

基于 ARIMA-BP 神经网络模型的桥梁 SHM 应变预测分析

邱 卓¹, 胡琼清¹, 伍伟斌¹, 钟菊芳², 万 灵^{1,3}

(1. 江西省交通科学研究院有限公司, 南昌 330200; 2. 南昌航空大学 土木建筑学院, 南昌 330063;
3. 浙江大学 建筑工程学院, 杭州 310058)

摘要:桥梁结构健康监测的应变监测数据具有较强的趋势性与随机性,为提升数据的预测精度,提出将传统单一的自回归积分滑动平均模型(ARIMA)和 BP 神经网络预测模型进行加权与组合,并将这两种方法分别运用于江西省某跨江大桥桥梁结构健康监测记录系统记录的应变监测数据的预测进行验证。结果表明:仅运用单一模型预测时,BP 神经网络的预测效果要优于 ARIMA 模型;加权与组合模型的预测精度均优于单一模型,其中加权模型及组合模型的残差平方和(SSE)与 BP 神经网络模型相差最大,分别高达 50.23%与 49.87%;对比加权模型与组合模型的各项误差指标,发现二者预测模型的预测精度极为接近;单一预测模型的误差包络范围大于其他两类模型,其中 ARIMA 模型的误差总和约为 50 $\mu\epsilon$,BP 神经网络模型的误差总和约为 30 $\mu\epsilon$,加权模型的误差总和约为 21.09 $\mu\epsilon$,组合模型的误差总和约为 20.97 $\mu\epsilon$ 。经分析,加权预测模型与组合预测模型均能实现对桥梁 SHM 应变预测。

关键词:结构健康监测(SHM);自回归积分滑动平均模型(ARIMA);BP 神经网络;加权预测;组合预测

中图分类号:U446 **文献标志码:**A **文章编号:**1671-1807(2022)08-0392-06

“十四五”以来,中国为实现交通强国,提升公路桥梁安全耐久水平,多次强调公路桥梁建设健康监测系统的必要性^[1]。早在 20 世纪 90 年代初期,国家就已经开始注意到结构健康监测系统在桥梁建设、运维、养护中所起的重要作用;时至今日,桥梁健康监测系统已在国内 300 余座桥梁中得到广泛运用^[1]。监测系统实时采集得到的监测数据,是体现桥梁结构特性的重要指标,因此对监测数据的分析及预测是评估桥梁结构状态发展趋势的重要基础^[2]。

从国内外学者对桥梁监测数据预测方法研究^[3-9]了解到,目前桥梁监测数据预测分析大多采用单一预测模型。如 Datteo 等^[3]利用确定 AR 模型模拟了桥梁系统的结构响应特征;Oliveira 等^[4]基于 ARIMA 算法进行了桥梁结构有效损伤识别;刘启斌等^[5]建立了监测数据的长短时记忆网络,实现了谐波监测数据的预测;陈兵^[6]基于灰色系统理论,利用最小二乘法构建了 GM(1,1)时间响应函数,并结合实际工程数据,得到了良好的预测结果;陆萍

等^[7]以江津长江大桥健康监测数据为例,建立了 ARIMA 预测模型,并针对桥梁监测系统的挠度数据进行了预测分析;沈健^[8]就天津海河大桥健康监测系统,利用了 BP 神经网络模型在数据识别中的优势,进行多传感器与单传感器数据的对比融合分析;张鹏^[9]利用基于 BP 神经网络模型的数据挖掘技术对桥梁监测数据进行分析,建立了监测数据的预测模型。

然而,传感设备在服役期所采集的数据往往具有波动性与随机性,采用单一的预测模型可能会存在些许误差^[10]。为探究单一预测模型的误差范围,比较不同预测模型的预测效果,本文以江西省某跨江大桥 SHM(structural health monitoring,结构健康监测)的实测应变数据为例,选用线性研究理论和复杂性研究理论的经典模型——ARIMA 模型和 BP 神经网络预测模型^[10],针对上述问题进行研究与对比,同时提出基于两种基础理论模型的加权预测模型与组合预测模型,并将其预测结果分别与两种基础预测理论模型进行对比,验证两类新模型的

