

基于SegRNN的运营环境下大跨拱桥结构响应预测研究

王鹏军, 樊宇, 杨阳

(清华大学, 北京市 100084)

摘要: 针对桥梁结构响应的预测问题, 基于分段递归神经网络(segment recurrent neural network, SegRNN)提出了一种响应预测方法, 可以对未来24、48 h内的响应进行预测。SegRNN将输入数据分段, 减小了递归神经网络(recurrent neural network, RNN)的迭代次数, 在解码阶段, 使用并行多步预测的方法, 代替了RNN的迭代循环多步预测的方法, 提高了预测精度。将过去的桥梁响应数据和温度、交通荷载数据作为输入, 使用SegRNN预测未来响应。对一座大跨度钢管混凝土拱桥为期1年的应变、梁端位移和GPS数据进行了分析。选择了10条典型测点位置的监测数据作为数据集, 测试了提出方法的有效性。结果表明, SegRNN在所有测试中的平均绝对误差和平均均方误差指标的平均值分别为0.254和0.387, 分别取得了12个和11个最佳结果, 相比LSTM(long short-term memory)、Transformer网络具有显著的优势。提出的方法可以应用于实际桥梁监测中, 为桥梁的风险预测提供支持。

关键词: 结构健康监测; 大跨度拱桥; SegRNN; 响应预测

中图分类号: U446; TU997

文献标志码: A

文章编号: 1009-7716(2026)02-0035-07

Analysis on Structural Response Prediction of Long-span Arch Bridges in Operation Environment Based on SegRNN

WANG Pengjun, FAN Yu, YANG Yang

(Tsinghua University, Beijing 100084, China)

Abstract: Aiming at the prediction problem of bridge structural response, and based on the segment recurrent neural network (segment recurrent neural network, SegRNN), a response prediction method is proposed able to predict the response within the next 24h and 48h. The data segment will be input into SegRNN to reduce the number of iterations of the recurrent neural network (recurrent neural network, RNN). In the decoding phase, a parallel multi-step prediction method is used to replace the iterative loop multi-step prediction method of RNN, which enhances the prediction accuracy. Taking the past bridge response data and temperature and traffic load data as input, SegRNN is used to predict the future responses. The strain, end-beam displacement and GPS data of a long-span concrete-filled steel tube arch bridge over a one-year period are analyzed. The monitoring data from 10 typical measuring point locations are selected as the dataset to test the effectiveness of the proposed method. The results show that the average values of the average absolute error and average mean square error indicators of SegRNN in all tests are 0.254 and 0.387 respectively, achieving 12 and 11 best results respectively, which has the significant advantage compared with LSTM (long short-term memory) and Transformer networks. The proposed method can be applied to actual bridge monitoring and provide the support for the risk prediction of bridges.

Keywords: structural health monitoring; long-span arch bridge; SegRNN; response prediction

0 引言

近年来,随着结构健康监测技术快速发展,许多大跨度桥梁上都安装了桥梁健康监测系统^[1-2]。交

通运输部《关于进一步提升公路桥梁安全耐久水平的意见》指出,要全面建立跨江跨海跨峡谷等特殊桥梁结构健康监测系统,提升公路桥梁的运营安全水平。大跨度桥梁结构复杂,在温度、交通荷载作用下,结构性能会随着时间的推移而逐渐退化^[3]。对这类桥梁进行全面监测评估,是保障桥梁安全运营的重要举措^[4]。面对海量监测数据,使用大数据、人工智能等

收稿日期: 2025-10-29

基金项目: 国家重点研发计划(2024YFB3214500)

作者简介: 王鹏军(1982—),男,博士,副研究员,从事智能传感器研发工作。

技术对桥梁响应进行准确的预测已成为可能^[5-8]。但目前,大部分研究只讨论了结构响应的一步预测^[9-10],基于桥梁监测数据预测结果对桥梁状态进行评估,而对更为长期的预测方法研究有限。Lin等人^[11]提出了一种分段循环神经网络(segment recurrent neural network, SegRNN)网络结构,可预测长期时间序列。本文基于SegRNN模型提出了大跨度拱桥响应预测方法,预测未来24、48 h内的响应。提出的方法将结构响应、温度和交通荷载作为模型输入,对未来响应预测。对一座大跨度钢管混凝土拱桥的应变、梁端位移和GPS数据进行了分析,讨论了桥梁响应与温度之间的相关性。选取了典型位置测点作为数据集测试了提出方法,并与近年来提出的其他先进模型进行了对比。

