与噪声 $\mathbf{z}$ 之和:

$$\mathbf{g} = \mathbf{v} + \mathbf{z} \quad (1)$$

基于上述定义, 单 GNSS 系统下车辆速度估计问题可归纳为从观测数据 $\mathbf{g}$ 中消除噪声 $\mathbf{z}$ 干扰, 反算车速真实值 $\mathbf{v}$ 。由于实际中难以获取真实数据和噪声的分布, 因此, 算法需要在自监督或无监督情况下估算车辆速度真值。

为实现自监督下的车辆速度估计, 本文引入噪声独立且零均值假设, 即 $E(\mathbf{z}) = 0$ 。此时, 含噪的观测 GNSS 数据 $\mathbf{g}$ 的期望即车辆速度的真值 $\mathbf{v}$:

$$E(\mathbf{g}) = \mathbf{v} \quad (2)$$

由此, 算法通过计算含噪观测数据 $\mathbf{g}$ 的数学期望, 即可求解车速真值。考虑车辆速度具有时

空相关性, 因此, 车速期望 $E(\mathbf{g})$ 可由观测数据 $\mathbf{g}$ 的邻域数据点近似^[6]。此时, 车辆速度估计可写为优化问题:

$$\arg \min_{\vartheta} \sum_i \|\mathbf{v}_i - \mathbf{g}_i\|^2, \mathbf{v}_i = f(\mathbf{g}_{\mathfrak{N}}; \vartheta) \quad (3)$$

式中: $\mathbf{g}_i$ 、 $\mathbf{v}_i$ 分别为车辆轨迹数据中第 i 个数据点的速度观测值和真值; $\mathbf{g}_{\mathfrak{N}}$ 为 $\mathbf{g}_i$ 邻域内的观测数据; ϑ 为训练的网络参数。

1.2 基于自监督学习的车辆速度估计算法总框架

为准确优化求解式(3), 获取准确的车辆速度估计值, 本文构建了一种基于自监督的 SSB-LSTM 算法, 总体结构如图 1 所示。SSB-LSTM 以车辆速度观测向量 $\mathbf{g}$ 和速度点的时间与空间间隔 Δt 、 Δx 为输入, 输出估计的车辆速度真值 $\mathbf{v}$ 。SSB-LSTM 共包括稀疏数据时空特征提取 LSTM 网络 (Sparse data spatial-temporal feature extraction LSTM, ST-LSTM) 和噪声双向抑制 LSTM 网络 (Noise bidirectional suppression LSTM network, NBS-LSTM) 两部分。首先, ST-LSTM 引入时间门控与空间门控函数以分析稀疏采样的 GNSS 数据点间时空相关性, 实现车辆速度特征的准确提取; 其次, 噪声双向抑制 LSTM 网络通过从前向和后向提取车辆速度的变化趋势以判别噪声, 并估计降噪后的车辆速度真值; 最后, SSB-LSTM 以求解式(3)为优化目标, 调整输出的车辆速度。

考虑到式(3)易导致算法陷入从邻近观测速度 $\mathbf{g}_{\mathfrak{N}}$ 到观测速度数据点 $\mathbf{g}$ 的恒等映射学习, 忽略对噪声的去除。为避免该问题, 本文将 SSB-LSTM 的训练进一步调整为“掩码-重建”过程 (Masking-and-reconstruction)^[12]。具体地, 该过程依据在 L_2 损失下有噪样本期望的解等于数据均值的研究结论^[4], 在掩码过程中从车辆轨迹数据中随机选择 N_M 个数据, 引入掩码矩阵 κ 进行标记并添加零均值的随机数据。令 $\mathbf{u}$ 为添加的随机数据, SSB-LSTM 输入的交通流数据为 $[g_1, g_2 + u_2, g_3, \dots, g_{i-1}, g_i + u_i, g_{i+1}, \dots, g_q]$, 掩码矩阵为 $[0, 1, 0, \dots, 0, 1, 0, \dots, 0, 0]$ 。在重建过程中, SSB-LSTM 同时计算掩码数据点的梯度并优化求解式(3), 以有效且快速地求解含噪车辆轨迹数据点的速度真实值。




图 1 面向车辆速度估计的自监督双向 LSTM 算法总体结构

Fig. 1 Overall structure of self-supervised bidirectional LSTM network for vehicle travel speed estimation

