

基于多最小二乘支持向量机的桥梁温度挠度效应的分离

杨红¹, 孙卓², 刘夏平², 朱卫安¹, 王燕萍¹

(1. 广州大学 物理与电子工程学院, 广州 510006; 2. 广州大学 土木工程学院, 广州 510006)

摘要: 根据桥梁挠度的各成分的特性, 建立温度和温度挠度效应的非线性关系。为了提高温度挠度效应的拟合能力, 提出多最小二乘支持向量机(M-LS-SVM)拟合模型。通过减聚类方法将输入空间划分为一些小的局部空间, 在每个局部空间中用LS-SVM建立子模型。为解决子模型相互之间的严重相关问题, 提高模型的精度和鲁棒性, 各个子模型的预测输出通过主元递归(PCR)方法连接。实验和分析结果表明: 该方法能分离挠度监测信号中的温度效应, 为从长期监测信号中进行损伤识别提供基础数据。

关键词: 多最小二乘支持向量机; 温度; 温度挠度效应; 分离

中图分类号: TU13; TP183 **文献标识码:** A

Separation of bridge temperature deflection effect based on M-LS-SVM

YANG Hong¹, SUN Zhuo², LIU Xia-ping², ZHU Wei-an¹, WANG Yan-ping¹

(1. School of Physics and Electronic Engineering, Guangzhou University, Guangzhou 510006, China;

2. School of Civil Engineering, Guangzhou University, Guangzhou 510006, China)

Abstract: According to the characteristics various components of bridge deflection, the non-linear relationship between temperature and temperature deflection effect was established. In order to improve the regressive ability to fit the temperature deflection effect, a multiple least square support vector machine (M-LS-SVM) regressive model was presented. The subtractive clustering was adopted to divide the input space into several sub-spaces, and sub-models were built by LS-SVM in each sub-space. In order to minimize the severe correlation among sub-models and to improve the accuracy and robustness of the model, the sub-models were combined by the method of principal components regression (PCR). The experimental and analytical results show that the method can separate the temperature effect from monitoring signals of deflection and provide basis data for damage detection from long-term monitoring signals.

Key words: multiple least square support vector machine; temperature; deflection temperature effect; separation

大跨径预应力混凝土连续梁(刚构)桥的挠度是反映桥梁结构安全的重要指标之一, 利用各种挠度测量方法, 获取结构性能的异常变化信号, 及早发现大型结构的安全隐患, 已成为土木结构的研究方向^[1-5]。但尽管现代计算手段不断取得进步, 准确预测大跨预应力混凝土的长期挠度仍然不是一件容易的工作。

温度是影响桥梁结构信号变化的最主要因素, 很多学者都提出消除温度效应影响的方法。文献[6-7]利用统计获主成分分析了温度效应的变化规律, 文献[8-9]采用主成分分析、本征正交分解等方法来规避温度效应问题, 但基于主成分和本征分解的方法不能直接消除温度效应、在噪声环境下精度差且需要长达

几年的结构健康基准期才能有效地进行评估; 梁宗保^[10]根据桥梁挠度监测信息具有不同时间尺度的特点, 利用小波分析理论进行信号分离, 建立了温度效应的相移回归方程, 剔除了结构响应信息中的温度效应, 刘纲等^[11]同样利用长期监测信号的多尺度特性, 结合粒子群优化算法和滤波算法自适应改变日温差效应时间尺度的频率带宽, 提取日温差所在时间尺度上的信号来回归日温差效应规律, 由于日温差或年温差变化1℃引起的位移或应变改变量是相同的, 故回归得到的日温差效应规律即为温度效应规律, 回归统计方法虽简单易行, 却精度较低, 并且环境因素复杂多变, 通过该方法分离温度因素的作用效应并不可靠, 而且文献[10-11]都假设温度与温度挠度效应呈线性关系, 而实际上它们却是呈非线性关系; 陈德伟等^[12]尝试用神经网络方法通过实测值来模拟温度与挠度之间的非线性关系, 并用它来预测桥梁由温度所产生的挠度变化,

