

基于深度学习的船舶惯导与卫导信息深度融合方法

王喜龙

海军装备部, 天津 300061

[摘要] 针对船舶惯性导航系统 (INS) 存在累积误差、卫星导航系统 (GNSS) 易受复杂海洋环境干扰导致定位精度下降的问题, 提出一种基于深度学习的船舶惯导与卫导信息深度融合方法。分析船舶惯导与卫导信息的特性及融合难点, 构建融合系统的整体架构; 设计基于 CNN-GRU 混合网络的信息预处理模块, 实现对两类导航信息的噪声抑制与特征提取; 构建基于注意力机制的深度融合模型, 动态调整两类信息的权重分配; 通过仿真实验验证传统融合方法 (UKF、EKF) 的应用效果。基于深度学习的船舶惯导与卫导信息深度融合方法的抗干扰能力、定位精确度均提高。

[关键词] 深度学习; 船舶导航; 惯性导航; 卫星导航; 信息融合

DOI: 10.33142/sca.v9i4.19577

中图分类号: TP391.41

文献标识码: A

Deep Fusion Method of Ship Inertial Navigation and Satellite Navigation Information Based on Deep Learning

WANG Xilong

Naval Equipment Department, Tianjin, 300061, China

Abstract: A deep learning based method for deep fusion of ship inertial navigation system (INS) and satellite navigation system (GNSS) information is proposed to address the problems of accumulated errors in INS and decreased positioning accuracy caused by complex marine environment interference in GNSS. Analyze the characteristics and fusion difficulties of ship inertial navigation and satellite navigation information, and construct the overall architecture of the fusion system; Design an information preprocessing module based on CNN-GRU hybrid network to achieve noise suppression and feature extraction for two types of navigation information; Build a deep fusion model based on attention mechanism, dynamically adjust the weight allocation of two types of information; Verify the application effect of traditional fusion methods (UKF, EKF) through simulation experiments. The anti-interference ability and positioning accuracy of the deep fusion method of ship inertial navigation and satellite navigation information based on deep learning have been improved.

Keywords: deep learning; ship navigation; inertial navigation; satellite navigation; information fusion

引言

为满足日益增长的海上作业精度需求, 船舶导航技术需保证其在复杂的海洋环境中具有较高的可靠性。当前, 惯性导航 (INS) 具有自身定位及短期精度高等优点, 但是长期存在累积漂移的问题; 而卫星导航 (GNSS) 虽然具有良好的定位稳定性, 但在遭受较强的外界干扰或者遭遇极端天气的情况下, 容易产生失真甚至丢失的情况。因此将二者相结合成为一种发展趋势。但传统卡尔曼滤波等融合算法过于依赖准确的数学模型及噪声统计信息, 并不能很好地处理时变性以及非线性的现实海洋环境噪声。本文通过设计 CNN-GRU 混合网络进行信息预处理, CNN 负责提取空间特征, GRU 捕捉时间序列的动态演变; 结

合注意力机制实现自适应加权, 使系统能自动学习惯导与卫导信息的内在关联, 为船舶在极端环境下的高精度航行提供技术支撑。

1 船舶惯导与卫导信息特性及融合难点

1.1 惯导与卫导信息特性分析

舰载 INS 主要包括惯性测量装置 (IMU)、导航计算单元及显示器, 其中 IMU 是其核心部分, 它由陀螺仪和加速度计组成。陀螺仪用来测量舰船的角速度, 而加速度计则用来测量舰船的线加速度, 导航计算单元是对 IMU 的输出角速度及加速度积分得到, 配合初始导航参数得出船位、航速及姿态。INS 的特点就是自主性好, 不依赖外界信号, 在复杂的环境中也能不断地输出导航信息, 但是

陀螺仪和加速度计具有漂移误差(例如随机漂移、温度漂移),随着时间的推移,其定位误差会越来越严重。

船舶 GNSS 是一种通过接收机接收卫星播发的导航信号,并利用卫星轨道参数计算出船舶的位置、速度和时间的设备。GNSS 具有定位精度高、无累积误差等特点,可进行全圆周导航,但是容易受到外界环境的影响,其定位误差主要由卫星轨道误差、电离层误差、对流层误差、多路径效应以及电磁干扰引起。