2 自监督双向 LSTM 的车辆速度估计算法

2.1 稀疏数据时空特征提取 LSTM 网络

准确提取车辆速度时空特征是实现速度精准估计的必要依据。然而,实际中,GNSS 系统采集的时间或空间间隔设置较大,且难以保证等间距,所表征的速度信息是稀疏的,算法极易受干扰而出现时空特征分析偏差,计算具有不稳定性。LSTM 网络能够同时捕捉序列数据长期与短期的特征,对挖掘车辆速度数据特征具有较大的潜力^[13]。但目前常用的 LSTM 网络以等间隔序列数据的特征分析为主,难以适应单 GNSS 系统下稀疏数据特征的分析。

为准确提取单 GNSS 下稀疏车辆速度数据的时空特征,本文构建了一种 ST-LSTM 网络,在 LSTM 原有基础上引入时间与空间门控函数,充分挖掘稀疏、不等间距的车辆检测数据中速度时空关联的变化。

ST-LSTM 以车辆速度向量 g 与时、空间隔 Δt 、 Δx 为输入,输出车辆速度的时空特征嵌入向量 h_t 。ST-LSTM 网络结构如图 2 所示,主要包括时间门 r_t 、空间门 d_t 、遗忘门 f_t 、输入门 i_t 、输出门 o_t 以及单元状态 c_t 。




图 2 稀疏数据时空特征提取 LSTM 网络

Fig. 2 Sparse data spatial-temporal feature extraction LSTM network

时间门控函数 r_t 和空间门控函数 d_t 将相邻数据点间的时空距离嵌入速度表征,依据交通流时空变化规律,估算相邻速度数据点与当前速度的时空关联强度。时间门控函数 r_t 和空间门控函数 d_t 的计算方程如下:

$$r_t = \varphi(W_{xr}g_t + \varphi(W_r\Delta t_t) + b_t) \quad (4)$$

$$d_t = \varphi(W_{xd}g_t + \varphi(W_d\Delta x_t) + b_x) \quad (5)$$

式中: φ 为激活函数; W_{xr} 、 W_{xd} 、 W_r 、 W_d 均为激活函数的权重; b_t 、 b_x 均为激活函数的偏差。

在时间、空间门控函数的辅助下,单元状态 c_t 将考虑不同时空距离下速度相关性的变化,存储相邻数据中与当前速度数据点关联的重要特征。具体地,单元状态 c_t 是由输入门 i_t 、遗忘门 f_t 、时间

门 r_t 与空间门 d_t 共同控制求解的。其中,输入门 i_t 与遗忘门 f_t 分别计算单元状态 c_t 中应保留的当前速度、前期速度的特征。时间门 r_t 和空间门 d_t 用于控制当前速度特征的占比。最终,单元状态 c_t 将通过输出门 o_t 转换为车辆速度的时空特征 h_t 。

$$i_t = \varphi(W_{gi} \cdot g_t + W_{hi} \cdot h_{t-1} + W_{ci} \cdot c_{t-1} + b_i) \quad (6)$$

$$f_t = \varphi(W_{gf} \cdot g_t + W_{hf} \cdot h_{t-1} + W_{cf} \cdot c_{t-1} + b_f) \quad (7)$$

$$c_t = f_t \cdot c_{t-1} + i_t \cdot r_{t-1} \cdot d_{t-1} \cdot \tanh(W_{gc} \cdot g_t + W_{hc} \cdot h_{t-1} + b_c) \quad (8)$$

$$o_t = \varphi(W_{go} \cdot g_t + W_{to} \cdot \Delta t_{t-1} + W_{do} \cdot \Delta d_{t-1} + W_{ho} \cdot h_{t-1} + W_{co} \cdot c_t + b_o) \quad (9)$$

$$h_t = o_t \cdot \tanh(c_t) \quad (10)$$

式中: W_{gi} 、 W_{hi} 、 W_{ci} 、 W_{gf} 、 W_{hf} 、 W_{cf} 、 W_{gc} 、 W_{hc} 、 W_{go} 、 W_{to} 、 W_{do} 、 W_{ho} 、 W_{co} 均为函数的权重; b_i 、 b_f 、 b_c 、 b_o 均为函数的偏差。