基金项目: 国家自然科学基金面上项目(51078093); 广东省科技计划项目(2011B010300026)

收稿日期: 2012-08-09 修改稿收到日期: 2013-01-25

第一作者 杨红男, 博士, 副教授, 1967年3月生

然而存在神经网络本身结构如何确定和精度问题。

温差效应由日温差效应和年温差效应组成,温差效应难于分离的困难在于年温差效应的频率太低,与长期挠度的频率相近,文献[10-11]提出的小波或粒子群滤波无法对它进行分离。文献[13]将温差效应作为整体考虑,提出最小二乘支持向量机(Least Square Support Vector Machine, LS-SVM)拟合的方法,将温度作为输入,温度产生的挠度效应作为输出,建立输入与输出的精细化非线性模型,确定温度和温度效应之间的定量关系,以实现桥梁挠度监测中温差效应的精确分离。

但文献[13]的模型为单模型结构形式,随着训练数据的增加,系统的复杂程度会急剧增大,再由于数据野点的存在,单一的回归模型往往不尽如人意,因此本文在文献[13]的基础上提出一种基于多最小支持向量机(Multiple Least Square Support Vector Machine, M-LS-SVM)建模方法,将温差作为 M-LS-SVM 模型的输入,温差产生的温差效应作为 M-LS-SVM 模型的输出,建立温差和温差效应的非线性关系,得到温差效应随温差变化的精确值。为了提高 LS-SVM 的拟合精度,对输入数据用减聚类算法分类,根据分类结果建立相应的 LS-SVM 子模型,再由 LS-SVM 子模型通过主元递归(Principal Component Regression, PCR)连接起来,形成 M-LS-SVM 模型,这样只要测量温差的变化,就能得到温差效应的变化,从而为分离长期健康监测中的温度效应提供了一种有效的新方法。

1 桥梁挠度信号和温度信号的成分分析

1.1 挠度监测信号和温度信号的组成

在桥梁挠度的长期监测中,考虑到影响挠度的主要原因,按照主成分分析法可以认为桥梁结构挠度响应增量信号 ΔY 和温度增量信号 ΔT 由下式组成

$$\left. \begin{aligned} \Delta Y &= Y_T + Y_P + Y_C + Y_D + Y_R \\ \Delta T &= T_d + T_f + T_y \end{aligned} \right\} \quad (1)$$

其中: Y_T 是温度挠度效应, Y_P 是荷载挠度效应, Y_C 是混凝土的收缩徐变挠度效应, Y_D 是结构的损伤挠度效应,徐变、损伤等引起的不可恢复的挠度变化都可归结到长期挠度中, Y_R 是系统的测试误差挠度效应; T_d 是日温差, T_f 是骤然降温, T_y 是年温差。式中各种效应和温差均是时间 t 的函数,与温度增量信号相对应,桥梁结构挠度响应的温度效应 Y_T 可以认为是由日温差效应、骤然降温效应和年温差效应组成,从式(1)可知,监测获取的结构响应增量信号是多种效应的叠加。

1.2 挠度信号组分的频率特性

桥梁挠度中的荷载效应频率比较高,通常在几 Hz;日温差效应通常是按每天 1 个循环周期考虑,若视天

为秒进行频率单位刻画,其频率为 1 Hz;而实测数据显示,若视小时为秒,则桥梁挠度和温度信号的幅值主要分布 0.01 Hz 以下的低频部分^[10],在该频率段,挠度的变化主要由徐变、损伤和年温差效应引起,也就是说温度效应中的年温差的影响尺度,与结构劣化效应(长期挠度)的时间尺度相近,并可能有重叠的部分。

