

基于深度学习的民航卫星导航完整性监测

Maosen Lin

香港理工大学 香港

【摘要】GPS、伽利略、格洛纳斯和北斗等卫星导航系统提供需要高精度和高可靠的全球定位和授时服务。监控这些系统的性能对于确保精确且强大的导航能力至关重要。传统的监测技术通过分析卫星数据来评估导航精度和服务质量。诸如精度因子 (DOP) 和定位误差等关键参数是根据卫星几何形状和测量值进行评估的。然而，这些方法在对复杂的性能因素进行随时间变化的建模时存在局限性。深度学习的最新进展为增强卫星导航监测提供了新的机遇。深度神经网络可以揭示海量卫星数据中隐藏的模式和动态。卷积神经网络 (CNN) 和长短期记忆网络 (LSTM) 等模型分别非常适合卫星图像处理和时间序列预测任务。深度学习方法可以融合来自全球传感器网络的多源数据，从而全面了解系统性能。神经网络可以学习原始卫星观测数据与 DOP、时间漂移和定位精度等质量指标之间的复杂映射。循环模型还可以根据检测到的趋势预测未来的性能下降。关键研究重点包括收集高质量的训练数据、选择网络架构以及解释模型输出。挑战包括推广到未知缺陷和新的卫星星座。有了充足的数据和验证，深度学习可以显著改善卫星监测，从而随着系统规模的扩大和发展实现稳健的导航。总而言之，深度学习在增强卫星导航质量评估和预测方面拥有巨大的潜力。通过严谨的研究，自动化深度学习有望成为全球可靠高精度定位不可或缺的技术。这些技术的成熟及其与现有监测基础设施的整合前景光明。

【关键词】全球导航卫星系统 (GNSS)；深度学习；长短期记忆网络 (LSTM)；精度因子 (DOP)

【收稿日期】2025 年 6 月 3 日 **【出刊日期】**2025 年 7 月 9 日 **【DOI】**10.12208/j.ae.20250002

Civil aviation satellite navigation integrity monitoring with deep learning

Maosen Lin

The Hong Kong Polytechnic University, Hong Kong

【Abstract】Satellite navigation systems like GPS, Galileo, GLONASS and BeiDou provide global positioning and timing services that require high accuracy and reliability. Monitoring the performance of these systems is crucial for ensuring precise and robust navigation capabilities. Traditional monitoring techniques analyze satellite data to assess navigation accuracy and service quality. Key parameters like dilution of precision (DOP) and positioning errors are evaluated based on satellite geometry and measurements. However, these methods have limitations in modeling complex performance factors over time. Recent advances in deep learning provide new opportunities to enhance satellite navigation monitoring. Deep neural networks can uncover hidden patterns and dynamics in large volumes of satellite data. Models like convolutional neural networks (CNN) and long short-term memory (LSTM) are well-suited for satellite image processing and time series forecasting tasks respectively. A deep learning approach can fuse multi-source data from global sensor networks for a comprehensive view of system performance. The neural networks can learn complex mappings between raw satellite observations and quality metrics like DOP, timing drifts and positioning accuracy. Recurrent models can also estimate future degradations based on detected trends. Key research priorities include assembling high-quality training data, selecting network architectures, and interpreting model outputs. Challenges include generalizing to unseen defects and new satellite constellations. With sufficient data and

注：本文于 2023 年发表在 Advances in Computer and Communications 期刊 4 卷 4 期，此文为其授权翻译版本。

validation, deep learning can significantly improve satellite monitoring to enable robust navigation as systems scale and evolve. In summary, deep learning holds substantial promise for enhancing satellite navigation quality assessment and prediction. With rigorous research, automated deep learning could become an integral technology for reliable high-precision positioning across the globe. The outlook is positive for these techniques to mature and integrate with existing monitoring infrastructure.

【Keywords】 Global Navigation Satellite System (GNSS); Deep learning; Long Short-Term Memory (LSTM); Dilution of Precision (DOP)

1 简介

GPS、伽利略和北斗等全球导航卫星系统提供全球定位、导航和授时（PNT）服务，为交通运输、电信、农业和其他领域的定位技术提供支持。这些服务的可靠性和准确性对于公共安全和经济功能至关重要。然而，GNSS 的性能受多种复杂因素的影响，包括卫星几何形状、信号失真、空间天气和干扰。定位误差和授时偏差在不同地点和时间可能存在显著差异。为了维持稳健的 PNT 服务，对 GNSS 进行客观、多维度的监测至关重要。持续评估性能指标可以洞察新出现的漏洞，并指导采取先发制人的改进措施。

