

文章编号:1671-6833(2011)04-0013-05

基于神经网络的大跨度屋盖非高斯风压场模拟方法

孙芳锦^{1,2}, 张爱社³

(1. 同济大学 土木工程防灾国家重点实验室, 上海 200092; 2. 辽宁工程技术大学 建筑工程学院, 辽宁 阜新 123000;
3. 山东建筑大学 土木工程学院, 山东 济南 250101)

摘 要:采用径向基函数神经网络(Radical Basis Function Neural Networks,简称 RBF 神经网络)来模拟大跨度结构的非高斯风压场.根据某大跨度结构的形式特点,将结构风场看成是屋面位置和时间的函数,将风压场分解为一系列径向基函数.再利用单调非线性无记忆转换映射和 RBF 中获得的风场函数定义向量过程,从而将非高斯场的模拟转换为互相关高斯过程的模拟.将 RBF 神经网络应用于一大跨度屋盖的非高斯场模拟,得到结构上非高斯风压场的分布.结果对比表明,RBF 神经网络模拟非高斯风压场具有较高的准确性.该方法可直接利用 RBF 神经网络的输出结果,避免推导高斯过程和非高斯过程的关系式,因此具有较高的效率.RBF 神经网络模拟非高斯风压场在准确性和效率上均具有显著优势.

关键词:RBF 神经网络;大跨度结构;非高斯过程;风压场模拟;转换向量过程

中图分类号:TU312.1 **文献标志码:**A

0 引言

目前在风工程中计算结构风荷载一般采用高斯模型,这种模型未考虑湍流的二阶效应,但计算出的作用在结构上的风压也符合高斯规律.近年来通过对低矮建筑和高层建筑的风洞实验研究发现,由于风和结构间的相互作用,这些结构中受高湍流影响的位置,其风压时程体现出明显的非高斯特性^[1-3],比如位于分离流和涡流中的测点.因此发展数值模拟技术研究风压场的非高斯特性对于准确研究结构在风荷载作用下的特性和响应有着重要的意义和价值.

目前,国内外关于风压场的非高斯特性数值模拟研究还非常有限.国内外学者常采用的方法是静态转换方法,该方法主要是将非高斯和高斯两种过程联系起来,并且利用现有的高斯过程模拟方法实现对非高斯过程的模拟. Gurley, Holmes 等^[4-5]根据目标概率分布函数推导出非高斯过程的目标相关函数,然后将其转换成高斯过程的相关函数并模拟出高斯过程,再转换成非高斯过程. Winterstein 等^[6]则是采用 Correlation - Distortion

方法,根据前几阶目标矩(例如均值、方差、偏度和峰度)确定参数,例如采用 Hermite 级数的 N 项展开式来表达高斯过程和非高斯过程的转换关系.国内李璟等^[7]采用三次多项式表达风压过程和高斯过程之间的转换关系,推导出关于多项式所含参数的非线性方程组,利用高斯随机向量联合矩的特性获得相关函数的转换关系,最后模拟得到非高斯风压场分布规律.这种静态转换方法需要推导出高斯过程和非高斯过程间的相互关系,推导过程一般比较复杂.

笔者结合一大跨度屋盖结构形式,采用径向基函数神经网络(简称 RBF 神经网络)来模拟结构的非高斯风压场.将结构风场看成是屋面位置和时间的参数,并将该结构风压场的分解为一系列径向基函数(RBF).再利用单调非线性无记忆转换映射和 RBF 中获得的风场函数定义转换向量过程,从而将非高斯场的模拟转换为互相关高斯过程的模拟.该方法可直接利用 RBF 神经网络的输出结果,避免推导高斯过程和非高斯过程的关系式,通过将 RBF 神经网络应用于大跨度屋盖的非高斯场模拟,得到了结构非高斯特性风压场分布.

收稿日期:2011-01-20;修订日期:2011-04-20

基金项目:国家自然科学基金资助项目(51078225);辽宁工程技术大学博士启动基金(09139).

作者简介:孙芳锦(1981-),女,辽宁沈阳人,同济大学博士后,讲师,主要研究方向为建筑结构抗风. E-mail: whirlsun@163.com.