荷载效应频率比较高,可以用滤波的方法处理;年温差效应由于频率低,单独处理相当困难。

1.3 温度与温度挠度效应的非线性关系

影响混凝土箱梁温度场的因素很多,有大气温度、混凝土的热参数、构件的形状、铺装层的厚度和颜色、空气湿度、太阳辐射强度,以及所处地理环境等。日照和骤然降温下,箱梁结构构件表面和内部在热对流、辐射、传导等方式作用下,混凝土结构的温度不仅随时间变化,而且结构物体内各点存在温度差,形成不均匀温度场,并存在明显的滞后现象^[14]。

根据结构力学原理,可建立结构温度与其挠度效应间的线性关系式。但由于大气温度与桥梁结构温度的差异,桥梁结构温度的挠度效应与大气温度间实质上是呈现非线性关系;同时考虑到桥梁结构温度场的复杂性,以及挠度是反映结构整体效应的指标,温度的挠度效应与结构测点温度间的关系实际为非线性关系。

2 桥梁挠度温度效应拟合的 M-LS-SVM 方法

2.1 M-LS-SVM 模型

对于非线性问题,可以通过非线性变换转化为某个高维空间中的线性问题。LS-SVM 基于结构风险最小化(SRM)思想,通过一个非线性映射 $\varphi(\cdot)$ 把样本从原空间映射到高维(M 维)的特征空间 F ,并在特征空间中构造函数 $h(z)$ 。

当用系统输入输出数据建立非线性对象的模型时,采用单个模型往往只是系统的一种近似模型,而不同模型在不同输入空间中的预测性能会有所不同。通过一定方式将这些单个模型进行连接,构成对象的整个输入空间模型,模型的预测精确度和鲁棒性将得到增强。

基于 M-LS-SVM 融合算法的思想,指的是将一个原始的特征样本空间,拆解成若干小的空间,然后分别在拆解后的小的特征样本空间上,建立各自的单支持 LS-SVM 模型,通过组合这几个单 LS-SVM 模型可得出结构比单 LS-SVM 模型性能更好的融合模型,相对于在原始的特征样本空间之上建立的支持向量模型,该融合模型在拟合性能、空间还有时间上的效率均要高很多。

连接多个子模型的一般化结构是模块式泛化结

构,如图 1 所示 M-LS-SVM 是由多个相对独立、协同作用的 LS-SVM 组成的系统。将已知较大的原始训练样本数据拆分成 n 个较小的子样本数据, n 个子样本数据通过各自的单支持向量机模型处理后得出 n 个输出数据 ($Y_1 \square Y_n$),最后再将所得出的 n 个输出数据进行融合,得到多个输出目标,最终达到融合建模的目的。M-LS-SVM 模型的输出是所有单个 LS-SVM 子模型输出的权连接,可表示为

$$Z = W^T Y = w_1 y_1 + w_2 y_2 + \dots + w_n y_n \quad (2)$$

其中: Z 是 M-LS-SVM 预测输出, $Y = [y_1, y_2, \dots, y_n]^T$, y_i 是第 i 个 LS-SVM 子模型的预测输出, $W = [w_1, w_2, \dots, w_n]^T$ 为连接权值向量, w_i 是连接第 i 个 LS-SVM 子模型的权值^[15],满足 $\sum_{i=1}^n w_i = 1$ 。




图 1 M-LS-SVM 模型

Fig. 1 Model of M-LS-SVM

LS-SVM 是一种新型机器学习方法,其原理是通过学习求出系统输入输出之间依赖关系的估计,标准 SVM 算法复杂度不依赖于输入空间的维数,而依赖于样本数据的个数,样本数据越大,求解相应的二次规划问题越复杂,计算速度越慢。与标准支持向量机不同,LS-SVM 用等式约束代替不等式约束,求解过程变成了解一组等式方程,避免了求解耗时的 QP 问题,求解速度相对加快。

对于第 i 个 LS-SVM,其表达式为:

$$h_i(z) = \sum_{j=1}^L \alpha_{ij} K_i(z_i, z_{ij}) + b_i \quad (3)$$

其中: $z_{ij} \in R^n$ 是第 i 个 LS-SVM 的样本数据, $b_i \in R$ 为一个偏差项, $K_i(z_i, z_{ij})$ 为核函数,它是实的对称函数,根据泛函的有关理论,只要一种核函数 $K_i(z_i, z_{ij})$ 满足 Mercer 条件,它就对应某一变换空间中的内积。

