Интернет-журнал «Транспортные сооружения» <https://t-s.today>
Russian journal of transport engineering

2019, №2, Том 6 / 2019, No 2, Vol 6 <https://t-s.today/issue-2-2019.html>

URL статьи: <https://t-s.today/PDF/10SATS219.pdf>

DOI: 10.15862/10SATS219 (<http://dx.doi.org/10.15862/10SATS219>)

Ссылка для цитирования этой статьи:

Афанасьев В.С. Устранение влияния температурного воздействия на динамические параметры пролетных строений балочных мостов // Интернет-журнал «Транспортные сооружения», 2019 №2, <https://t-s.today/PDF/10SATS219.pdf> (доступ свободный). Загл. с экрана. Яз. рус., англ. DOI: 10.15862/10SATS219

For citation:

Afanasev V.S. (2019). Elimination of the effect of temperature on the dynamic parameters of bridge beams. *Russian journal of transport engineering*, [online] 2(6). Available at: <https://t-s.today/PDF/10SATS219.pdf> (in Russian). DOI: 10.15862/10SATS219

УДК 624.21

ГРНТИ 67.01.81

Афанасьев Владимир Сергеевич

ФГАОУ ВО «Российский университет транспорта», Москва, Россия

Старший преподаватель

E-mail: a89162825980@ya.ru

Устранение влияния температурного воздействия на динамические параметры пролетных строений балочных мостов

Аннотация. Статья является частью диссертационного исследования на тему "Комплексная экспериментальная оценка динамических параметров пролетных строений балочных мостов". В статье представлен обзор влияния факторов окружающей среды на динамический отклик пролетных строений мостов, приведены примеры определения технического состояния за счет учета влияния воздействия окружающей среды на реальных объектах. Представлен процесс идентификации повреждений на основе операционного модального анализа с учетом фильтрации влияния.

Автором рассмотрено влияние температурного воздействия окружающей среды на собственные частоты колебаний пролетных строений балочных мостов. Поставлен численный эксперимент на примере большого автодорожного разборного моста: определена температура моста с учетом дополнительного нагрева пролетного строения от солнечной радиации и без неё; рассчитаны значения динамических параметров пролетного строения от изменения температуры в течении календарного года; построена зависимость частоты колебаний пролетного строения от изменений температуры пролетного строения. Далее в статье произведен анализ временного ряда, образованного по данным частотных изменений пролетного строения. Для описания временного ряда использованы два различных метода: модель, основанная на статистической зависимости между исследуемыми данными, и модель рекуррентной нейронной сети. Перед применением статистической интегрированной модели авторегрессии – скользящего среднего выполнено разложение временного ряда на аддитивные составляющие: тренд, сезонную составляющую, остаток и шум. После этого выполнено построение математической модели, описывающей стационарный остаток временного ряда. Второй метод – на основе рекуррентных нейронных сетей, можно перефразировать как вопрос

построения регрессионной зависимости. на основе обучающего и тестового наборов данных была сформирована сеть в которой есть видимый слой с 1 входным сигналом, скрытый слой с 4 блоками и выходной уровень, который делает одно значение предсказания.

Ключевые слова: исключение сезонности; мониторинг; мосты; временные ряды; нейронные сети; прогнозирование; динамические параметры

Введение

Статья является частью диссертационного исследования на тему "Комплексная экспериментальная оценка динамических параметров балочных мостов". В общем виде мониторинг технического состояния искусственных сооружений можно описать как процесс обнаружения повреждений и стратегии описания конструкций с помощью математических моделей. Появление повреждений неизбежно ведет к изменению динамического отклика объекта [1], однако это изменение может быть связано с факторами окружающей среды (влияние температуры, сезонные изменения в характеристиках почвы и т. д.) или даже с временными нагрузками (ветровое давление, воздействие различных видов транспорта), которые оказывают существенное влияние на динамику [2]. Исследования мостов показывают – это влияние ведет к отклонению собственных частот сооружения до 10 % [3], что может скрыть изменение частот из-за появления повреждений.

Поэтому, прежде чем определять наличие повреждений в конструкции, необходимо оценить влияние окружающей среды и характера случайного нагружения на динамический отклик конструкции. Процесс идентификации повреждений на основе операционного модального анализа с учетом фильтрации влияния представлен на рисунке 1.