1 RBF 神经网络

1.1 RBF 神经网络基础

径向基函数神经网络是一种高效的前馈式神经网络,它具有其它前向网络所不具有的最佳逼近性能和全局最优特性,并且结构简单,训练速度快.典型 RBF 神经网络由输入层、隐含层和输出层^[8]构成,该网络的拓扑结构如图 1 所示.由输入层到隐含层的映射是非线性的,而隐含层到输出空间的映射是线性的,隐含层采用径向基高斯函数作为网络的激活函数,实现从输入空间到隐含层空间的变换.




图 1 典型 RBF 神经网络

Fig.1 Typical RBF neural networks

在图 1 的 RBF 神经网络中, $X = [x_1, x_2, \dots, x_n]^T$ 为网络的输入向量,这里为结构的风压数据. n 为输入层节点个数.

网络隐含层节点的径向基向量为 $H = [h_1, h_2, \dots, h_j, \dots, h_m]^T$, h_j 为高斯基函数,

$$h_j = \exp\left(-\frac{\|X - C_j\|^2}{2b_j^2}\right), j = 1, 2, \dots, m \quad (1)$$

在该隐层中,第 j 个节点的高斯基函数中心矢量为

$$C_j = [c_{j1}, c_{j2}, \dots, c_{jn}]^T, i = 1, 2, \dots, n \quad (2)$$

网络隐含层节点的基宽向量为

$$B = [b_1, b_2, \dots, b_j, \dots, b_m]^T \quad (3)$$

式中: b_j 是节点 j 的高斯基函数半径,其大小决定了网络的复杂程度,可以通过实验和误差信息选取适当的值. $\|\cdot\|$ 为欧式范数.

隐含层至输出层的权向量为

$$W = [w_1, w_2, \dots, w_j, \dots, w_m]^T \quad (4)$$

网络的输出函数为

$$y_m(x) = \sum_{j=1}^m w_j h_j \quad (5)$$

1.2 大跨度屋盖风场的 RBF 神经网络

笔者研究的大跨度屋盖的简图如图 2 所示,根据其结构形式,笔者将其风场看成是屋盖位置

θ 和时间 t 的函数,记作 $p(\theta, t)$,根据已知风压分布特性和风压分区^[9]将其分为 12 个位置,将该结构风压场的分解为一系列径向基函数(RBF),如图 3 所示.




图 2 大跨度屋盖平面图

Fig.2 Plan of long-span roof




图 3 大跨度屋盖的位置

Fig.3 Location of long-span roof

笔者根据结构非高斯风压场的特性,将隐含层至输出层的权向量用时间相关权向量表示,

$$\begin{cases} p(\theta, t) = \sum_{k=1}^N \omega_k(t) \varphi_k(\theta) \\ \varphi_k(\theta) = \varphi(|\theta - \theta_k|/\sigma) \end{cases} \quad (6)$$

式中: $\omega_k(t)$ 为权重向量,可以认为是风压场向量随机过程的分量; φ_k 是激活函数,它是激活函数中心位置 θ_k 的函数; θ_k 对应于实验中结构风压测点的位置.

根据结构位置的划分,此处相应于结构的结点数目应为 12,但为了描述结构边缘的压力分布,这里定义了两个各含有 6 个隐含神经结点的独立的神经网络.其中第一个神经网络用来描述上部(迎风面)屋面风压,节点数为 1 ~ 6,第二个神经网络用于描述下部(背风面)屋面风压,节点数为 7 ~ 12.

笔者的激活函数 ϕ 选为如下形式

$$\phi(r_k) = \begin{cases} \exp\left(-\frac{r_k^2}{1-r_k^2}\right), & |r_k| < 1 \\ 0, & |r_k| \geq 1 \end{cases} \quad (7)$$

其中 $r_k = |\theta - \theta_k|$, 随时间变化的系数 $\omega_k(t)$ 由实验获得的风压时间序列插值获得。

2 非高斯风压场的模拟

首先为得到高斯随机向量, 将实验得到的风压系数数据做如下转换

$$\begin{cases} c_g = \ln(a + bc_p), \\ c_p = (\exp(c_g) - a)/b \end{cases} \quad (8)$$