2.2 减法聚类算法

样本数据的划分是建立各子模型的前提,而直接划分非常困难,因此本文对样本数据进行聚类,以达到区域划分的目的。聚类的原则是使同一类中的对象具有尽可能大的相似性,不同类中的对象具有尽可能大的差异性。由于减法聚类算法是一种适合基于数据建模规则的自动提取方法,不需要预先确定聚类数,能够自适应地确定聚类数及类中心,进而确定模型的结构。减法聚类算法的聚类中心位置和个数通过数据点的密度指标来选择,这种方法能够有效地反映数据的分布

状况。考虑 q 维空间中的 p 个数据点 X_1, X_2, \dots, X_n ,其减法聚类过程分为下面几步:

步骤 1:首先由式(4)给出数据点 X_i 处的密度指标

$$D_i = \sum_{j=1}^p \exp\left[-\frac{\|X_i - X_k\|^2}{(0.05\eta)^2}\right] = \sum_{j=1}^p \exp\left[-\sum_{k=1}^q \frac{(x_{i,k} - x_{j,k})^2}{(0.05\eta)^2}\right] \quad (4)$$

其中:聚类半径 η 定义了该点的一个邻域,半径以外的数据点对该点的密度指标贡献甚微,取 $\eta = \frac{1}{2} \min_k \{\max_i \|X_i - X_k\|\}$ 。在计算每个数据点密度指标后,选择具有最高密度指标的数据点 X_{c1} 作为第一个聚类中心, D_{c1} 为其密度指标;

步骤 2:假定 X_{ck} 为第 k 次选出的聚类中心,相应密度指标为 D_{ck} ,对于每个数据点的密度指标按式(5)修正

$$D_i = D_i - D_{ck} \exp\left[-\frac{\|X_i - X_k\|^2}{(0.05\beta)^2}\right] \quad (5)$$

式中: β 是一个正数,定义了密度指标函数显著减少的邻域,为了避免所选中心的彼此之间距离太近,可选 $\beta = 1.5\eta$ 。选出密度指标最高的数据点 X_{ck+1} 作为新的聚类中心。当 $D_i < 0$ 时将此数据点的密度指标设置为零,也就排除了此数据点作为聚类中心的可能性;

步骤 3:判断 $\frac{D_{ck+1}}{D_{c1}} < \varepsilon$ 是否成立。若不成立,则转到步骤 2;若成立则退出,并由此结束聚类过程。 ε 是事先给定的参数,此参数决定了最终产生的初始化聚类中心数目。为保证所选中心能够更好的代表输入数据且聚类数量合适,这里取 $\varepsilon = 0.05$ 。

通过上述减法聚类过程,确定聚类中心和子模型数 n ,并将数据划分为 n 个部分。

2.3 基于 PCR 分析的输出综合

在式(2)中,对于 p 组数据, n 个单个网络可以得到 p 组预测值 Y ,将其构成矩阵 $H(p \times n)$,并将对应的 p 组输出期望值构成向量 $Y_{MLSSVM}(p \times 1)$ 。求解参数 W 的传统方法是采用最小二乘法,即 $W = H^* Y_{MLSSVM}$,其中 $H^* = (H^T H)^{-1} H^T$,可以通过对 H 进行奇异值分解来得到。但由于所训练的多个 LS-SVM 模型反映的是同一种非线性关系,其相互之间是严重相关的,采用最小二乘法难以得到较好的连接权值,这样整个模型的预测精度就会下降。采用 PCR 方法来综合多个模型的预报值,消除局部系统之间的数据相关性,提高系统的鲁棒性和泛化能力。