收稿日期:2022-04-06

基金项目:江西省交通运输厅科技项目(2020Z0003);江西省交通运输厅重点科技项目(2021C0008)。

作者简介:邱卓(1994—),男,江西抚州人,江西省交通科学研究院有限公司,助理工程师,硕士,研究方向为结构健康监测。

合理性与准确性。

合理地构建桥梁监测数据预测模型,能有效地对监测数据进行预警,为桥梁的维护决策提供依据的同时,还能有效地控制结构安全事故的发生,具有重大的工程意义。

1 预测理论模型

1.1 ARIMA 模型

自回归积分滑动平均模型 ARIMA(p, d, q)是目前应用较为广泛的时间序列模型,其实质是在自回归移动平均模型的基础上针对不平稳信号进行差分处理。ARIMA 模型的主要思路为:①利用 ADF 单位根测试检验信号是否为平稳信号;②若信号为非平稳信号,则对其进行 d 阶差分以得到平稳信号;③将平稳信号通过使用自相关函数(ACF)和偏相关函数(PACF)来通过截尾性或拖尾性来判定自回归(AR)模型的阶数 p 和移动平均(MA)模型的阶数 q ,判定方法参照表 1;④通过确定 ARIMA 模型的参数(p, d, q),就可利用预测函数对测试数据集的值进行预测。

ARIMA(p, d, q)模型的表达式为

$$\begin{cases} \varphi(K) \nabla^d X_t = \theta(K) \varepsilon_t \\ \varphi(K) = 1 - \varphi_1 K - \varphi_2 K^2 - \cdots - \varphi_p K^p \\ \theta(K) = 1 + \theta_1 K + \theta_2 K^2 + \cdots + \theta_q K^q \end{cases} \quad (1)$$

式中: $\varphi_i(i = 1, 2, \cdots, p)$ 及 $\theta_i(i = 1, 2, \cdots, q)$ 分别为自相关系数和移动平均系数; $\varphi(K)$ 为自相关系数多项式; $\theta(K)$ 为移动平均系数多项式; K 为滞后算子; ∇^d 指 d 阶后向差分; t 为期数; X_t 为时间序列; ε_t 为第 t 期的残差项。

表 1 阶数判定方法

模型	自相关函数	偏相关函数
AR(p)	拖尾性	截尾性
MA(q)	截尾性	拖尾性
ARMA(p, q)	拖尾性	拖尾性

1.2 BP 神经网络模型

BP 神经网络(back-propagation network)是一种具有误差后向传播并重训练的多层前向网络,其通常结构为输入层、隐含层及输出层。该类方法的主要思路为:将输入数据通过权重矩阵映射到隐含层,再通过权重矩阵映射到输出层,然后与期望输出相比较,若是不符合则将误差反向传播,误差以某种形式通过隐含层像输入层逐层反向传递,反反复复,直至输出满足期望输出或者达到学习次数停止,由此得到预测模型。BP 神经网络算法的计算公

式为

$$y_k = f_2 \left[\sum_{j=1}^M \omega_{jk} f_1 \left(\sum_{i=1}^N \omega_{ij} x_i \right) \right] \quad (2)$$

式中: x_i 为输入层的输入值; y_k 为输出层的输出值; f_1 及 ω_{ij} 分别为输入层与隐含层之间的激活函数及权值; f_2 及 ω_{jk} 分别为隐含层与输出层之间的激活函数及权值。

2 加权预测模型

桥梁 SHM 应变数据通常与结构温度具有较强的相关性,而温度的变化往往具有趋势性,但应变数据却不完全受温度的影响,无论是适用于线性序列预测的 ARIMA 模型^[12],还是适用于非线性序列预测的 BP 神经网络模型^[13],皆无法对桥梁 SHM 应变数据进行精确地预测。因此,应当结合二者模型的优点,构建更为精准的预测模型。