2.2 噪声双向抑制的车辆速度估计 LSTM 网络

获取准确的车辆速度值需判别并去除单 GNSS 测量下受到的大量噪声干扰。噪声点的出现是离散、随机的,与交通流变化引起的车辆速度持续变化不同。因此,算法通过分析车辆速度数据的变化趋势,能够实现噪声的准确判别并去除。然而,现有的降噪算法仅从单向挖掘数据时序信息,对噪声的去除能力是有限的^[14,15]。

双向 LSTM(Bidirectional LSTM)使用两个 LSTM 网络分别从前向和后向上提取数据的上下文信息,在交通流预测^[16]、语音识别^[17]等领域都展现了较单向网络更加优越的能力。因此,本文将双向 LSTM 网络引入 SSB-LSTM 中,从前、后双向分析车辆速度变化趋势并判别噪声,获取车速真值。当车辆速度点间隔较大、相关性较弱时,算法将依据相同路段上的历史速度分布规律进行估计。基于噪声双向抑制的车速估计网络 NBS-LSTM,结构如图 3 所示。




图 3 噪声双向抑制的车辆速度估计 LSTM 网络

Fig. 3 Noise bidirectional suppression LSTM network for vehicle travel speed estimation

NBS-LSTM 网络层由前向 ST-LSTM 层、后向 ST-LSTM 层以及特征融合层组成。前向 ST-LSTM 的输入为从时间步 1 到时间步 q 的正序车辆速度向量 $g=[g_1, g_2, \dots, g_q]$ 以及相应的数据点时空间隔 $\Delta t, \Delta x$ 。前向 ST-LSTM 按照车辆轨迹行进方向正向迭代计算,输出车辆速度估计结果 $\vec{h}_t$ 。后向 ST-LSTM 层使用从时间步 q 到时间步 1 的逆序车辆速度数据和相应数据间时间间隔进行迭代计算,输出车辆速度估计结果 $\tilde{h}_t$ 。最终, NBS-LSTM 将融合前向与后向的车辆速度结果 $\vec{h}_t$ 和 $\tilde{h}_t$, 输出估计的第 t 个时间步的车辆速度数据点 v_t 。计算公式如下:

$$v_t = W \cdot (\vec{h}_t \oplus \tilde{h}_t) + b \quad (11)$$

$$\vec{h}_t = f_{\text{ST-LSTM}}(g_t, \Delta t_{t-1}, \Delta d_{t-1}, \vec{h}_{t-1}) \quad (12)$$

$$\tilde{h}_t = f_{\text{ST-LSTM}}(g_t, \Delta t_t, \Delta d_t, \tilde{h}_{t+1}) \quad (13)$$

式中: $\oplus$ 为矩阵的拼接操作; $\rightarrow$ 和 $\leftarrow$ 分别为 LSTM 网络前向、后向的车辆速度估计方向。

3 实验验证与分析

3.1 实验数据描述

为保证实验验证的客观性,提供算法在单 GNSS 环境中不同噪声干扰下车辆速度估计的准确评价,本文的实验数据分为真实车辆速度数据和合成车辆速度数据。

3.1.1 真实车辆速度数据

本文选取长春市第 13 路公交车 GPS 数据作为典型的单 GNSS 环境下的车辆速度数据集。实验路段以长春市同志街路口为起点至南湖广场结束。数据集时间范围为 2017 年 10 月 6 日至 2018 年 1 月 16 日,采样时间间隔为 30 s。考虑到实际工程中 GNSS 系统的采样间隔较大,实验按照时间间隔 1、2、3、5 及 10 min,求取相邻两 GPS 数据点间的平均速度,构造 GPS 不同采样率的车辆速度数据集用于训练和测试。

3.1.2 合成车辆速度数据

合成车辆速度数据在真实公交 GPS 数据的基础上,手工添加预设类型和水平(即噪声标准差)的速度噪声。添加的噪声分布类型包括高斯分布、泊松分布以及尖峰分布。高斯噪声描述由于周围障碍物、其他无线信号等因素导致的 GPS 数据误差。尖峰噪声是由车辆故障、急刹车等突变因素造成的速度误差。泊松噪声是由于驾驶个性等因素,导致的同一时刻、路段上车速的随机波动。添加的噪声