监测的关键参数包括精度因子（DOP）、授时精度、定位误差和服务可用性。这些质量指标是通过全球传感器网络和卫星遥测收集数据得出的。当代监测依赖于统计方法和基于物理的模型。机器学习和人工智能等先进技术可以从性能数据中揭示更深层次的模式和动态。自动化分析可以检测到细微的异常，并提前预测未来的中断。这将为运营商和用户提供可操作的信息，用于服务维护和应急计划。随着全球导航卫星系统（GNSS）随着新星座和双频的出现而日益复杂，智能监测将至关重要。对稳健监测的研究和基础设施的投资将确保全球 PNT 服务在不确定性日益增加的情况下仍能不间断地运行。国际合作对于汇编各种性能数据和制定稳健的质量标准也至关重要。总而言之，可靠的 GNSS 性能对于全球功能至关重要，需要主动监测和缓解措施。基于人工智能和大数据的智能评估将有助于确保无缝定位和授时服务。

对多传感器数据融合和先进算法的全面研究将使完整性监测能力能够满足 GNSS 日益增长的复杂性和用户需求。这对于确保未来几十年全球精密 GNSS 服务的可用性、连续性和可靠性至关重要。面对传统的评估监测技术，监测模型主要从多指标角

度构建，例如四大性能指标的关系模型、服务量模型（SVM）、并行递归 GNSS 性能评估模型等，但这些模型通常侧重于当前时刻的预测，难以处理时间序列信息。因此，一些研究利用星历数据对未来进行预测^[1,2]。

近年来，随着深度学习和大数据的浪潮，越来越多的领域采用大数据驱动的深度学习方法来获得更优的性能^[3]。随着算力技术的增强，深度学习技术在时间序列预测、自动驾驶等诸多领域展现出其强大的能力。长短期记忆网络^[4]是一种处理时间序列的有效模型，已被广泛应用于不同的神经网络结构中来解决预测需求。为了获得更准确可靠的 GNSS 服务性能预测精度，本文提出了一种基于长短期记忆（LSTM）神经网络的 GNSS 服务性能预测方法，该方法可以减少长期连续 GNSS 服务性能预测方法的计算量，并能够监测位置精度衰减（PDOP）和定位精度的发展趋势。具体而言，该方法需要对各卫星监测站的服务性能观测结果进行预处理，监测 PDOP 和定位精度的数据变化情况，从而比较不同卫星系统的性能。然后利用 LSTM 对不同卫星系统的 PDOP 趋势和定位精度进行预测。与基于星历数据的方法相比，LSTM 预测方法可以有效地监测和预警服务性能变化趋势，从而在更大程度上降低 GNSS 系统误差的不利影响，提高系统导航服务质量。

2 深度学习

神经网络（NN）是一种模拟人脑神经元之间信息传输和处理方式的计算机算法。它由一系列相互连接的神经元组成，负责处理输入数据并产生输出结果。神经网络可以通过学习数据样本的模式来自动识别、分类或预测新数据。它已被广泛应用于图像识别、语音识别、自然语言处理、推荐系统等各个领域。

神经网络的灵感源自动物大脑中的生物神经网

络。它们由多层简单的计算单元（称为神经元）组成，这些单元通过加权连接相互连接。每个神经元接收来自多个其他神经元的输入，将它们聚合起来，然后应用激活函数来确定其输出。神经元之间的连接具有数值权重，这些权重在训练期间会进行调整，以增强或减弱通过网络的信号。这种权重调整被称为反向传播，它使神经网络能够从样本中学习复杂的输入-输出映射。神经网络通常具有一个用于接收数据的输入层、一个用于生成预测的输出层，以及介于两者之间的一个或多个用于提取特征表示的隐藏层。深度神经网络具有许多隐藏层，可以实现分层特征学习。常见的神经网络架构包括卷积神经网络（CNN）、循环神经网络（RNN）和Transformer网络。

CNN 非常适合处理像图像这样的像素阵列。RNN 擅长于像文本和时间序列这样的具有记忆的序列建模。Transformer 是基于注意力机制的模型，适用于多种数据类型。神经网络具有通用函数逼近能力，这意味着只要有足够的数据、层和训练，它们几乎可以重建任何输入输出关系。这使得它们对于手动编程算法难以完成的复杂感知任务极具吸引力。它们的灵活性使其在计算机视觉、自然语言处理、预测、推荐等领域得到广泛应用。然而，神经网络需要大量的训练数据和计算能力。解读其内部表征仍然具有挑战性。正在进行的研究重点是提高训练效率、模型解读、不确定性估计和其他能力，以扩展神经网络在各行各业的适用性。