INS 和 GNSS 的信息特性对比如表 1 所示,两者的互补性为信息融合提供了基础:INS 的短时高精度的优势可以弥补 GNSS 信号中断时的定位需求,而 GNSS 的无累积误差优势可以校正 INS 的累积误差,实现优势互补,提升导航系统的整体性能。

表 1 INS 和 GNSS 的信息特性对比

导航系统	优点	缺点	误差特性
INS	自主性强、短时精度高、抗干扰强、输出连续	长期误差累积、初始对准复杂	随时间二次增长,存在漂移误差
GNSS	无累积误差、定位精度高、全天候、全球覆盖	易受干扰、信号易中断、依赖外部信号	误差稳定,受环境干扰影响大

1.2 惯导与卫导信息融合难点

船舶惯导与卫导信息融合的主要目的是利用两种信息的互补性实现高精度、高可靠的导航定位,但是由于船舶的复杂航行环境以及两种信息特点的不同导致融合过程中的困难有:

(1) 非线性、非平稳问题。由于在海上航行中会受到海况的影响,如风浪、洋流等,因此 INS 的误差存在强烈的非线性、时变性,并且 GNSS 的定位误差也会随着环境的变化而发生变化,所以将两者的信息进行融合也具有很强的非线性特点,传统上采用的线性融合的方法很难满足这一条件;集成精度有限。

(2) 噪声抑制难度大。INS 的 IMU 存在随机漂移、温度漂移等噪声,GNSS 信号存在多路径效应、电磁干扰等噪声,这些噪声具有随机性、非平稳性等特点,难以通过传统的滤波方法完全抑制,噪声会严重影响导航信息的质量,进而降低融合精度。

(3) 权重配置不当。现有融合算法多为静态加权法,在不同导航环境下及不同类型信息质量变化的情况下不能自适应地对信息进行最优加权组合。如 GNSS 定位解算中,当受到外界因素的影响导致 GNSS 的定位精度降低时,

若继续采用固定的加权因子,则会使融合的结果会因 GNSS 带来的误差而产生较大的偏差;当 INS 产生的误差过大时,固定权值不能有效发挥 GNSS 的校正效果。

(4) 时空同步问题。INS 和 GNSS 的采样频率不同(INS 采样频率通常为 100Hz~1000Hz,GNSS 采样频率通常为 1Hz~10Hz),且两类系统的时间基准存在差异,导致两类信息存在时空不同步问题,若不进行同步处理,会引入额外的融合误差。

2 基于深度学习的船舶惯导与卫导信息深度融合方法设计

2.1 信息采集与预处理模块

信息采集模块的核心功能是获取船舶惯导系统和卫星导航系统的原始导航信息,为后续融合处理提供数据基础。采集的惯导信息包括:陀螺仪输出的角速度(滚转角速度、俯仰角速度、航向角速度)、加速度计输出的线加速度(x轴、y轴、z轴加速度),以及导航计算机计算得到的位置(经度、纬度、高度)、速度(东向速度、北向速度、天向速度)信息;采集的卫导信息包括:GNSS 接收机输出的位置(经度、纬度、高度)、速度(东向速度、北向速度、天向速度)信息,以及信号强度、定位精度因子(PDOP)等辅助信息。

由于采集的原始导航信息中存在大量噪声和异常值,会影响后续融合精度,因此需要对原始信息进行预处理,预处理步骤包括:

(1) 异常值剔除。采用 3σ 准则剔除原始数据中的异常值,即当某一数据点与数据集的均值之差大于 3 倍标准差时,判定为异常值并剔除,避免异常值对融合结果的影响。

(2) 归一化处理。由于惯导与卫导信息的量纲不同(如角速度单位为 rad/s,加速度单位为 m/s^2 ,位置单位为度),直接融合会导致模型训练困难,因此需要对预处理后的 data 进行归一化处理。

(3) 数据补全。GNSS 信号可能出现短暂中断,导致部分数据缺失,采用线性插值法对缺失数据进行补全,确保数据的连续性,为后续时空同步和特征提取提供完整的数据支撑。

2.2 时空同步模块

INS 和 GNSS 的采样频率不同,且时间基准存在差异,导致两类信息存在时空不同步问题,若不进行同步处理,会引入额外的融合误差。因此,本文设计时空同步模块,实现惯导与卫导信息的时空对齐。