Рисунок 1. Последовательность процесса операционного модального анализа для идентификации повреждений (составлено автором)

Параметр u_k представляет "белый шум", стационарный Гауссовский процесс по всей полосе частот, x_k – отклик конструкции во времени, $u_{среды k}$ – воздействие окружающей среды, w_k – модальный вклад от случайных нагружений, v_k – шумы от внешних источников, y_k – измеряемый отклик конструкции, все стрелки обозначают векторы сигналов, а k означает индекс дискретного времени. Оценка воздействия среды и нагружений относительно

измеренного отклика производится на основе корреляционной зависимости между ними, например с помощью регрессионных моделей [4]. В работе [5] также изучено влияние разных типов возбуждения (измеряемые и регулируемые гармонические колебания, ударное воздействие молотком, запись "белого шума") моста на процесс идентификации повреждений.

На ряде внеклассных сооружений применяются системы мониторинга, где дополнительно используются показания скорости ветра и температуры для определения технического состояния. Одна из таких систем установлена на мосту Stonecutters, Гонконг, Китай [6]. Подобного рода сооружения находятся в сложных эксплуатационных условиях и подвержены различным агрессивным воздействиям окружающей среды, например сверхвысокой скорости ветра или неравномерному солнечному нагреву. Для предотвращения пагубного влияния на результаты модального анализа, на мосту фиксируются характеристики ветрового потока и температура нагрева конструкций. После этого, используя эти данные производится корректировка модальных параметров модели. Однако, проводятся исследования [7], в которых разрабатываются методы устранения влияния факторов окружающей среды без их прямого измерения, что позволит упростить системы мониторинга объектов за счет уменьшения количества измеряемых параметров.

1. Постановка задачи

В данной работе рассматривается влияние воздействия окружающей среды, в частности температурных изменений, на собственные частоты колебаний мостов. Объектом для исследований выбран путепровод из инвентарных мостовых конструкций – большой автодорожный разборный мост (БАРМ). Пролетное строение имеет длину 53,5 м, ширину 8,6 м и состоит из двух главных балок, собирающихся из шести средних и двух концевых секций, объединенных между собой поперечными балками двутаврового сечения, на которые укладываются щиты настила, выполненные в виде ортотропной плиты.

В расчетном комплексе Midas Civil была создана пространственная модель сооружения (рисунок 2). Модель объекта составлена из балочных элементов в виде двутавров для главных и поперечных балок и двутавров №14 для настила. Листы настила представлены пластинчатыми элементами заданной толщины, настил жестко соединен с поперечными балками. Для модели были определены значения динамических параметров в расчетном комплексе и при натурных испытаниях [8].

Рисунок 2. Пространственная модель автодорожного моста БАРМ, вид снизу [8] (составлено автором)

Для изучения влияния температуры на динамические характеристики моста был поставлен численный эксперимент. С этой целью составлена таблица 1 средних ежемесячных температур воздуха с учетом количества солнечных дней. При температурном расчете вводится

предположение, что во время солнечной погоды происходит дополнительный нагрев пролетного строения, который был учтен согласно "Рекомендаций по расчету температурных воздействий" [9] и только в период солнечных дней.

Таблица 1

Температура воздуха и моста при воздействии солнечной радиации

Месяц	Солнечно, дней	Т воздуха, °С		Дополнительный нагрев	Т моста, °С
		min, ночь	max, день		
1	2	-10	-7.5	5.12	-2.38
2	2	-7.4	-4	2.73	-1.27
3	3	-5	-0.4	0.27	-0.13
4	8	2.7	9.6	6.56	16.16
5	15	10.7	20	13.66	33.66
6	14	13.3	22.7	15.50	38.20
7	17	15.3	25.1	17.14	42.24
8	19	14.1	23.8	16.26	40.06
9	9	8.9	15.7	10.72	26.42
10	6	3	6.9	4.71	11.61
11	6	-1.5	1.4	0.96	2.36
12	2	-5.9	-3.4	2.32	-1.08

Составлено автором

Расчет нагрева пролетного строения произведен для каждого месяца с дополнительным нагревом и без него. Далее были определены дополнительные напряжения в главных балках конечно-элементной модели из-за нагрева. На следующем этапе эти напряжения были применены в качестве начальных условий для расчета собственных частот моста. Для каждого состояния произведен модальный анализ и сформирована генеральная совокупность данных. В итоге полученные данные на примере первой частоты колебаний можно представить в виде графика на рисунке 3. При годовых колебаниях температуры пролетного строения днем изменение первой частоты будет соответствовать графику 3.a (рис. 3). Для того чтобы проследить возможные закономерности, построим график 3.b (рис. 3), соответствующий изменению первой частоты за 3 года и выделим взвешенное скользящее среднее.