采用 PCR 方法将 H 写成如下形式

$$H = t_1 v_1^T + t_2 v_2^T + \dots + t_n v_n^T \quad (6)$$

其中 $t_i = u_i \lambda_i$ 和 v 分别为矩阵 H 的第 i 个主元分量和

负荷分量,为单位正交向量,且 $t_i = \mathbf{H}v_i$, λ_i 是矩阵 \mathbf{H} 的奇异值, u_i 和 v_i 分别是与奇异值 λ_i 对应的左特征向量和右特征向量。由于矩阵 \mathbf{H} 存在相关性,一般取反映对象主要变化部分的前 k 项来计算,从而构造矩阵 \mathbf{H}_k 如下

$$\mathbf{H} \approx \mathbf{H}_k = \mathbf{T}\mathbf{V}^T \quad (7)$$

其中: $\mathbf{T} = [t_1, t_2, \dots, t_k]$, $\mathbf{V} = [v_1, v_2, \dots, v_k]$ 。

由式(2)有:

$$\mathbf{Y}_{MLSSVM} = \mathbf{H}\mathbf{W} = \mathbf{T}\mathbf{V}^T\mathbf{W} \quad (8)$$

记 $\mathbf{W}_k = \mathbf{V}^T\mathbf{W}$, 可以计算 \mathbf{W}_k 的最小二乘解为

$$\mathbf{W}_k = (\mathbf{T}^T\mathbf{T})^{-1}\mathbf{T}^T\mathbf{Y}_{MLSSVM} \quad (9)$$

由于 \mathbf{V} 为正交向量,有 $\mathbf{V}^T = \mathbf{V}^{-1}$, 于是得到连接权值矩阵

$$\mathbf{W} = \mathbf{V}\mathbf{W}_k = \mathbf{V}(\mathbf{T}^T\mathbf{T})^{-1}\mathbf{T}^T\mathbf{Y}_{MLSSVM} \quad (10)$$

2.4 数据的预处理

对桥梁挠度的频谱分析表明,0.01 Hz 以上的频率成分可以看成荷载效应和噪声,可以用滤波的方法处理;对测量出的温度值也先用滤波的方法去除干扰噪声,然再用 EMD 的方法将温度信号分解,经验模态分解能根据信号本身的特点,自适应地将信号分解为若干个固有模态函数之和^[16-17],将测量的温度数据用 EMD 方法分离,是为了建立多输入、单输出的 LS-SVM 模型,增加模型的鲁棒性。

2.5 温差效应分离算法描述

综合以上内容,得出基于 M-LS-SVM 的桥梁挠度温度效应分离算法:

(1) 在模型训练阶段:

步骤 1: 首先将样本数据(包括温度信号、挠度的温度效应信号)进行滤波,然后将温度信号用 EMD 分解,形成 M-LS-SVM 的多输入信号;

步骤 2: 用减法聚类算法对样本数据进行分类;根据分类结果确定子 LS-SVM 模型的数目;

步骤 3: 用分类后的样本数据对各子 LS-SVM 模型进行训练,从而建立各子 LS-SVM 模型;

步骤 4: 用 PCR 分析方法得到 M-LS-SVM 中各子 LS-SVM 模型的连接权值,最终形成 M-LS-SVM 模型;

(2) 在分离阶段

步骤 1: 对测量的桥梁信号进行滤波,将温度信号用 EMD 分解;

步骤 2: 将温度数据作为 M-LS-SVM 模型输入,得到的输出结果就是相应的桥梁温度效应。

3 模拟及实测信号研究

3.1 模拟信号分析

背景桥取广州市某桥,该桥横跨骆岗水道,单孔双向通航,全桥跨径总长 650 m,分为主桥和引桥两部分,

主桥为 65 m + 100 m + 65 m (如图 2) 预应力砼连续箱梁,南、引桥均为 7 × 30 m 的先简支后连续预应力小箱梁。采用 Midas 软件计算右幅 50 m 点处的长期下挠值: 整体升温 1 °C, 跨中挠度 $f' = 1.4878$ mm; 截面线性温差 1 °C, 跨中挠度 $f'' = -1.5057$ mm, 取每天的整体日温差幅值为 8 °C、截面温差为 4 °C、年温差为 30 °C, 因日温差和年温差为周期性函数,假设其按正弦变化,根据文献[11],则可得到按时序变化的整体日温差 $T_{11}(t)$ 、截面日温差 $T_{12}(t)$ 和年温差 $T_2(t)$, 整体日温差效应 $f_{11}(t)$ 、截面日温差效应 $f_{12}(t)$ 和年温差效应 $f_3(t)$ 。温度计算公式 $T_0(t)$ 为