神经网络通常使用反向传播进行训练。反向传播是一种广泛应用于训练人工神经网络的技术，它通过最小化网络的误差或损失函数来调整神经网络的权重。该算法的工作原理是将误差在网络中反向传播，从输出层到输入层。在每一层，误差乘以激活函数的导数，然后使用梯度下降来更新网络的权重。权重的更新规则如下：

$$\Delta W = -\eta \frac{\partial E}{\partial w}$$

其中 Δw 是梯度， η 是学习率， E 是误差函数， $\frac{\partial E}{\partial w}$ 是误差关于权重的偏导数。反向传播中通常使用的误差函数是均方误差（MSE），其定义为：

$$E = \frac{1}{2} \sum_i (y^i - \hat{y}^i)^2$$

其中 y^i 是目标输出， \hat{y}^i 是预测输出，总和是对所有数据取的。

长短期记忆网络（LSTM）是一种特殊的循环神经网络（RNN），通过加入门控机制解决了传统 RNN 中的梯度消失和梯度爆炸问题，有效地实现了时间序列的建模。

LSTM 的主体结构由三个门组成：输入门、忘记门和输出门。其中，输入门和忘记门用于控制是否将当前输入和前一时刻的状态添加到记忆单元，输出门用于控制从记忆单元输出的信息量。

LSTM 的记忆细胞由当前输入、前一时刻的记忆细胞以及门控信号的加权和构成，具体表达式如下：

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{c}_t$$

其中， c_t 表示当前时刻的记忆单元， f_t 表示遗忘门， i_t 表示输入门， \tilde{c}_t 表示当前时刻的输入与前一时刻的状态的加权和， \odot 表示相应元素的乘积。

LSTM 的输出由记忆单元和输出门决定，具体表达式如下：

$$h_t = o_t \odot \tanh(c_t)$$

其中， h_t 表示当前时刻的输出， o_t 表示输出门， \tanh 表示双曲正切函数。

3 卫星导航监测与分析原理

目前，我国自主研发的卫星导航系统是北斗卫星系统，该系统在实际导航中提供了精确的卫星导航服务，取得了令人瞩目的服务效果。因此，这里以北斗卫星为例，简要介绍卫星导航系统服务质量评估的基本原则。北斗系统公共服务性能规范对空间信号性能和服务性能进行了约束。我国自主研发的北斗导航卫星系统通过提供高精度定位、导航和授时服务，已广泛应用于国民经济的各个领域。为保障北斗系统持续稳定地提供高质量服务，需要建立科学的性能监测与评估体系。北斗系统服务性能主要包括服务精度和服务可用性两个方面。服务精度是反映北斗系统提供导航、定位和授时服务精度的重要指标，主要通过定位精度、测速精度和授时精度进行评估。业务可用性反映北斗系统服务的连续性，包括定位可用性和定位精度可用性。北斗公共服务性能规范对上述业务性能指标做出了明确规定。例如，面向全球用户，水平定位精度需达到 10 米，测速精度需达到 0.2 米/秒，授时精度需控制在

30 纳秒以内。所有服务性能指标均需通过地面监测设备进行全天候、全区域监测，并结合卫星运行和控制信息，计算得出质量评估结果。未来随着北斗系统的升级换代和应用领域的拓展，需要建立自动化、智能化的性能评估体系，实现各项业务指标的预测预警。同时，还需要进一步完善监测手段，丰富监测数据类型，全面评估北斗导航服务质量及其演变规律，才能持续为用户提供高可靠、高精度的卫星导航服务。服务性能特性主要包括服务精度和服务可用性：服务精度包括定位精度、测速精度、授时精度，其中定位精度最为重要；服务可用性是指可用服务时间与预期服务时间之比，包括 PDOP 可用性和位置服务可用性，可用服务时间是指在给定区域内，服务精度达到规定性能标准所需的时间。

PDOP 可用性和定位服务可用性，以规定条件和规定服务区域内，PDOP 和定位精度满足技术要求的时间占规定时间的百分比来衡量。通常选取较为直观的 PDOP 和定位精度指标进行监测评估。