加权预测模型是指利用 ARIMA 预测模型与 BP 神经网络模型分别对桥梁 SHM 实测应变序列进行拟合分析,将二者得到的预测序列进行权重分配再求和,以得到与实测应变序列误差最小的预测序列。该方法的表达式为

$$J_t = k_1 X_{1t} + k_2 X_{2t} \quad (3)$$

式中: J_t 为加权模型预测序列; X_{1t} 为 ARIMA 模型预测序列, k_1 为其权值; X_{2t} 为 BP 神经网络预测序列, k_2 为其权值; $k_1 + k_2 = 1$ 。

实现加权预测模型分为以下 5 个步骤:

第 1 步,确定差分阶数 d 。将 SHM 应变序列同时通过 ADF 和 KPSS 检验以判断原序列是否平稳,若序列未能通过平稳性检验,即采取差分运算直至该序列达到平稳。

第 2 步,将平稳信号通过使用自相关函数(ACF)和偏相关函数(PACF)识别其截尾或拖尾得到 p 和 q (识别判定方法见表 1),构造 ARIMA(p, d, q)模型并得到 ARIMA 模型预测序列。

第 3 步,构建 BP 神经网络的结构,配置隐含层层数、最小学习率及最大训练误差。

第 4 步,以前 10 个应变数据作为输入值,将第 11 个数值作为输出,进行滚动训练,依据上一步所配置的各项参数不断对预测参数进行调整,直至满足误差要求或超过最大训练次数,得到 BP 神经网络预测模型,并利用该模型得到 BP 神经网络预测序列。

第 5 步,参照式(3)的运算规则,利用 MATLAB 建立一个关于 $k_1 = 0.1, 0.2, \cdots, 0.9$ 的循环,求得各 k_1 对应的加权模型预测序列,令原始序列分

别减去这些加权模型预测序列,得到各 k_1 对应误差序列,对误差序列的绝对值进行求和得到各序列的误差总和,选择较小两个误差总和对应的 k_1 值,即判定在此区间内可以找到最小误差的权值,反复运用上述这一夹逼方法,求得权值 k_1 与 k_2 。

3 组合预测模型

结合实际工程经验,桥梁 SHM 应变数据的变化往往与其结构温度变化具有一定的相关性,而结构温度受大气温度昼夜、季节更替的影响会出现趋势性,因此导致桥梁 SHM 应变数据也存在变化趋势。

组合模型针对 SHM 应变序列具有趋势变化的特点,采用适合于线性研究理论模型的 ARIMA 对桥梁 SHM 应变序列的趋势项部分进行预测,再选用 BP 神经网络模型对应变序列除趋势项以外的细节项部分进行预测,最后将二者模型的预测序列进行叠加,形成组合预测序列。组合预测模型流程如图 1 所示。




图 1 组合预测模型流程

4 桥梁 SHM 应变数据预测

4.1 数据选取及处理

选用江西省某跨江大桥桥梁结构健康监测系统 2021 年 4 月的某一应变传感设备记录的应变监测数据作为分析案例。由于应变传感设备的采

集频率较高,数据量过大,不利于分析效率,因此对所采集到的数据进行抽样提取,同时再利用 3 倍标准差原则对记录数据进行剔除异常值处理,最终共获取 600 个应变数值,用以后续的分析。

4.2 应变数据预测

4.2.1 单一模型预测分析及对比

利用 1.1 节 ARIMA 模型理论,对所选取的应变序列进行预测分析。经验算,ARIMA(4,1,5)的模型参数最为适用此次应变数据的预测。该模型的预测效果如图 2 所示。经整体观察,ARIMA 预测序列基本与原应变序列贴合。为更加清晰地分辨其预测效果,特将 420~540 期处数据情况进行局部放大,可见 ARIMA 预测序列确与原序列存在细微的偏差。通过计算其误差评价得到该模型的残差平方和 SSE(sum of squared error)、均方误差 MSE(mean squared error)、平均绝对误差 MAE(mean absolute error)、平均绝对百分比误差 MAPE(mean absolute percentage error)、均方根误差 RMSE(root mean square error)及决定系数 R^2 (coefficient of determination) 分别为 7.332 8、1.354、0.083 4、39.28%、0.110 6、0.998 7。