1 基于SegRNN的结构响应预测方法

1.1 SegRNN

SegRNN主要分为编码层和解码层两部分^[11]。总体来说,编码层通过将序列分段进行循环迭代计算,相比于原始数据点直接迭代降低了迭代次数,在解码层,使用了并行多步预测策略,代替了普通RNN的迭代多步预测方式。通过减少循环迭代次数和并行多步预测的策略,显著提高了预测精度。SegRNN的网络结构如图1所示。




图1 SegRNN结构

输入数据为单通道或者多通道的时间序列数据,假设长度为 l 。首先,SegRNN将序列分割为 n 段,每个分段的数据长度为 l/n ,分段数量可以根据数据的周期特征进行选择。然后每个分段序列通过线性层和激活函数提取特征后,输入至RNN单元中。常用的RNN单元包括三种典型的单元:经典RNN,GRU和LSTM。GRU单元的参数相比于LSTM较少,但是却能得到和LSTM相接近的性能,因此本文选择了GRU单元,与文献^[11]一致。编码器对数据进行分段后,对每个分段进行循环迭代,如此仅需要迭代计算 n 次,而传统的RNN方法对原始数据进行迭代,需

要计算 l 次。通过减少迭代次数,有利于减小循环迭代时的梯度消失问题。

解码层使用并行多步预测,即解码器的最后一步输出 h_n 对未来的多步预测结果同时进行预测,这与传统RNN的递归输出方式不同。此外,解码层还引入了位置编码和通道编码,以弥补并行预测造成的顺序丢失问题。最后,将GRU的输出经过线性层变换后,得到未来的多步预测结果。

1.2 结构响应预测方法

本文提出的结构响应预测方法如图2所示。由于运营环境下,结构响应受到温度^[12]、交通荷载^[13]的影响,因此将温度和交通荷载也作为网络输入,通过捕捉环境作用与结构响应的关系辅助响应预测。需要注意的时,对于温度和交通荷载,同样仅输入过去的的数据,避免未来信息的泄露。网络的输出为预测的未来结构响应,预测长度与输入长度可以不同,根据具体任务需求定义。本文选择的输入时间长度为过去96 h的监测数据,由于大部分监测数据都存在日周期特征,将数据按照24 h的长度进行分割。预测长度设置为24、48 h。




图2 网络的输入和输出

网络的训练使用均方根误差(mean square error, MSE)作为损失函数。优化器使用Adam优化算法。此外,实际监测数据中经常存在数据缺失的问题,针对该问题,本文使用均值对缺失数据进行填充。并且生成缺失位置掩码,在计算损失函数时,不考虑数据缺失位置的损失,即数据缺失位置的误差不会反向传播至网络参数,从而避免数据缺失对训练的影响。

2 数据来源与数据集生成

2.1 某大跨拱桥监测系统

本研究使用的数据来自一座中承式钢管混凝土拱桥,如图3(a)所示。该桥长530 m,主跨500 m,矢

跨比为 1/4.5,桥面宽度 28 m,双向 4 车道布置。两肋间桥面以上的拱圈上弦设置“K”形钢管横撑,桥面以下的拱脚短设置径向钢管混凝土横撑。全桥共设置 64 根吊杆。主梁采用钢-混凝土加劲梁,主次纵横梁均采用“工”字形截面。拱座设计为分离式钢筋混凝土拱座。桥梁照片如图 3(a)所示。桥梁安装了健康监测系统(见图 3(b)),对大桥运营环境及关键部位结构响应进行监测。自动、实时获得桥址环境、外部荷载、结构响应等数据和信息,实时监测掌握桥梁的结构状态,交通状态,保障桥梁的安全运营。结构响应监测项目包括:位移、应变、加速度、倾角、索力等,环境监测包括温湿度、交通荷载。