水平的范围设为 5、10、15、20 km²/h²。添加的 3 种类型噪声的计算公式分别为:

$$p_{\text{Gaussian}}(z) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(z-\mu)^2}{2\sigma^2}} \quad (14)$$

$$p_{\text{Poisson}}(z) = \frac{e^{-\sigma}\sigma^z}{z!} \quad (15)$$

$$p_{\text{peak}} = \begin{cases} v_{\max}, & x \sim p_{\text{Gaussian}}(x) \\ 0, & \text{其他} \end{cases} \quad (16)$$

式中: μ 、 σ 分别为添加的速度噪声的均值和标准差; $v_{\max}$ 为速度最大值; x 为随机选择添加噪声的位置。

3.2 评价指标

为准确衡量算法在单 GNSS 下的车辆速度估计性能,本文选取结构相似性指数 (Structural SIMilarity, SSIM) 以及峰值信噪比 (Peak signal to noise ratio, PSNR) 作为评价指标。

PSNR 常用于衡量算法去除数据中噪声的数量,单位为分贝 (Decibel, dB)。PSNR 越大代表算法在车辆速度估计中修正误差干扰的能力越强。SSIM 计算的是算法在数据中去除的噪声与估计的车辆速度间的结构相似性,能够较好地衡量算法在含噪的单 GNSS 数据下保留速度本征的能力。SSIM 取值为 $-1 \sim 1$ 。SSIM 越大代表算法对车辆速度的估计能力越强。PSNR 和 SSIM 的计算公式分别为:

$$\text{PSNR} = -10 \log_{10} \left(\frac{v_{\max}^2}{\text{MSE}} \right), \text{MSE} = \frac{1}{n} \sum_{i=1}^n \|v_i - \hat{v}_i\|^2 \quad (17)$$

$$\text{SSIM}(z, \hat{v}) = \frac{(2\mu_z\mu_{\hat{v}} + C_1)(2\sigma_{z\hat{v}} + C_2)}{(\mu_z^2 + \mu_{\hat{v}}^2 + C_1)(\sigma_z^2 + \sigma_{\hat{v}}^2 + C_2)} \quad (18)$$

式中: v_i 与 $\hat{v}_i$ 分别为第 i 个车辆速度数据点的观测值、估计值; n 为车辆速度数据点总数; μ_z 和 σ_z^2 分别为去除的噪声的均值和方差; $\mu_{\hat{v}}$ 和 $\sigma_{\hat{v}}^2$ 分别为估计的车辆速度的均值和方差; $\sigma_{z\hat{v}}^2$ 为去除的噪声与估计的车辆速度之间的协方差;常数 C_1 和 C_2 用于保证计算稳定。

3.3 不同数据采样间隔下的算法速度估计性能分析

本节通过讨论 SSB-LSTM 算法在不同采样间隔的车辆速度估计结果,来验证算法在单 GNSS 系统采样稀疏情况下的计算性能,相应的 PSNR 和 SSIM 指标如图 4 所示。

在稀疏采样条件下,SSB-LSTM 估计车辆速




图 4 SSB-LSTM 对不同采样间隔车辆速度数据的估计误差

Fig. 4 Estimation error of SSB-LSTM for vehicle speed with different sampling time intervals

度的 PSNR 和 SSIM 平均值分别为 26.73 dB 和 0.09,依然能够较为准确地估计车辆速度。此外,随着 GPS 数据采样间隔从 1 min 扩大至 10 min,SSB-LSTM 算法的 PSNR、SSIM 分别降低 17.96%、42.86%。这说明随着数据点间的交通关联逐渐减弱,SSB-LSTM 从数据中去除的噪声逐渐减少,但保留速度特征的能力逐渐增强。总体而言,SSB-LSTM 算法去除稀疏数据的噪声数量与保留速度特征的能力成反比。

3.4 不同噪声干扰下的算法速度估计性能分析

单 GNSS 系统下的车辆速度检测数据包含多种类型的噪声干扰。本节讨论在不同水平的高斯噪声、泊松噪声以及尖峰噪声干扰下 SSB-LSTM 算法对车辆速度的估计性能。SSB-LSTM 算法的车辆速度估计 PSNR 和 SSIM 指标如表 1 所示。