Рисунок 3. Изменение первой частоты колебаний пролетного строения за год (3.a) и три года (3.b) (составлено автором)

2. Создание предсказательных моделей по совокупности данных

Сгенерированные данные представлены в виде временных рядов – последовательно измеренных данных, описывающих протекающий во времени процесс. Первое, что необходимо сделать при анализе подобного рода данных, это оценить стационарность временного ряда – отсутствие тренда, сезонности, выбросов данных и т. д. По графику скользящего среднего на рисунке 3.б присутствует ярко выраженная сезонность данных – регулярное изменение частоты, повторяющееся в течение определенного периода времени, в данном случае ежегодно. Выбросы и устойчивые тренды отсутствуют – скользящее среднее не меняется от года к году, так как частоты самой конструкции остаются неизменными. Поэтому дальнейшая обработка будет производиться с упором на удаление сезонности.

В общем можно выделить два основных метода создания моделей для описания и прогнозирования временных рядов: математические методы, основанные на статистической обработке данных и методы машинного обучения, такие как, например, рекуррентные нейронные сети. Разберем каждый из них в отдельности.

2.1 Интегрированная модель авторегрессии – скользящего среднего (ARIMA)

Модель ARIMA относится к классу статистических моделей для анализа и прогнозирования временных рядов [10].

Название модели – это акроним, заглавные буквы которого буквально означают следующее:

- AR: Авторегрессия – это использование связи между текущими и некоторыми запаздывающими наблюдениями.
- I: Интегрированная – это процесс, который использует разницу между текущим и предыдущим наблюдением для того, чтобы временной ряд был неизменным.
- MA: Скользящее-среднее – это такая модель, где используется зависимость между наблюдением и остаточными ошибками от скользящей средней модели применительно к запаздывающим наблюдениям.

Каждый из этих компонентов явно указан в качестве параметра модели. Стандартные обозначения, используемые в ARIMA (p , d , q), где параметры заменяются числами для того, чтобы быстро указать конкретно используемую модель. Параметры модели означают:

- p – число запаздывающих наблюдений, содержащихся в модели, так же известное как порядок лаг;
- d – число порядка разности временного ряда;
- q – размер скользящего-среднего окна (порядок скользящего-среднего).

Применительно к моделям типа ARIMA различают два основных подхода, для того чтобы убрать сезонность и тренд во временных рядах – это дифференцирование и декомпозиция. В сгенерированных данных тренд отсутствует, поэтому предпочтительней воспользоваться методом декомпозиции, тогда тренд будет представлен в виде горизонтальной линии. В этом случае удобно воспользоваться абстракцией, когда временной ряд раскладывается на несколько составляющих: остаток (среднее значение в ряде), тренд, сезонность и шум (случайная вариация в ряде). Первые три составляющие относятся к систематическим – компоненты временных рядов, которые имеют согласованность или повторяемость и могут быть описаны и смоделированы. Шум, в свою очередь, относится к несистематическим – его невозможно смоделировать напрямую.

По графику 3.b можно видеть, что сезонность имеет одинаковую частоту и амплитуду (ширину и высоту циклов), то есть линейность сезонной составляющей. Тогда представляется возможным использовать аддитивную модель описания составляющих временного ряда, где изменения со временем последовательно производятся на одну и ту же величину:

$$y(t) = \text{остаток} + \text{тренд} + \text{сезонность} + \text{шум}$$

Разложение исходного временного ряда показано на рисунке 4.

Рисунок 4. Разложение исходного временного ряда на тренд, сезонность и остаток (составлено автором)

После того как произведена декомпозиция, следующим этапом является построение математической модели, описывающей стационарный остаток временного ряда. Построение модели на базе ARIMA требует вычисления параметров p , d , q , которое можно выполнить несколькими методами. В этой статье рассматривается метод итеративного поиска наилучшей модели путем перебора всех основных комбинаций параметров, оценка моделей производится по Информационному критерию Акаике (AIC). Этот критерий измеряет, насколько хорошо модель соответствует данным, принимая во внимание общую сложность описательной функции. Модель, которая точно описывает данные при использовании множества функций, будет иметь больший показатель AIC, чем модель, которая использует меньшее количество функций для достижения такой же точности. Поэтому необходимо выбрать модель, которая дает наименьшее значение критерия. После проведенного поиска коэффициенты $(0, 2, 0)$ дали минимальный результат AIC:-7965,1. На рисунке 5 на верхнем графике исходный ряд представлен синим цветом, красным – восстановленный ряд с помощью сформированной модели ARIMA $(0, 2, 0)$, на нижнем графике черным и красным показаны исходный и восстановленный остатки соответственно.