式中: a, b 为每个测压点在实验中测得的风压系数进行统计回归分析得到的系数(包括相对误差); c_p 为屋面压力系数, 为进行无量纲分析, 表示为如下形式

$$c_p(\theta, t) = 2p(\theta, t)/\rho v_m^2 \quad (9)$$

式中: ρ 是空气密度; v_m 是空气流体的平均速度; c_g 是与压力系数具有相同均值 $\mu(\theta)$ 和方差 $\sigma(\theta)$ 的高斯场

$$c_g(\theta, t) = \mu(\theta) + \sigma(\theta)c_{g,0.1}(\theta, t) \quad (10)$$

式中: $c_{g,0.1}(\theta, t) = N_{0.1}^{-1}(\mu(\theta, t))$ 为一零均值、单变量高斯场。

利用实验记录 c_p 和式(8)可以获得高斯变量 c_g 的新时程。此时利用单调非线性无记忆转换映射 $g(\cdot)$ 和 RBF 中获得的风场函数 $p(\theta, t)$ 定义一转换向量过程 $Y(t)$, $Y(t)$ 的第 k 个分量可以表示为^[10]

$$Y_k(t) = g_k[p_k(t)] = F_{X_k}^{-1}[\Psi_p(p_k(t))] \quad (11)$$

式中: $F_{X_k}(x_k)$ 是 $Y_k(t)$ 的边缘分布; Ψ_p 是风压场函数 $p_k(t)$ 的边缘分布, 为标准高斯分布, 即

$$\Psi_{p_k}(p_k) = p[P_k(t) \leq p_k], k = 1, \dots, m \quad (12)$$

利用上式可以将非高斯场的模拟转换为互相关高斯过程 c_{gk} 的模拟, 然后再利用式(8)将获得的高斯过程转换为对数正态过程 c_{pk} 。

3 数值算例

利用上述方法, 对图3所示屋面结构的非高斯风压进行模拟。根据相关资料^[9], 顺风向风场采用 Kaimal 纵向谱, 10 m 高平均风速为 26.8 m/s, 对应的风压约为 0.45 kN/m², 地表粗糙度类别为 II 类。将风压场离散为作用在屋盖上 382 个点的风压时程。

根据该结构情况将其做如图3所示的划分, 屋面上的位置恰好和 RBF 神经网络的中心相对应。本例中共有 12 个互相关过程, 通过一 12 阶的多回

归数字过滤器共生成了 14.4 万个样本, 对实验数据^[9]进行回归分析得到的系数值如图4所示。

为便于计算, 将结构划分为 16 个区域, 如图3所示。由实验结果^[9]可知, 在屋脊线附近气分离较为严重, 即屋脊线附近区域 1~16 区块均会呈现非高斯风压。首先利用屋盖上在实验中测得的 0° 风向角下块 1、3、5、13~16 区块的已知风压作为 BRF 神经系统的训练值。然后利用该神经系统预测 0° 风向角下测点区域 7、9、10、11~12 的非高斯风压场, 并利用 AR 模型生成风压时程样本, 计算共耗时 136 s。受篇幅所限, 这里只给出区块 9、10、12 的非高斯风压系数, 如图 5~7 所示。




图4 回归分析得到系数值

Fig. 4 Coefficients obtained from regression analysis




图5 区域9的风压时程

Fig. 5 Wind pressure history of zone 9




图6 区域10的风压时程

Fig. 6 Wind pressure history of zone 10




图7 区域12的风压时程

Fig. 7 Wind pressure history of zone 12

为检验风压时程模拟的正确性,需要对模拟的风压时程进行统计,计算出自相关、互相关函数并与相应的目标相关函数进行对比,如图8所示,可以看出两者吻合得非常好。

为检验风场的非高斯性,需全面检验风压时

程模拟样本的概率分布特性,这里选取区域10和区域11,根据模拟的时程曲线拟合出其PDF曲线,并与根据实验数据得到的PDF曲线对比,如图9所示,可以看出笔者的模拟值具有很高的精确度。




图8 风压时程的自相关函数、互相关函数

Fig. 8 Auto/cross correlation functions of the wind pressure time histories




图9 风压时程样本非高斯分布检验

Fig. 9 Verification of non-Gaussian distribution of the generated wind pressure time histories