$$T_0(t) = T_{11}(t) + T_{12}(t) + T_2(t) \quad (11)$$

其中

$$T_{11}(t) = 4\sin\frac{\pi(t-6)}{12} \quad (12)$$

$$T_{12}(t) = 2\sin\frac{\pi(t-6)}{12} \quad (13)$$

$$T_2(t) = 15\sin\frac{\pi(t-2190)}{4380} \quad (14)$$

跨中竖向位移计算公式 $f_0(t)$ 为

$$f_0(t) = f_{11}(t) + f_{12}(t) + f_2(t) \quad (15)$$

其中

$$f_{11}(t) = 4f' \times \sin\frac{\pi(t-6)}{12} \quad (16)$$

$$f_{12}(t) = 2f'' \times \sin\frac{\pi(t-6)}{12} \quad (17)$$

$$f_2(t) = 15f'' \times \sin\frac{\pi(t-2190)}{4380} \quad (18)$$

上式中采样频率取 1 次/小时,温度单位为 °C, 挠度单位为 mm。




图 2 背景桥(65 m + 100 m + 65 m 主桥)立面图/cm

Fig. 2 Elevation of bridge/cm

一般认为在考虑年温差和日温差的情况下,温度变化以 1 年为一个周期,所以可以用一年的温度变化数据作为建立 M-LS-SVM 模型的依据,以 6 小时为采样周期计算 365 天(1 年)共 1 460 组温度和温度效应数据,将其中的 1 095 组数据作为 M-LS-SVM 模型训练集,另外 365 组数据作为 M-LS-SVM 模型测试集。将温度计算公式 T_0 的三个组成 $T_1(t)$ 、 $T_2(t)$ 和 $T_3(t)$ 作为 M-LS-SVM 的输入,通过减法聚类运算,训练用的 1 095 组数据被分成 5 个输入空间,也就是建立了 5 个 LS-

SVM 子模型,采用 PCR 方法来综合多个子模型的输出值,从而建立了 M-LS-SVM 模型,为了和文献[13]的方法进行比较,核函数采用 RBF 核函数,各子 LS-SVM 模型参数是在训练优化时自动生成。

用测试数据进行测试。图 3 上图是用公式(15)计算出的挠度温度效应和 LS-SVM 以及 M-LS-SVM 拟合的挠度温度效应的比较,图 3 和图 4 是 LS-SVM 以及 M-LS-SVM 的拟合误差;图 4 上图是模拟的长期挠度和用 LS-SVM 以及 M-LS-SVM 分离出温度挠度效应后的长期挠度的比较,下图为比较的误差值。评价分离效果可以有多种方法^[18],为了和文献[13]的方法比较,本文用均方误差和最大误差的绝对值来进行对比,对比结果如表 1 所示,可以看出 M-LS-SVM 模型的精度较之单个 LS-SVM 模型有提高。

表 1 M-LS-SVM 和 LS-SVM 的精度指标比较(单位 mm)

Tab.1 Comparison of accuracy index between M-LS-SVM and LS-SVM(Unit: mm)

	Midas 计算的 挠度温度效应和 拟合的挠度温度 效应的比较		Midas 计算的 长期挠度信号和 拟合长期挠度 信号的比较	
	均方误差	最大误差 的绝对值	均方误差	最大误差 的绝对值
M-LS-SVM	0.04	0.61	0.02	0.29
LS-SVM	0.05	0.78	0.02	0.36