图 2 ARIMA 模型预测结果

运用 1.2 节 BP 神经网络模型理论,对所选取的应变序列进行预测分析。神经网络模型采用 3 层网络结构,10 个输入节点,10 个中间节点和 1 个输出节点。设定学习率为 0.1,最大训练次数为 50 000,最大训练误差为 0.01,建立 BP 神经网络预测模型,并利用该模型得到 BP 神经网络预测序列。该模型的预测效果如图 3 所示。经整体观察,BP 神经网络预测模型较好地贴合了原应变序列的数据变化,经局部放大处理,可以直观地看出其预测效果与真实数据变化趋势完全一致,但依然存有部分误差。

结合图 2 与图 3 进行分析,可明显看出 BP 神




图 3 BP 神经网络模型预测结果

神经网络预测序列与原数据的贴合度优于 ARIMA 预测序列,两类模型的误差评价见表 2。由表 2 可知,BP 神经网络误差评价指标 SSE、MES、MAE、MAPE、RMSE 及 R^2 分别为 2.594 8、0.805、0.050、23.68%、0.065 8 及 0.999 5。其中,决定系数越高说明预测误差越小,其余评价指标越高预测误差越大。经分析,在此案例中,BP 神经网络模型各误差评价指标均要优于 ARIMA 模型,因此认为,BP 神经网络模型相比 ARIMA 模型更适用于本案例的预测分析。两类模型的误差对比如图 4 所示,其中 ARIMA 模型的误差包络范围明显大于 BP 神经网络模型,前者误差总和约为 $50\text{ }\mu\epsilon$,后者误差总和约为 $30\text{ }\mu\epsilon$ 。

表 2 ARIMA、BP 神经网络模型误差评价

模型	SSE	MES	MAE	MAPE/%	RMSE	R^2
ARIMA	7.332 8	1.354	0.083 4	39.28	0.110 6	0.098 7
BP	2.594 8	0.805	0.050	23.68	0.065 8	0.999 5




图 4 ARIMA、BP 神经网络预测误差对比

4.2.2 ARIMA-BP 神经网络加权模型预测分析

为探究更好的预测模型用以桥梁 SHM 应变预测,通过结合各单一模型的优势,采用第 2 节提出的加权思路,对两类模型进行加权处理,以得到新的加权预测模型,并验证其合理性及有效性。其方法前 4 步分别为各单一模型的构建思路,第 5

步利用夹逼方法不断对加权预测序列的权值进行迭代,直至找到权值最优解,经反复运算,得到最终权值 $k_1 = 0.332\ 1$, $k_2 = 0.667\ 9$,其最小误差总和为 $21.092\ 7\text{ }\mu\epsilon$ 。将加权系数代入至加权公式中求得最终的加权预测序列,预测效果如图 5 所示。由图 5 可见,加权模型的预测结果与原序列的贴合度明显要优于单一模型,该模型既能完美符合变化趋势的同时几乎不与原序列曲线存在预测误差。




图 5 ARIMA-BP 加权模型预测结果

4.2.3 ARIMA-BP 神经网络组合模型预测分析

由于应变数据的变化不仅具有趋势性,还具有细微波动的复杂性,于是可对应变数据进行分解,将其分解为趋势项序列与细节项序列。已有研究表明,ARIMA 适用于对趋势项这一线性变化的序列预测,BP 神经网络模型则更适用于细节项这一复杂的序列预测^[14]。因此,可参照第 3 节的思路,利用 ARIMA 对桥梁 SHM 应变序列的趋势项部分进行预测,再选用 BP 神经网络模型对应变序列除趋势项以外的细节项部分进行预测,最后将两类单一模型进行组合叠加,以获得新的组合预测模型,并参照组合模型得出组合预测序列,预测效果如图 6 所示。由图 6 可见,组合模型的预测效果明显要优于单一模型,可以认为,该组合模型能很好地对原序列进行预测。