5 结论

笔者采用径向基函数神经网络来模拟大跨度结构的非高斯风压场。将结构风场看成是屋面位置 and 时间的函数,将风压场分解为系列径向基函数。再利用单调非线性无记忆转换映射和RBF中获得的场函数定义转换向量过程,从而将非高斯场的模拟转换为互相关高斯过程的模拟。

(1) RBF神经网络在模拟非高斯风压过程中,当网络及函数中心选择适当时,只要很少的节点就可以获得很好的逼近效果,节省计算资源。

(2) RBF神经网络方法可直接利用RBF神经网络的输出结果,避免推导高斯过程和非高斯过

程的关系式,因此具有较高的效率。

(3) 对实际工程屋盖的风压场模拟算例表明:采用RBF神经网络方法模拟出来的风压时程具有非高斯特征,样本的相关函数、PDF曲线分别与目标曲线吻合得很好,说明模拟效果准确可靠。

(4) RBF神经网络适用于非高斯风压场的模拟,准确性高、效率高。

参考文献:

- [1] HOLMES J D. Non-Gaussian characteristics of wind pressure fluctuations[J]. Wind Engng. and Industrial Aerodynamics Amsterdam, 1981, 7: 103 - 108.
- [2] KAWAI H. Pressure fluctuations on square prisms-Applicability of strip and quasi-steady theories [J]. Wind Engng. and Industrial Aerodynamics, Amsterdam, 1983, 13: 197 - 208.
- [3] STATHOPOULOS T. PDF of wind pressures on low-rise buildings[J]. Journal of Structural Engineering, ASCE, 1980, 106(5): 973 - 990.
- [4] GURLEY K R, KAREEM A. Simulation of a class of non-normal random processes[J]. International Journal of Non-linear Mechanics, 1996, 31(5): 601 - 617.
- [5] HOLMES J D, COCHRAN L S. Probability distributions of extreme pressure coefficients[J]. Journal of Wind Engineering Industrial Aerodynamics, 2003, 91: 893 - 901.
- [6] WINTERSTEIN S R. Nonlinear vibration models for extremes and fatigue[J]. Journal of Engineering Mechanics, 1988, 114(10): 1772 - 1790.
- [7] 李璟, 韩大建. 屋盖结构非高斯风压场两步快速模拟法研究[J], 建筑结构学报, 2010, 31(4): 78 - 85
- [8] 刘金琨. 先进PID控制及其MATLAB仿真[M]. 北

- 京:电子工业出版社,2003.
- [9] 田森源,楼文娟. 杭州大剧院风压分布的风洞试验研究[J]. 实验力学, 2004, 19(1): 6 - 11.
- [10] GRICORIU M. Applied non-Gaussian processes: examples, theory, simulation, linear random vibration and MATLAB solutions [M]. Englewood Cliffs, NJ: Prentice-Hall, 1995.

Non-Gaussian Wind Field Simulation Method for Large-span Roofs Based on Neural Networks

SUN Fang-jin^{1,2}, ZHANG Ai-she³

(1. State Key Laboratory for Disaster Reduction in Civil Engineering, Tongji University, Shanghai 200092, China; 2. Institute of Civil Engineering & Architecture, Liaoning Technical University, Fuxin 123000, China; 3. School of Civil Engineering, Shandong Jianzhu University, Jinan 250101, China)

Abstract: Radical basis function neural networks (RBF neural networks for short) are adopted to simulate numerically non-Gaussian wind field of large-span roofs. According to properties of a large-span roof, the wind field is considered as the function of position and time, decomposed into a series of radical basis functions. And monotonic nonlinear memoryless transformation mapping and wind field function obtained from RBF neural networks are combined to define a transformation vector process, with which non-Gaussian process is transformed to Gaussian process for simulation. The proposed RBF neural networks are applied to the simulation of non-Gaussian wind field of a large-span roof. And the non-Gaussian wind field distribution on the roof is obtained. Comparison of results shows that RBF neural networks are highly accurate when simulating non-Gaussian wind field. The method can make direct use of the outputs of RBF neural networks, without deriving formula between non-Gaussian process and Gaussian process. Thus, RBF neural networks have obvious edge in simulating non-Gaussian wind field of large-span roofs, both in accuracy and efficiency.

Key words: RBF neural network; large-span roof; non-Gaussian process; wind field simulation; transformation vector process