图3 桥梁照片和GPS测点布置

本文主要对桥梁的应变、GPS、梁端位移数据进行分析。应变测点布置在主梁和拱肋的四分点、跨中截面位置,共计 82 个测点,采样频率为 20Hz 对主梁顶板、底板等关键位置进行监测。GPS 测点布置在主梁跨中和拱肋跨中、四分点,共计 9 个测点,采样频率为 20 Hz。梁端位移测点布置在梁、拱结合处和主梁两端,采样频率为 20 Hz。图 4 所示为 2024 年 1 年部分梁端位移、GPS 和应变监测数据的小时平均值,其中梁端位移测点#4 为主梁梁端位移,GPS 测点#3 分别为拱肋跨中竖向位移,应变测点#82 分别为拱肋截面的应变。从图中可以看出,GPS 和梁端位移数据受温度影响存在显著的季节趋势,夏季和冬季的差异很大,而应变收到交通荷载的影响更显著,波动更剧烈。

图 5 所示为温度和交通荷载监测数据。同样统计了温度每小时的平均值,温度波动特征除了季节




图4 结构响应监测数据

上的不同外,还存在显著的日周期特征,白天温度高而夜间温度低。该桥梁还安装了动态称重系统,根据系统记录的车辆信息,统计了每小时经过桥梁的车辆数量,可以发现,车辆数量同样存在明显的日周期特征,白天车辆数量多,每小时通过桥梁的车辆数量最大可达到仅 10 000 辆。

从上述图 4 和图 5 对比中可以发现,结构位移、应变与温度具有一定相关性,因此进一步讨论了结构响应与温度的相关关系,绘制了响应与温度的散点图,如图 6 所示。梁端位移与温度具有很强的线性关系,这表明温度是影响梁端位移的主要因素而 GPS 监测的竖向位移与温度尽管具有一定相关性,但是表现出了不同的特征,主要原因是计算得到的竖向位移小时平均值数据中,日周期变化并不显著,而年周期随温度变化的更加显著。应变的相关性分




图5 温度和交通荷载监测数据

析表明,不同测点位置的应变与温度呈现出不同的 相关特征。




图6 梁端位移与温度相关性

2.2 数据集

本研究选取了一些典型位置的结构监测数据作为数据集以验证提出方法的有效性。数据集说明如表1所示。对于应变,选择了主梁四分点和跨中的顶、底板位置的应变测点,此外还选择了拱肋在四分点和跨中位置截面的应变测点。对于位移数据,选择了主梁两侧的两个梁端位移测点以及主梁和拱肋跨中位移的竖向GPS测点。数据集选择了2024年的监测数据,通过预处理,计算了小时平均值,共计8 784 h。将数据集按照7:2:1的比例划分为训练集、测试集和验证集。

3 结果与讨论

使用第3.2节生成的数据集,对网络进行训练,

表1 数据集说明

测点编号	类型	位置	时长/h
STR#23	应变	主梁四分点截面顶板位置	8 784
STR#27	应变	主梁四分点截面底板位置	8 784
STR#32	应变	主梁跨中截面顶板位置	8 784
STR#36	应变	主梁跨中截面底板位置	8 784
STR#72	应变	拱肋四分点截面位置	8 784
STR#82	应变	拱肋跨中截面位置	8 784
DIS#1	梁端位移	主梁西侧梁端	8 784
DIS#3	梁端位移	主梁东侧梁端	8 784
GPS#1	竖向位移	主梁跨中竖向位移	8 784

设置学习率为0.000 1,训练批次大小为32,设置早停机制,当验证集的损失连续三轮不降低时,停止训练,选择验证集损失最小的网络参数,训练轮数最大为50轮。分别对预测长度为24 h和48 h的情况进

行了训练。

图7所示为预测步长为24 h的部分测试集结果,显示了各个数据集在第7 147 h的预测结果。结果表明,大部分测点的预测结果与真实值十分接近,并且预测值能够反映实际的变化趋势,准确捕捉了日周期的特征。而梁端位移测点DIS#1的预测效果较

差,而DIS#3的预测效果则比较准确,原因时DIS#1出现了更为严重的数据缺失问题,这导致训练集的样本十分有限。图8所示为预测步长为48 h的预测结果,同样的,大部分测点都取得了良好的预测结果,并且准确反映了监测数据的日周期特征,预测的趋势与实测结果相符合。




图7 预测步长为24 h的结果(第7 147 h)