注 1:动态挠度是仅考虑收缩徐变效时应用 Midas 计算出来的 3 年挠度值加上公式(15)计算出的挠度温度效应的叠加。

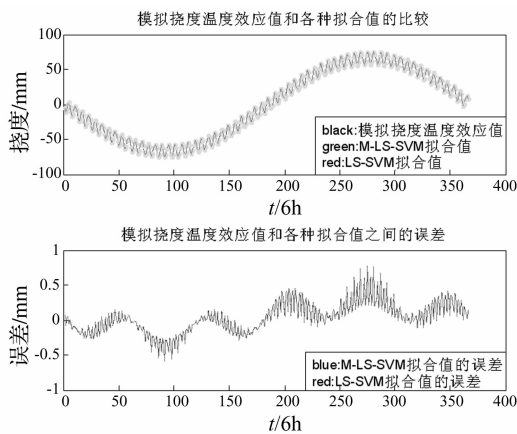


图 3 模拟的温度挠度效应及其拟合值的比较
Fig.3 Comparison of simulating temperature deflection effect and its regressive values

3.2 实测信号分析结果

背景桥均位于我国某高速公路,建成于 1996 年底。背景桥上部结构为变截面预应力混凝土连续箱梁,跨径组合为 75 m + 125 m + 75 m (如图 5),采用对称悬臂浇筑方法施工。




图 4 模拟的动态挠度及其长期挠度的拟合
Fig.4 Simulating dynamic deflection and long-term deflection regression




图 5 背景桥(75 m + 125 m + 75 m 主桥)立面图/cm
Fig.5 Elevation of bridge

为了建立 M-LS-SVM 模型,先要得到 M-LS-SVM 的训练样本值,M-LS-SVM 的训练样本值由实际的温差数据和温度挠度效应数据组成,温差数据由安放在桥梁上的温差传感器取得,温差挠度效应数据从一年的实时动态挠度数据相应地取得,过程如注 3 说明。考虑到要计算 10 年的长期挠度,所以以 12 小时为单位采样 365 天(1 年)的温差和温差效应数据,共 730 组数据,将其中 365 组温差和温差效应数据作为训练集,另外 365 组数据作为测试集。为了得到多维输入温差数据,提高 M-LS-SVM 模型的鲁棒性,本文先用 EDM 算法分离温差数据:设温差数据 $x(t)$ 为原信号序列, $imf_i(t)$ 为经 EMD 得到的本征模态函数, $r_n(t)$ 为余量,则原始信号可以表示为所有的 $imf_i(t)$ 及余量之和

$$x(t) = \sum_{i=1}^n imf_i(t) + r_n(t)$$

具体过程如文献[17]所示。根据分析,上式的 n 取 2,将 $\{imf_1(t), imf_2(t), r_n(t)\}$ 作为温差输入值。

通过减法聚类运算,训练用的 365 组数据被分成 4 个输入空间,也就是建立了 4 个子 LS-SVM 模型,采用 PCR 方法来综合多个子模型的输出值。

图 6 上图 LS-SVM 以及 M-LS-SVM 的拟合值和实际值的比较,下图是拟合值和实际值的误差。图 7 上图是实际的长期挠度和用 LS-SVM 以及 M-LS-SVM 分离后温度挠度效应的长期挠度的比较,下图为它们的误差值;表 2 是 M-LS-SVM 和文献[13]方法的精度指

标比较,可以看出 M-LS-SVM 模型的精度较之单个 LS-SVM模型有大幅提高。




图6 实际的温度挠度效应及其拟合值

Fig. 6 Actual temperature deflection effect and its regressive values




图7 实际的动态挠度及其长期挠度拟合(1996年-2006年)

Fig. 7 Actual dynamic deflection and long-term deflection regression(1996 — 2006)

表2 M-LS-SVM 和 LS-SVM 的精度指标比较(单位 mm)

Tab. 2 Comparison of accuracy index between M-LS-SVM and LS-SVM(Unit: mm)