图 6 ARIMA-BP 组合模型预测结果

4.2.4 模型评价

由 4.2.1 节已知,BP 神经网络预测模型的预测效果要优于 ARIMA 预测模型,因此将加权模型、组合模型与 BP 神经网络预测模型进行对比,以分析加权、组合模型的优势与合理性。各类模型的误差评价见表 3。由表 3 可知:无论是加权模型还是组合模型的误差评价均优于单一模型,且各项指标均相差较大,其中加权与组合模型的 SSE 与 BP 神经网络模型相差最大,高达 50.23%;加权模型的各项误差评价指标均与组合模型的评价指标十分接近,其中,加权模型的 SSE、MES、RMSE 分别比组合模型的低 0.009 4、0.002 1、0.000 2,加权模型的误差指标 MAE、 R^2 与组合模型的相等,而 MAPE 高于组合模型 0.01%。

图 7 及图 8 分别为 BP 神经网络与 ARIMA-BP 加权模型预测误差对比以及 BP 神经网络与 ARIMA-BP 组合模型预测误差对比。由图 7、图 8 可知,BP 神经网络模型的误差包络范围明显大于其他两类模型,其中加权模型的误差总和约为 21.09 $\mu\epsilon$,组合模型的误差总和约为 20.97 $\mu\epsilon$,均小于 BP 神经网络预测模型的误差总和。因此,在本案例中,可以认为加权模型和组合模型的预测效果均要优于单一模型。图 9 为 ARIMA-BP 加权模型与组合模型预测误差对比。分析图 9,两类模型的误差包络范围接近,结合表 3 中的各项误差评价指标进行分析,可以认为 ARIMA-BP 加权模型与组合模型均适用于本案例应变序列的预测分析。

表 3 不同预测模型的误差评价

模型	SSE	MES	MAE	MAPE/%	RMSE	R^2
BP	2.594 8	0.805	0.050	23.68	0.065 8	0.999 5
加权模型	1.291 3	0.568	0.035	16.59	0.046 4	0.999 8
组合模型	1.300 7	0.570	0.035	16.58	0.046 6	0.999 8




图 7 BP 神经网络与 ARIMA-BP 加权模型预测误差对比




图 8 BP 神经网络与 ARIMA-BP 组合模型预测误差对比




图 9 ARIMA-BP 加权模型与组合模型预测误差对比

5 结论

通过对 ARIMA 模型与 BP 神经网络这两个分别适用于线性研究理论和复杂性研究理论的经典模型进行梳理,提出了基于这两种预测模型的加权模型与组合模型更适用于桥梁 SHM 应变预测的方法。并以江西省某跨江大桥桥梁结构健康监测系统的某一应变传感设备记录的应变监测数据为例验证了两种方法的合理性。得出以下结论:

- 1)BP 神经网络模型的预测结果优于 ARIMA 模型的预测结果。
- 2)当 ARIMA-BP 神经网络加权模型的权值 k_1 取值 0.332 1, k_2 取值 0.667 9 时,存在模型最小误差总和,值为 21.092 7。
- 3)无论是预测结果还是预测的误差指标均表明,ARIMA-BP 神经网络加权模型与 ARIMA-BP 神经网络组合模型均相比单一模型具有更好的预测效果。

参考文献

[1] 《中国公路学报》编辑部. 中国桥梁工程学术研究综述·2021[J]. 中国公路学报,2021,34(2):1-97.

[2] 秦权. 桥梁结构的健康监测[J]. 中国公路学报,2000(2): 39-44.