时间同步方面,以 INS 的时间基准为参考,对 GNSS 数据进行插值处理,将 GNSS 的低采样频率数据(1Hz~

10Hz) 插值到 INS 的高采样频率 (100Hz), 确保两类信息的时间戳一致。采用线性插值法进行时间同步, 假设 GNSS 在时刻 t_1 和 t_2 的输出数据分别为 x_1 和 x_2 , 则在时刻 ($t_1 < t < t_2$) 的插值数据 $x(t)$ 为:

线性插值的核心逻辑为: 若已知两个不同时刻的 GNSS 输出数据, 可通过两个时刻的时间差值与数据差值, 计算出两个时刻之间任意时刻的 GNSS 插值数据, 实现时间同步。

空间同步方面, 由于 INS 和 GNSS 的坐标系可能不一致 (INS 多使用导航坐标系, GNSS 使用大地坐标系), 因此需要进行坐标系变换, 将二者的信息统一到同一个坐标系中 (文中采用大地坐标系)。利用坐标转换矩阵将来自 INS 的导航参数 (位置、速度) 转换为大地坐标系中的参数, 实现空间同步。

通过时空同步模块, 实现了惯导与卫导信息的时间戳对齐和坐标系统一, 为后续的特征提取和深度融合奠定了基础。

2.3 CNN-GRU 混合网络特征提取与噪声抑制模块

惯导与卫导信息中包含大量的噪声和冗余信息, 直接进行融合会影响融合精度, 因此需要设计特征提取与噪声抑制模块, 挖掘两类信息的关键特征, 抑制噪声干扰。本文采用 CNN-GRU 混合网络作为特征提取与噪声抑制模块, 结合 CNN 的空间特征提取能力和 GRU 的时间序列建模能力, 实现对导航信息的深度处理。

2.3.1 CNN 特征提取子模块

卷积神经网络 (CNN) 具有强大的空间特征提取能力, 自动提取数据中的局部特征和关键信息, 抑制噪声干扰, 具体结构如下:

(1) 卷积层: 采用 3×3 的卷积核, 卷积核数量分别为 32、64、128, 步长为 1, 填充方式为 “same”, 确保卷积后特征图的尺寸与输入尺寸一致。卷积层的作用是提取导航信息中的局部空间特征, 捕捉惯导与卫导信息的局部关联。

(2) 批归一化层: 对卷积层的输出进行批归一化处理, 加快模型训练速度, 避免梯度消失或梯度爆炸问题, 提升模型的稳定性。

ReLU 激活函数的核心逻辑为: 当输入值大于 0 时, 输出值等于输入值; 当输入值小于等于 0 时, 输出值为 0, 通过这种方式引入非线性因素, 缓解梯度消失问题。

(4) 池化层: 采用最大池化, 池化核尺寸为 2×2 , 步长为 2, 用于对卷积层提取的特征进行降维, 减少模型参数, 同时保留关键特征, 抑制噪声干扰。

CNN 子模块的输入为时空同步后的惯导与卫导信息序列, 输出为提取的局部空间特征, 通过 CNN 子模块, 能够有效抑制导航信息中的噪声, 提取关键的空间特征。

2.3.2 GRU 时间序列建模子模块

门控循环单元 (GRU) 是一种改进型 RNN, 在一定程度上可缓解 RNN 的梯度消失和梯度爆炸现象, 具有较强的时间序列建模能力, 可以捕获导航信息的时间相关性。船舶导航信息存在显著的时间序列特性 (INS 的误差随时间积累, GNSS 的信号质量随时间变化), 所以使用 GRU 子模块来对 CNN 提取到的空间特征进行时间序列建模, 挖掘信息的时间关联。

本文设计的 GRU 子模块由 2 个 GRU 层和 1 个 dropout 层组成, 具体结构如下:

(1) GRU 层: 隐藏层单元数量为 128, 采用 tanh 激活函数, 用于对 CNN 提取的空间特征进行时间序列建模, 捕捉导航信息的时间相关性, 挖掘惯导误差累积规律和 GNSS 信号质量变化规律。

(2) dropout 层: dropout 概率设置为 0.5, 用于防止模型过拟合, 提升模型的泛化能力, 确保模型在不同导航环境下均能稳定工作。

GRU 子模块的输入为 CNN 子模块输出的空间特征序列, 输出为融合了时空特征的高维特征向量, 该特征向量既包含了导航信息的关键特征, 又捕捉了时间相关性, 为后续的深度融合提供了高质量的特征支撑。