精度衰减因子（DOP）表征用户可见的卫星空间几何质量。它没有单位，但可以在一定程度上反映卫星星座的状况和定位服务的质量。其中，星座 DOP 值包括位置精度衰减因子、水平精度衰减因子（HDOP）、仰角精度衰减因子（VDOP）、时间精度衰减因子（TDOP）和几何精度衰减因子（GDOP）^[5]。

这些指标通常利用数据的协方差来计算，根据卫星导航伪距测距原理，往往需要利用 4 颗或更多可见卫星才能得到有效的用户位置计算结果。鉴于低仰角导航卫星信号的大气延迟改正误差和多路径误差较大，会对计算结果造成较大的误差影响，仰角低于限值的卫星将被剔除，不用于定位计算。当 PDOP > 3 时，判断当前可见，卫星几何分布理想，定位误差较小。

此外，根据北斗卫星导航系统开放服务性能规范的定义，服务精度包括定位精度、测速精度、授时精度。其中，定位精度是指在规定的用户条件下，北斗系统向用户提供的位置与用户真实位置之差的统计值，包括水平定位精度和垂直定位精度。定位精度描述了真实定位结果的误差，为用户使用卫星导航定位服务提供参考。

3.1 各种类型的卫星故障

姿态控制故障：卫星在太空中维持预定方向或姿态的能力出现问题。

电力系统故障：卫星发电、存储或分配出现问题。

通讯故障：卫星收发信号出现问题。**热控故障：**卫星温度调节出现问题。

轨道机动失败：卫星调整轨道的能力出现问题。

软件故障：由编码错误或运行软件所用的内存或处理系统的问题引起。

3.2 训练方法

根据 LSTM 的时间序列预测原理，提出一种基于 LSTM 的 GNSS 服务性能预测分析方法，其流程如下：第一步，采集卫星历史观测数据和检测分析数据，并进行预处理，清理噪声数据；第二步，将数据按一定比例划分为训练集和测试集，然后对数据进行归一化；第三步，不断优化模型直至模型收敛。对于多路径误差的处理，可以并联多个 LSTM 来减轻误差的影响，或者采集模拟的多路径误差数据来提高 LSTM 网络的泛化能力。

4 结论

本文介绍了一种基于深度学习的检测性能分析方法。然而，深度学习方法存在一定的泛化问题。本文提出利用长短期记忆（LSTM）神经网络进行卫星导航服务性能预测。LSTM 能够有效地对时间序列数据中的长期依赖关系进行建模。该方法包括：收集历史 GNSS 数据，例如信号指标和定位误差。预测过程以清理和格式化数据。将数据分成训练集和测试集。规范化特征以实现有效学习。训练 LSTM 模型以预测性能指标。优化超参数直到模型收敛。使用并行 LSTM 分支或模拟训练数据解决多路径误差。如何提高模型在卫星导航系统检测和分析中的泛化性能将是一个有趣的研究方向。

参考文献

- [1] Karolina Krzykowska and Michal Krzykowski. “Forecasting parameters of satellite navigation signal through artificial neural networks for the purpose of civil aviation”. International Journal of Aerospace Engineering, 2019.
- [2] Shizhuang Wang, et al. “Enhancing navigation integrity for Urban Air Mobility with redundant inertial sensors”.

- Aerospace Science and Technology, 126 (2022), p. 107631.
- [3] Yann LeCun, Yoshua Bengio, and Geoffrey Hinton. "Deep learning". Nature, 521.7553 (2015), pp. 436-444.
- [4] Sepp Hochreiter and Jürgen Schmidhuber. "Long short-term memory". Neural computation, 9.8 (1997), pp. 1735-1780.
- [5] Li, B., Zhao, K., & Shen, X. Dilution of precision in positioning systems using both angle of arrival and time of arrival measurements. IEEE Access, 8, 2020, 192506-192517.
- [6] B.Pattanayak and L. Moharana. Analyzing the Effect of Dilution of Precision on the Performance of GPS System. Retrieved from:
<https://ieeexplore.ieee.org/abstract/document/9428982>,
2021.
- [7] Zhong Zheng, Xiaoting Wang, Shan Luan, Hanyu Zheng, Minglong Pu, and Wei Zhang. "Error analysis of received signal strength-based visible-light positioning using dilution of precision." Optical Engineering, 60(10), 106102 (5 October 2021).
<https://doi.org/10.1117/1.OE.60.10.106102>.

版权声明：©2025 作者与开放获取期刊研究中心(OAJRC)所有。本文章按照知识共享署名许可条款发表。

<https://creativecommons.org/licenses/by/4.0/>



OPEN ACCESS