进一步分析了预测结果的平均绝对误差(mean absolute error, MAE)和MSE指标,并且与LSTM^[14], Transformer^[15], Autoformer^[16], iTransformer^[17], 和TimeXer^[18]网络进行了对比,结果如表2所示。SegRNN在所有10条数据共20个测试中,MAE指标取得了12个最优结果,MSE取得了10个最优结果,表明了该模型在结构响应预测上的巨大优势。

图9为各个模型的预测结果对比。可以看到,原始Transformer的预测效果较差,难以准确捕捉响应的周期性变化。而一些基于Transformer的改进方法,例如Autoformer, iTransformer则显著改善了Transformer的识别结果。iTransformer, TimeXer以及SegRNN的结果比较接近,都能准确捕捉结构响应的日周期性特征。

5 结 论

本文提出了一种基于SegRNN的结构响应预测

方法,可以对未来24、48 h的响应进行预测。对一座大跨径拱桥为期一年的监测数据进行了分析,讨论了温度与应变、位移的相关性。基于桥梁应变、梁端位移和GPS监测数据生成了10条典型测点数据作为数据集测试了提出方法的有效性。结果表明,SegRNN能够准确捕捉结构响应的周期特征,准确预测未来一段时间内的响应数据。在所有测试中,SegRNN预测结果的MAE和MSE指标平均值分别为0.254和0.387,分别取得了12个和11个最佳结果。相比于LSTM, Transform, Autoformer, iTransformer 和TimeXer网络,SegRNN在数据集中表现出了最好的预测效果。

本文采用了仅数据驱动的方法预测桥梁响应,结果在一定程度上缺乏直观的解释,在未来的研究中,可以采用更为先进的时间序列预测方法,并且将桥梁的物理信息嵌入神经网络中,以提供更为可靠的预测结果。




图8 预测步长为48 h的结果(第7 147 h)

表2 各模型在测试集上的预测效果对比

数据集	预测步长	SegRNN		TimeXer		iTransformer		Autoformer		Transformer		LSTM	
		MAE	MSE	MAE	MSE	MAE	MSE	MAE	MSE	MAE	MSE	MAE	MSE
STR#23	24	0.115	0.046	0.122	0.048	<u>0.120</u>	<u>0.046</u>	0.220	0.146	0.409	0.366	0.176	0.086
	48	0.139	0.062	0.156	0.075	<u>0.141</u>	<u>0.063</u>	0.299	0.253	0.400	0.361	0.243	0.163
STR#27	24	0.158	0.092	0.149	0.088	<u>0.152</u>	<u>0.089</u>	0.219	0.167	0.368	0.346	0.188	0.114
	48	0.179	<u>0.106</u>	0.161	0.095	<u>0.165</u>	0.108	0.316	0.333	0.250	0.177	0.221	0.159
STR#33	24	0.115	0.064	0.134	0.075	<u>0.126</u>	<u>0.068</u>	0.226	0.174	0.269	0.221	0.126	0.078
	48	0.140	<u>0.086</u>	<u>0.145</u>	0.084	0.162	0.112	0.281	0.238	0.317	0.276	0.251	0.163
STR#36	24	<u>0.247</u>	0.228	0.230	0.189	0.253	<u>0.223</u>	0.282	0.245	0.354	0.355	0.344	0.334
	48	0.278	0.261	0.247	0.204	<u>0.260</u>	<u>0.226</u>	0.409	0.496	0.477	0.530	0.541	0.698
STR#72	24	0.134	0.165	<u>0.165</u>	<u>0.204</u>	0.179	0.258	0.231	0.256	0.315	0.306	0.354	0.397
	48	0.170	0.216	<u>0.189</u>	<u>0.226</u>	0.201	0.287	0.259	0.267	1.297	3.379	0.456	0.531
STR#82	24	0.249	0.196	0.163	0.104	<u>0.168</u>	<u>0.107</u>	0.284	0.266	0.339	0.301	0.190	0.129
	48	0.279	0.238	0.169	0.112	<u>0.173</u>	<u>0.118</u>	0.295	0.275	0.210	0.151	0.225	0.157
DIS#1	24	0.072	0.014	0.100	0.026	<u>0.091</u>	<u>0.021</u>	0.340	0.192	1.448	2.467	1.246	1.938
	48	0.113	0.028	0.132	0.044	<u>0.116</u>	<u>0.031</u>	0.392	0.262	1.685	3.305	0.843	0.994
DIS#3	24	0.336	0.209	0.331	0.200	0.284	0.152	0.421	0.326	1.381	2.458	1.175	1.835
	48	0.399	0.289	0.416	0.308	0.331	0.195	0.508	0.505	1.715	3.643	0.735	0.891
GPS#1	24	0.473	1.368	0.518	1.038	0.732	1.698	0.889	2.315	2.580	8.910	3.495	15.946
	48	0.644	2.176	0.879	2.455	0.986	3.238	1.023	2.997	2.221	6.514	4.545	26.106
GPS#3	24	0.359	0.746	0.478	0.801	0.568	1.023	0.643	1.277	1.796	4.212	2.620	8.973
	48	0.485	1.159	0.596	1.254	0.684	1.441	0.808	1.851	2.004	5.061	3.053	11.714
均值		0.254	0.387	0.274	0.382	0.295	0.475	0.417	0.642	0.992	2.167	1.051	3.570
计数		12	11	6	8	2	2	0	0	0	0	0	0