在去除车辆速度数据中的噪声误差方面,对同一类型噪声,SSB-LSTM 算法在不同噪声水平下的 PSNR 取平均值,算法对高斯噪声、泊松噪声、尖峰噪声的平均去除量分别为 21.57、22.67、18.52 dB PSNR。可以得出,SSB-LSTM 去除泊松噪声的能力最强,去除尖峰噪声的能力最弱(较泊松噪声低 18.31%)。随噪声水平从 5 km²/h²提高至 20 km²/h²,算法去除泊松噪声的 PSNR 增加 5.39%,而去除高斯噪声和尖峰噪声的能力则没有明显的下降或上升趋势。算法对由建筑物遮挡、天气等环境干扰因素导致的车辆速度检测误差去除能力更强,对由车辆故障、急刹车等突变因素导致的速度误差去除能力略弱。

在保留数据中的速度特征方面,SSB-LSTM

算法去除高斯噪声、泊松噪声、尖峰噪声的 SSIM 平均值为 0.40、0.28、0.41。算法在处理泊松噪声时对速度特征的保留程度最好,在尖峰噪声时

表现最差。随着噪声水平的提高,算法在去除高斯和尖峰噪声时的速度特征保留能力没有明显变化趋势。

表 1 不同噪声干扰下 SSB-LSTM 的车辆速度估计误差指标

Table 1 Error indicators for vehicle speed estimation of SSB-LSTM under different noise interferences

噪声水平/($\text{km}^2 \cdot \text{h}^{-2}$)	高斯噪声		泊松噪声		尖峰噪声	
	PSNR/dB	SSIM	PSNR/dB	SSIM	PSNR/dB	SSIM
5	20.98	0.58	22.09	0.31	18.13	0.41
10	23.20	0.24	22.65	0.28	20.30	0.47
15	20.44	0.41	22.67	0.28	18.37	0.37
20	21.66	0.36	23.28	0.25	17.28	0.37

算法去除速度噪声与实际添加的速度噪声之差的箱线分布如图 5 所示。就高斯噪声而言,随着噪声方差从 $5 \text{ km}^2/\text{h}^2$ 增加到 $20 \text{ km}^2/\text{h}^2$,SSB-LSTM 算法去除的噪声均值较实际值略低 4.23 km/h,但降噪误差的方差从 $63.41 \text{ km}^2/\text{h}^2$ 扩大到 $437.72 \text{ km}^2/\text{h}^2$ 。可以得出以下结论:在处理高斯噪声时,算法对大方差噪声的去除能力较弱。算法去除的泊松噪声与实际值的差距随噪声方差的增加从 3.91 km/h 逐渐增加了 4.50、7.90、14.42 km/h,相应的降噪误差方差从 $23.51 \text{ km}^2/\text{h}^2$ 扩大到 $37.31 \text{ km}^2/\text{h}^2$ 。在不同噪声水平下,算法在车

辆速度估计过程中,去除尖峰噪声的误差均值与方差都较为稳定,分别为 35.68 、 $36.62 \text{ km}^2/\text{h}^2$ 。

3.5 不同算法的车辆速度估计性能对比

本节选取若干常用的速度估计算法与 SSB-LSTM 进行比较,选取的对比算法包括 LWR 模型、集合卡尔曼滤波方法(Ensemble Kalman filtering, EnKF)、Noise2Void。LWR 模型依据其表征的交通流运行规律来估算交通数据。EnKF 是通过分析数据变化趋势来去除误差干扰的典型算法。Noise2Void 为目前先进的自监督降噪智能算法。




图 5 速度估计中算法去除的噪声与实际噪声间的绝对误差箱线图

Fig. 5 Box plot of absolute error between the noise removed by the algorithm in speed estimation and the actual noise

在真实车辆速度数据集上,各算法车辆速度估计误差指标 PSNR 与 SSIM 的取值如图 6 所示。总体上,SSB-LSTM 的 PSNR 与 LWR、EnKF、Noise2Void 相比分别高 31.18%、46.38% 以及 9.22%。SSB-LSTM 算法对车辆速度数据中噪声误差的去除能力比其他算法更强。SSB-LSTM 算法的 SSIM 比 LWR 大 0.53,比 EnKF、Noise2Void 分别小 0.24 和 0.12。这说明 SSB-LSTM 保留速度特征的能力比 EnKF、Noise2