Рисунок 5. Описание исходного временного ряда и остатков моделью ARIMA (составлено автором)

2.2 Модель на основе рекуррентных нейронных сетей

Из всех разновидностей нейронных сетей для работы с временными рядами выделяют долгую краткосрочную память (LSTM), она хорошо приспособлена к обучению на задачах классификации, обработки и прогнозирования временных рядов в случаях, когда важные события разделены временными лагами с неопределённой продолжительностью и границами [11]. Эта рекуррентная сеть обучается с применением обратного распространения во времени – алгоритма, который используется для обновления весов с учетом всех сетевых параметров. Использование нейронной сети можно перефразировать как вопрос построения регрессионной зависимости.

При работе с временными рядами важно соблюдать последовательность использования значений. Простейшим методом подготовки к построению модели является разделение упорядоченного набора данных на обучающий и тестовый наборы данных. Разделим данные на обучающий набор данных с 67 % наблюдений, которые возможно использовать для обучения модели, а оставшиеся 33 % для тестирования модели.

После того, как исходные данные смоделированы и произведена оценка точности описывающей модели по обучающей выборке, нам нужно получить представление об предсказательной способности модели по новым, тестовым данным. Для регрессионной зависимости мы будем делать это с использованием перекрестной проверки.

Сформируем сеть, в которой есть видимый слой с 1 входным сигналом, скрытый слой с 4 блоками LSTM или нейронами и выходной уровень, который делает одно значение предсказания. Для блоков LSTM используется функция активации сигмоида по умолчанию. На рисунке 6 представлен график описания временного ряда и остатка с помощью сформированной модели. Оценкой точности в данном случае являлся квадратный корень из среднеквадратической ошибки (RMSE – root mean squared error), который составил 0,10 единиц.

Рисунок 6. Описание исходного временного ряда и остатков моделью LSTM (составлено автором)

3. Дальнейшие исследования

Обе модели дают неплохую описательную способность, среднеквадратичная ошибка находится в допустимых пределах. Ограничения для предсказательной способности моделей вводятся в связи с коррелированностью данных численного эксперимента, в будущем при долгосрочном мониторинге реальных объектов этого можно будет избежать за счет большего объема данных.

Следующим направлением исследований является соединение двух методов и построение ансамбля моделей на основе метода голосования (*Ensemble learning*) [12]. Это позволит улучшить предсказательную способность, устранить ошибки, возникающие при появлении выбросов и нивелировать недостатки каждой из моделей.

ЛИТЕРАТУРА

1. Maas S. Damage assessment of concrete structures through dynamic testing methods. Part 2: Bridge tests / S. Maas, A. Zürbes, D. Waldmann, M. Waltering, V. Bungard, G. De Roeck // Engineering Structures. 2012. Т. 34. С. 483–494.
2. Афанасьев, В.С. К вопросу вибрационного контроля динамических параметров мостов / В.С. Афанасьев // Наука XXI века: Опыт прошлого – взгляд в будущее [Электронный ресурс]: Материалы II Междунар. науч.-практ. конф. (25 апреля 2016 г., Омск) – Электрон. дан. – Омск: СибАДИ. – 2016. – С. 78–82.
3. Soyoz S. Long-term monitoring and identification of bridge structural parameters / S. Soyoz, M.Q. Feng // Computer-Aided Civil and Infrastructure Engineering. 2009. № 2 (24). С. 82–92.
4. Ramos L.F. Damage identification on masonry structures based on vibration signatures / PhD Thesis. – 2007. 232 с.
5. Maeck J. Damage identification on the Z24-bridge using vibration monitoring / J. Maeck, B. Peeters, G. De Roeck // Smart Mater. Struct. 2001. Т. 10, № 3. С. 512–517.
6. Colato G.P. Stonecutters cable-stayed bridge: full-scale testing of dynamic control devices / G.P. Colato, R. Chiarotto, M. Fetti, S. Infanti, M.G. Castellano // The 14th World Conference on Earthquake Engineering. – Beijing, China – October 12–17, 2008.
7. Nguyen V.H. Damage detection in bridge structures including environmental effects / V.H. Nguyen, J. Mahowald, J.-C. Golinval, S. Maas // EUROLYN 2014. – Porto, Portugal. – June 30–July 2, 2014. – pp. 2613–2620.
8. Афанасьев, В.С. Прогнозирование грузоподъемности мостов / Н.А. Донец, В.С. Афанасьев // Механизация строительства. – 2016. – Т. 77. – № 5. – С. 53–59.
9. Рекомендации по расчету температурных и усадочных воздействий на пролетные строения мостов. – М.: Минтрансстрой, 1988.
10. Adhikari, R. An Introductory Study on Time series Modeling and Forecasting / R. Adhikari, R.K. Agrawal // LAP Lambert Academic Publishing. – 2009.
11. Pedregosa F. Scikit-learn: Machine Learning in Python / F. Pedregosa // JMLR. 2011. №12, С. 2825–2830.
12. Zhang, G.P. Time series forecasting using a hybrid ARIMA and neural network model / G.P. Zhang // Neurocomputing. 2013. №50, С. 159–175.