	实际的挠度温度效应和拟合的挠度温度效应的比较		实际的长期挠度信号和拟合长期挠度信号的比较	
	均方误差	最大误差的绝对值	均方误差	最大误差的绝对值
M-LS-SVM	1.01	1.16	4.78	5.25
LS-SVM	1.60	1.78	6.91	8.89

注2:采集的数据首先经过滤波处理,目的是滤掉高频的活载效应和噪声干扰。

注3:在该桥梁建成合拢之初 t_1 时刻、温差为 T_1 时封路采集桥梁挠度 $s_1(t_1, T_1)$,相隔一年后再在温差为 T_1 并且封路的状态下采集桥梁挠度 $s_2(t_2, T_1)$ (由于封路荷载效应可以去掉,温差两次测量时温差都是 T_1 ,这样可以避免考虑温差效应的变化)。同时在 t_1 时点开始采集桥梁动态挠度数据,根据测量到的动态挠度数据,再结合测到的 $s_1(t_1, T_1)$ 、 $s_2(t_2, T_1)$ 和桥梁结构的性质计算 (t_1, t_2) 之间每个时点的长期挠度,而每个时点的温差效应 = 去掉活载效应的动态挠度 - 长期挠度。

4 结论

实现桥梁长期挠度的分离,关键在于年温度效应的分离,本文根据 M-LS-SVM 模型具有的函数逼近特性,通过学习确定了温度和挠度温度效应的非线性关系,并得出以下结论:

(1) 从以上的计算结果可以看出,建立将温度作为输入和挠度温度效应作为输出的 M-LS-SVM 模型,通过测定温度的变化取得挠度温度效应,这种方法是可行的;

(2) M-LS-SVM 模型较之单个 LS-SVM 模型,其拟合精度得到提高,能够更精确地确定温度与温度效应之间的非线性关系,是一种更为精确的分离方法;

(3) 基于 M-LS-SVM 的桥梁挠度监测中温度效应分离方法,将温度效应作为整体来考虑,避免单独分离低频的年温差效应。

本文研究成果为以后长期挠度的分离提供了依据和方便。

参考文献

- [1] Law S S, Li J. Updating the reliability of a concrete bridge structure based on condition assessment with uncertainties [J]. Engineering Structures, 2010, 32(1): 286 - 296.
- [2] Forrest R W B, Higgins C, Senturk A E. Experimental and analytical evaluation of reinforced concrete girders under low-cycle shear fatigue [J]. Structural Journal, 2010, 107(2): 199 - 207.
- [3] Burgoyne C, Scantlebury R. Why did Palau bridge collapse? [J]. The Structural Engineer, 2006, 84(6): 30 - 37.
- [4] Hao S, Asce M. I-35W bridge collapse [J]. Journal of Bridge Engineering, 2010, 15(5): 608 - 614.
- [5] Sasaki K K, Paret T, Araiza J C, et al. Failure of concrete T-beam and box-girder highway bridges subjected to cyclic loading from traffic [J]. Engineering Structures, 2010, 32(7): 1838 - 1845.
- [6] Xia Y, Hao H, Zanardo G, et al. Long term vibration monitoring of an RC slab: Temperature and humidity effect [J]. Engineering Structures, 2006, 28(3): 441 - 452.
- [7] Kim J T, Park J H, Lee B J. Vibration-based damage monitoring in model plate-girder bridges under uncertain temperature conditions [J]. Engineering Structures, 2007, 29(7): 1354 - 1365.
- [8] Lanata F, Grosso A D. Damage detection and localization for continuous static monitoring of structures using a proper orthogonal decomposition of signals [J]. Smart Materials and Structures, 2006, 15(6): 1811 - 1829.
- [9] Yan A M, Kerschen G, De Boe P, et al. Structural damage diagnosis under varying environmental conditions-Part I: A linear analysis [J]. Mechanical Systems and Signal Processing, 2005, 19(4): 847 - 864.

(下转第 88 页)