Void 更强,但弱于 LWR。这可能是因为 LWR 模型表达的交通流规律能够在估计时有效辅助提取速度数据的特征。在采样间隔 10 min 的 GPS 数据下,SSB-LSTM 的 PSNR 与时间间隔 1 min 相比下降了 17.96%。这是因为采样间隔过大,速度数据点间的相关关系较弱,SSB-LSTM 利用相邻数据求解速度的可靠性也降低。

在合成车辆速度数据集上,上述算法在不同噪声干扰下速度估计的 PSNR 与 SSIM 如图 7~图 9




图 6 不同算法在真实车辆速度数据集上的估计误差对比

Fig. 6 Comparison of estimation errors of different algorithms on real vehicle speed dataset




图 7 不同算法在合成高斯噪声数据上的速度估计误差对比

Fig. 7 Comparison of speed estimation errors of different algorithms on synthetic Gaussian noise data




图 8 不同算法在合成泊松噪声数据上的速度估计误差对比

Fig. 8 Comparison of speed estimation errors of different algorithms on synthetic Poisson noise data

所示。与 LWR 模型、EnKF 模型相比,SSB-LSTM 在高斯噪声、泊松噪声、尖峰噪声干扰下取得的 PSNR 分别高 4.27、11.10 以及 9.16 dB,SSIM 分别高 0.60、1.15 以及 1.01。SSB-LSTM 去除速度数据中各类型噪声的能力比 LWR、EnKF 更强,但

保留交通流本征的能力较弱。与 Noise2Void 模型相比,SSB-LSTM 去除高斯噪声的能力较弱,而去除尖峰噪声的能力更强。这说明 SSB-LSTM 利用双向 LSTM 分析交通流数据变化趋势,对车辆故障等突变因素导致的尖峰噪声有更强的平滑能力。而




图9 不同算法在合成尖峰噪声数据上的速度估计误差对比

Fig. 9 Comparison of speed estimation errors of different algorithms on synthetic Peak noise data

Noise2Void 模型在估计车辆速度时不利用中心数据点的信息,限制了去除误差干扰的精度。

4 结 论

(1)在应对单 GNSS 系统数据采样稀疏性方面,SSB-LSTM 估计车辆速度的 PSNR 和 SSIM 平均值为 26.73 dB 和 0.09,证实了算法在单 GNSS 环境下估计速度的有效性。随着车辆速度数据采样时间间隔从 1 min 增加至 10 min,SSB-LSTM 去除的噪声逐渐减少,但保留速度特征的能力逐渐增强。

(2)对于车辆速度数据中包含的高斯、泊松、尖峰等不同类型的噪声干扰,SSB-LSTM 算法去除量均大于为 18 km/h。同时,随噪声水平从 5 km²/h² 提高至 20 km²/h²,算法去除车辆速度中噪声干扰的能力表现稳定。这说明提出的 SSB-LSTM 在车辆速度估计中,对由驾驶个性、车辆工况突变等因素产生的噪声具有较好的去除效果。

(3)算法在去除车辆速度数据中噪声干扰的过程中,易滤除部分关键速度特征。未来研究可在算法中引入关于交通流规律、速度时空分布特征等先验信息,在保障算法尽可能多去除数据噪声的基础上,提升算法对车辆速度的估计精度。

参考文献:

[1] 闵海根,方煜坤,吴霞,等. 弱 GNSS 信号下基于 EMD 和 LSTM 的车辆位置预测方法研究[J]. 中国公路学报, 2021, 34(7): 128-139.
Min Hai-gen, Fang Yu-kun, Wu Xia, et al. Position prediction based on empirical mode decomposition

and long short-term memory under global navigation satellite system outages[J]. China Journal of Highway and Transport, 2021, 34(7): 128-139.