Afanasev Vladimir Sergeevich
Russian university of transport, Moscow, Russia
E-mail: a89162825980@ya.ru

Elimination of the effect of temperature on the dynamic parameters of bridge beams

Abstract. An article presents an overview on influence of environmental factors on the dynamic response of bridge beams. Examples of the determination of the technical condition by taking into account the influence of the environment on real bridges are given. The process of damage identification based on operational modal analysis with filtering effects is presented.

Author considered an influence of temperature effect of the environment on eigenfrequencies of beam bridges. A numerical experiment was performed using a large road collapsible bridge as an example: bridge temperature was determined with additional heating of the girder from solar radiation and without it; the values of dynamic parameters of the girder from the change in temperature during the calendar year were calculated; the dependence of eigenfrequency of the girder on changes in temperature of the bridge is constructed. Further, an analysis of a time series formed from the eigenfrequency changes of the girder was made. Two different methods were used to describe the time series: a model based on a statistical pattern in the given data and a model of a recurrent neural network. Before applying the statistical autoregressive integrated moving average model, the time series was decomposed into additive components: trend, seasonal component, residuals and noise. After that, construction of a mathematical model describing the stationary residuals of the time series was performed. Second method – based on recurrent neural networks, can be rephrased as a question of constructing a regression model. on the basis of the training and test data sets, a network was formed containing a visible layer with 1 input signal, a hidden layer with 4 blocks and an output level that makes one prediction value.

Keywords: seasonality elimination; structural health monitoring; bridges; time series; neural networks; forecasting; dynamic parameters

REFERENCES

1. Maas S., Zürbes A., Waldmann D., Waltering M., Bungard V., De Roeck G. (2012). Damage assessment of concrete structures through dynamic testing methods. Part 2: Bridge tests. *Engineering Structures*, 34, pp. 483–494.
2. Afanas'ev V.S. (2016). K voprosu vibratsionnogo kontrolya dinamicheskikh parametrov mostov. *Nauka XXI veka: Opyt proshlogo – vzglyad v budushchee. [On the issue of vibration control of the dynamic parameters of bridges. Science of the XXI century: Experience of the past – a look into the future.]* Omsk: Siberian State Automobile and Highway University, pp. 78–82.
3. Soyoz S., Feng M.Q. (2009). Long-term monitoring and identification of bridge structural parameters. *Computer-Aided Civil and Infrastructure Engineering*, 2(24), pp. 82–92.
4. Ramos L.F. (2007). *Damage identification on masonry structures based on vibration signatures*, p. 232.
5. Maeck J., Peeters B., De Roeck G. (2001). Damage identification on the Z24-bridge using vibration monitoring. *Smart Mater. Struct.*, 3(10), pp. 512–517.
6. Colato G.P., Chiarotto R., Fetti M., Infanti S., Castellano M.G. (2008). *Stonecutters cable-stayed bridge: full-scale testing of dynamic control devices*. Beijing, China.
7. Nguyen V.H., Mahowald J., Golinval J.-C., Maas S. (2014). *Damage detection in bridge structures including environmental effects*. Porto, Portugal, pp. 2613–2620.
8. Donets N.A., Afanas'ev V.S. (2016). Prediction of lifting bridges. *Mechanization of construction*, 5(77), pp. 53–59 (in Russian)
9. (1988). Rekomendatsii po raschetu temperaturnykh i usadochnykh vozdeystviy na proletnye stroeniya mostov. [*Recommendations for the calculation of temperature and shrinkage effects on the span structures of bridges.*] Moscow: Mintransstroy.
10. Adhikari R., Agrawal R.K. (2009). An Introductory Study on Time series Modeling and Forecasting. *LAP Lambert Academic Publishing*.
11. Pedregosa F. (2011). Scikit-learn: Machine Learning in Python. *JMLR*, 12, pp. 2825–2830.
12. Zhang, G.P. (2013). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, pp. 159–175.