通过 CNN-GRU 混合网络模块, 实现了对惯导与卫导信息的噪声抑制和特征提取, 有效去除了冗余信息和噪声干扰, 提取了能够反映导航信息本质的时空特征, 为后续的自适应加权融合奠定了基础。

2.4 注意力机制深度融合模块

缩放点积注意力机制用于对 INS 特征和 GNSS 特征进行自适应加权融合。分别将两者的特征向量转换成查询、键、值向量后进行点积操作并使用缩放因子计算相似度, 经过 SoftMax 函数后获得自适应变化的权重, 最后依据权重对特征进行线性加权, 最后经过全连接网络进行预测得到最终的导航信息。由于该方法采用的是可学习权值, 并不是固定的权值, 因此可以对当前的状态做出反应, 例如当 GNSS 捕获到较强的信号时, 会增大 GNSS 权值来修正导航误差; 而当 GNSS 接收机受到较大干扰时, 则会增加 INS 的短期稳定性, 提高鲁棒性。

3 仿真实验与结果分析

3.1 仿真实验设置

采用 MATLAB 软件搭建仿真平台, 设置船舶航行轨

迹为匀速直线航行,航行时间为 1000s,航行速度为 10m/s。

(1) INS 参数:陀螺仪随机漂移为 $0.01^\circ/\text{h}$,加速度计随机误差为 $100\mu\text{g}$,采样频率为 100Hz,初始定位误差为 10m,初始速度误差为 0.1m/s。

(2) GNSS 参数:正常情况下定位误差为 1m,采样频率为 10Hz;在 200s~300s 和 700s~800s 两个时间段,模拟 GNSS 信号受干扰,定位误差增大至 10m,信号强度降低 50%。

3.2 仿真结果分析

综上所述,与其它算法相比,该方法具有更高的定位精度、更强的鲁棒性和更好的收敛性。这是由于 CNN-GRU 能够降低噪声影响,挖掘有效信息,并在一定程度上为后处理提供了质量较高的数据;另外,基于注意力机制的设计弥补了固定权重分配比带来的弊端,可根据当前 GNSS 和 INS 的可靠性计算二者间的加权系数。GNSS 在正常状态下提供高精度的误差修正,在受到干扰的情况下主动减小 GNSS 权重来依靠 INS,既极大地降低了位置估计值的方差又保证了在恶劣环境下的导航参数平稳可信。有效克服了惯性导航系统误差积累及卫星导航系统容易受到干扰的问题,实现了船舶全天候精确导航的要求。

4 结论与展望

CNN-GRU 与注意力机制深度融合模型的提出可以有效提高船舶导航的精度与稳定性,有效破解了以往 INS

累积误差与 GNSS 易受干扰的难题。在今后的研究中为了进一步提高该融合模型的工程实用性与环境适应力,在研究过程中积极引入 Transformer 优化实时性,并通过开展多源信息融合与海试实验进行验证。

【参考文献】

- [1]严新平,刘佳仑,张煜,等.智能航运的研究现状与展望[J].现代交通与冶金材料,2022,2(1):7-18.
- [2]李伟,张军,宁君,等.基于改进蚁群算法的船舶路径规划及跟踪控制[J].舰船科学技术,2022,44(7):68-73.
- [3]丁志国,张新宇,王程博,等.基于驾驶实践的无人船智能避碰决策方法[J].中国舰船研究,2021,16(1):96-104.
- [4]郝琨,张慧杰,李志圣,等.基于改进避障策略和双优化蚁群算法的机器人路径规划[J].农业机械学报,2022,53(8):303-312.
- [5]于巧婵,陈香玉,李亚斌,耿雄飞,杜尊峰.智能船舶综合测试技术体系与测试要求分析[J].船舶工程,2021,43(1):365-371.
- [6]王立林,刘俊.基于多尺度卷积的船舶行为识别方法[J].计算机应用,2019,39(12):3691-3696.
- [7]刘磊,张永,张明阳,王永明,陈静.多特征融合的船舶轨迹相异度模型分析与优选[J].交通运输工程学报,2021,21(5):199-213.

作者简介:王喜龙(1981—),毕业于哈尔滨工程大学通信工程专业,现就职于海军装备部,副高级工程师。