[3] DATTEO A,BUSCA G,QUATTROMANI G,et al. On the use of AR models for SHM: a global sensitivity and

- uncertainty analysis framework[J]. Reliability Engineering & System Safety, 2018, 170: 99-115.
- [4] OLIVEIRA M, FILHO J V. Structural health monitoring based on AR models and PZT sensors[C]//Sensors, IEEE, 2012.
- [5] 刘启斌, 尹温硕, 胡卫华, 等. 基于 LSTM 算法的电力谐波监测数据预测[J]. 电力电容器与无功补偿, 2019, 40(5): 139-145.
- [6] 陈兵. 基于优化 GM(1, 1) 模型的基坑位移监测数据预测方法[J]. 测绘与空间地理信息, 2020, 43(2): 222-224.
- [7] 陆萍, 王涛, 韦跃, 等. 时间序列模型在桥梁健康监测数据预测中的应用[J]. 重庆科技学院学报(自然科学版), 2018, 20(6): 75-79.
- [8] 沈健. 基于多传感器信息融合的桥梁健康监测系统的研究与实现[D]. 南京: 南京邮电大学, 2017.
- [9] 张鹏. 基于神经网络的桥梁监测数据挖掘[D]. 重庆: 重庆大学, 2007.
- [10] 崔建国, 李鹏程, 崔霄, 等. 基于 ARIMA-LSTM 的飞机液压泵性能趋势预测方法[J]. 振动. 测试与诊断, 2021, 41(4): 735-740, 832.
- [11] 张逸飞, 付玉慧. 基于 ARIMA-BP 神经网络的船舶交通事故预测[J]. 上海海事大学学报, 2020, 41(3): 47-52.
- [12] ZHANG G P. Time series forecasting using a hybrid ARIMA and neural network model[J]. Neurocomputing, 2003, 50: 159-175.
- [13] BABU C N, REDDY B E. A moving-average filter based hybrid ARIMA-ANN model for forecasting time series data[J]. Applied Soft Computing, 2014, 23: 27-38.
- [14] KHASHEI M, BIJARI M. A novel hybridization of artificial neural networks and ARIMA models for time series forecasting[J]. Applied Soft Computing, 2011, 11(2): 2664-2675.

Strain Prediction and Analysis of Bridge SHM Based on ARIMA-BP Neural Network Model

QIU Zhuo¹, HU Qiongqing¹, WU Weibin¹, ZHONG Jufang², WAN Ling^{1,3}

(1. Jiangxi Transportation Research Institute Co., Ltd., Nanchang 330200, China;

2. College of Civil Engineering, Nanchang Hangkong University, Nanchang 330063, China;

3. School of Architectural Engineering, Zhejiang University, Hangzhou 310058, China)

Abstract: The strain monitoring data of bridge structure health monitoring has strong tendency and randomness, in order to improve the prediction accuracy of the data, the traditional single autoregressive integral moving average model (ARIMA) and BP neural network prediction model are weighted and combined, and the two methods are applied to the prediction of the strain monitoring data recorded by the bridge structural health monitoring system of a river crossing bridge in Jiangxi Province. The results show that when the first mock exam is used alone, the BP neural network has better prediction effect than the ARIMA model. The prediction accuracy of weighted and combined models are better than that of single model, and the difference between the sum of squares error (SSE) of weighted model and combined model with BP neural network model is the largest, up to 50.23% and 49.87% respectively. By comparing the error indexes of the weighted model and the combined model, it is concluded that the prediction accuracy of the two prediction models is very close. The error envelope range of single prediction model is larger than that of the other two models, and the total error sum of ARIMA model is about 50 $\mu\epsilon$, the total error sum of BP neural network model is about 30 $\mu\epsilon$, the total error sum of the weighted model is about 21.09 $\mu\epsilon$, the total error sum of the combined model is about 20.97 $\mu\epsilon$. After analysis, both the weighted prediction model and the combined prediction model can predict the SHM strain of the bridge.

Keywords: structural health monitoring(SHM); auto-regressive integrated moving average(ARIMA); back-propagation network; weight prediction; combined forecasting