图 9 识别结果对比

参考文献:

[1] 孙利民,尚志强,夏烨.大数据背景下的桥梁结构健康监测研究现状与展望[J].中国公路学报,2019,32(11):1-20.

[2] 宗跃然,左永辉,程勋煜.长大桥群结构健康监测系统研究及开发[J].城市道桥与防洪,2024(5):15-17.

[3] 陈华鹏,刘维刚,江钰,等.混凝土桥梁服役性能退化及预防性维护综述[J].华东交通大学学报,2024,41(2):1-24.

[4] 叶慰.健康监测在长大桥梁养护中的应用[J].科技风,2011(24):99-100.

[5] 唐良,边祖光,赵银飞,等.基于深度学习和监测数据的桥梁损伤识别方法研究[J].城市道桥与防洪,2022(1):174-180.

[6] 夏烨,潘诚,龚丰宗,等.基于监测数据的装配式梁桥横向连接性能评估[J].中国公路学报,2025,38(3):317-330.

[7] GONG F, PAN C, XIA Y. Experimental Study on the Damping Ratio Evaluation of a Cable-Stayed Bridge Based on Damping Dissipation Function[J]. Structural Control and Health Monitoring, 2025(1).

[8] 夏烨,龚丰宗,尚志强,等.基于监测数据衰减响应模式提取的斜拉桥阻尼比特性分析[J].中国公路学报,2023,36(7):90-101.

[9] WANG W, REN P, LIU Y, et al. FT-SMNet: Fourier transform sparse matrix network for structural health monitoring time series data forecasting [J]. Mech Syst Signal Proc, 2025, 224: 112196.

[10] 樊学平,周衡,刘月飞.桥梁时变可靠性的多过程贝叶斯动态混合预测[J].吉林大学学报(工学版),2023,53(8):2332-2338.

[11] LIN S, LIN W, WU W, et al. Segrnn: Segment recurrent neural network for long-term time series forecasting[J]. arXiv preprint arXiv: 230811200, 2023.

[12] 杨欣,张举兵,李小龙,等.基于监测数据的钢桁梁桥温度变形研究[J].工程力学,2024,41(增刊1):310-316.

[13] 郭晓光,徐凯澳,黄骞.基于深度学习的重载车辆作用下桥梁动力响应预测方法研究[J].重庆交通大学学报(自然科学版),2025,44(5):19-26.

[14] 赵启凡,刘月飞,樊学平.BO-LSTM和Copula理论相融合的桥梁构件时变可靠性预测[J].振动工程学报,2025,38(9):2182-2191.

[15] 袁汉超.基于振动监测数据和机器学习的桥梁损伤识别方法分析[J].集成电路应用,2025,42(5):373-375.

[16] WU H, XU J, WANG J, et al. Autoformer: Decomposition transformers with auto-correlation for long-term series forecasting [J]. Advances in neural information processing systems, 2021(34): 22419-22430.

[17] LIU Y, HU T, ZHANG H, et al. itransformer: Inverted transformers are effective for time series forecasting[J]. arXiv preprint arXiv:231006625, 2023.

[18] WANG Y, WU H, DONG J, et al. Timexer: Empowering transformers for time series forecasting with exogenous variables[J]. Advances in Neural Information Processing Systems, 2024(37): 469-498.