[2] Shen C, Zhang Y, Tang J, et al. Dual-optimization for a MEMS-INS/GPS system during GPS outages based on the cubature Kalman filter and neural networks[J]. Mechanical Systems and Signal Processing, 2019, 133:No. 106222.
[3] Yao Y Q, Xu X S, Zhu C C, et al. A hybrid fusion algorithm for GPS/INS integration during GPS outages[J]. Measurement, 2017, 103: 42-51.
[4] Lehtinen J, Munkberg J, Hasselgren J, et al. Noise2Noise: learning image restoration without clean data[C]//International Conference on Machine Learning, Stockholm, Sweden, 2018: 2965-2974.
[5] Moran N, Dan S, Yu Z, et al. Noisier2Noise: learning to denoise from unpaired noisy data[C]//IEEE Conference on Computer Vision and Pattern Recognition, Seattle, USA, 2020: 12061-12069.
[6] Krull A, Buchholz T O, Jug F. Noise2Void-Learning denoising from single noisy images[C]//IEEE Conference on Computer Vision and Pattern Recognition, Long Beach, USA, 2019: 2124-2132.
[7] 刘雪梅,程彭圣男,李海瑞,等. 基于字词向量的 BiLSTM-CRF 水利工程巡检文本实体识别模型[J]. 华北水利水电大学学报: 自然科学版, 2023(3): 9-17.
Liu Xue-mei, Chengpeng Sheng-nan, Li Hai-rui, et al. Research on text entity recognition for water project inspection based on word-character vector BiLSTM-CRF[J]. Journal of North China University of Water Resources and Electric Power, 2023(3): 9-17.
[8] 崔丽霞,许利显. 基于 Bi LSTM-CTC 的语音识别系统研究[J]. 自动化与仪器仪表, 2023 (10): 90-94.

- Cui Li-xia, Xu Li-xian. Research on speech recognition system based on BiLSTM-CTC[J]. Automation & Instrumentation, 2023 (10):90-94.
- [9] 苏兆品, 张玲, 张国富, 等. 基于多特征融合和 BiLSTM 的语音隐写检测算法[J]. 电子学报, 2023, 51(5): 1300-1309.
- Su Zhao-pin, Zhang Ling, Zhang Guo-fu, et al. A speech steganalysis algorithm based on multi-feature fusion and BiLSTM[J]. Acta Electronica Sinica, 2023, 51(5): 1300-1309.
- [10] 付翔, 肖帅, 徐超. 轮毂电动机驱动车辆并联式复合制动策略[J]. 江苏大学学报: 自然科学版, 2025, 46(1): 9-17.
- Fu Xiang, Xiao Shuai, Xu Chao. Parallel compound braking strategy of vehicle driven by wheel motor[J]. Journal of Jiangsu University(Natural Science Edition), 2025, 46(1): 9-17.
- [11] Guo S, Yan Z F, Zhang K, et al. Toward convolutional blind denoising of real photographs[C]//IEEE Conference on Computer Vision and Pattern Recognition, Long Beach, USA, 2019: 1712-1722.
- [12] He K M, Chen X L, Xie S N, et al. Masked autoencoders are scalable vision learners[C]//IEEE Conference on Computer Vision and Pattern Recognition, New Orleans, USA, 2022: 15979-15988.
- [13] Cui Z Y, Ke R M, Pu Z Y, et al. Stacked bidirectional and unidirectional LSTM recurrent neural network for forecasting network-wide traffic state with missing values[J]. Transportation Research Part C: Emerging Technologies, 2020, 118(9): No. 102674.
- [14] Lv Y S, Duan Y J, Kang W W, et al. Traffic flow prediction with big data: a deep learning approach[J]. IEEE Transactions Intelligent Transportation Systems, 2015, 16(2): 865-873.
- [15] Do L N N, Vu H L, Vo B Q, et al. An effective spatial-temporal attention based neural network for traffic flow prediction[J]. Transportation Research Part C: Emerging Technologies, 2019(108): 12-28.
- [16] 贾现广, 冯超琴, 苏治文, 等. 城市交通网格集群的 Bi-LSTM 的流量预测[J]. 重庆大学学报, 2023, 46(9): 130-141.
- Jia Xian-guang, Feng Chao-qin, Su Zhi-wen, et al. Forecasting for urban traffic grid clusters based on Bi-LSTM[J]. Journal of Chongqing University, 2023, 46(9): 130-141.
- [17] Graves A, Jaitly N, Mohamed A R. Hybrid speech recognition with deep bidirectional lstm[C] //IEEE Workshop on Automatic Speech Recognition and Understanding, Olomouc, Czech Republic, 2013: 273-278.