

文章编号:1671-6833(2008)04-0116-04

基于图像识别和神经网络的大跨度结构风荷载模拟

孙芳锦¹, 张大明², 殷志祥¹

(1. 辽宁工程技术大学 土木建筑工程学院, 辽宁 阜新 123000; 2. 辽宁工程技术大学 技术与经济学院, 辽宁 阜新 123000)

摘 要: 将图像识别技术和神经网络(ANN)系统相结合, 给出了大跨度结构风荷载的模拟方法。采用递归图和特征脸识别两种图像识别技术, 将风速时间数值序列转化为图像信息, 然后将大量风速时间序列转换为维数较少的向量 Ω , 再结合多层 ANN 体系得到简化的神经网络模型, 预测出空间各点的风速时程。最后将其应用到一大跨度结构的风荷载模拟中, 结果不仅与目标值符合良好, 而且可以减少神经网络的层数, 大大提高运算速度和结果的可信度。

关键词: 图像识别技术; 神经网络; 风荷载模拟; 图像信息; 计算效率

中图分类号: TU 312⁺.1

文献标识码: A

0 引言

近年来大跨度结构在现代社会中越来越多地受到人们的青睐。由于这类结构自身的高柔性、质量轻、非线性等特性, 使得风荷载成为此类结构的控制荷载。由于现行的结构设计规范^[1]对该类结构风荷载计算的规定并不完善, 因此找到能准确预测该类结构风荷载的方法就尤为重要。通常最可靠的方法是进行风洞试验, 但由于风洞试验的造价高, 且受到相似条件、测点有限等客观因素的限制, 使得风洞试验的使用范围也有一定的局限性, 因此许多研究人员便将目光转向寻找更经济可靠的方法上。在过去的几年内, 人工神经网络^[2](ANN)在大跨度空间结构风工程的应用中也已取得了一些进展, 包括预测建筑结构表面静风压特性^[3,5], 及对脉动风的模拟^[3,6]等。

以上文献在对风荷载的模拟中, 一般都只单独采用 ANN 技术, 一个 ANN 系统通常由输入层、隐含层和输出层构成。其中隐含层的神经元数是经过反复试算分析得到的, 文献^[7]指出隐含层的神经元数至少为输出神经元数的 10 倍。通常结构风荷载的模拟需要的输出值较多, 这就需要大量的隐含层和神经元的数目, 从而大大增加了计算量, 对结果的准确度也会造成一定影响。

笔者将图像识别技术和神经网络(ANN)系

统相结合, 给出了大跨度结构风荷载的模拟方法。采用递归图和特征脸识别两种图像识别技术, 将风速时间数值序列转化为图像信息, 然后将大量风速时间序列转换为维数较少的向量 Ω , 再结合多层 ANN 体系得到简化的神经网络模型, 预测出空间各点的风速时程。最后将其应用到一大跨度结构的风荷载模拟中, 并将其结果与目标值进行了对比。

1 人工神经网络技术和图像识别技术

1.1 人工神经网络技术

人工神经网络是由大量简单的神经元广泛连接而成的网络, 具有自学习、自适应性、联想记忆功能和较强的鲁棒性和容错性。反向传播网络(简称 BP 网络)是目前应用最为广泛的神经网络。BP 网络无需建立数学模型就能直接实现系统输入与输出参数之间的复杂非线性映射。图 1 为 BP 网络的拓扑结构。BP 网络由 3 个层次的神经元组成: 输入层、隐含层和输出层。每一层神经元只接受前一层神经元的输入, 并在节点上进行复合(线性叠加)和畸变(非线性映射)。

1.2 图像识别技术

应用多层 ANN 和图像识别技术将数值风速时间序列转化为图像信息, 得到简化的神经网络模型。这里采用递归图和特征脸识别两种图像识

收稿日期: 2008-07-14; 修订日期: 2008-08-13

基金项目: 辽宁省教育厅基金资助项目(202183391)

作者简介: 孙芳锦(1981-), 女, 辽宁沈阳人, 辽宁工程技术大学讲师, 博士, 主要从事大跨度结构的风振研究, E-mail: whirl_sun@163.com.

别技术. 递归图是数值序列的图形表达, 它表示了数值序列在多维空间中的投影图^[8]. 笔者首先利用递归图将风时间数值序列转化为图形表达, 然后应用特征脸识别技术将大量风时间序列转换为维数较少的向量 Ω , 这样可以大大减少在 ANN 训练时所需的信息量, 从而提高计算效率. 整个图像识别的过程如下:




图1 BP神经网络拓扑图

Fig. 1 BP neural network topological diagram

(1) 给定向量之间距离为 dE 的一组数值序列, $X_i = \{x_i, x_{i+1}, \dots, x_{i+dE-1}\}$, 此时生成了 n 个 X_i 向量.

(2) 当定义向量 X_i 后, 就可以计算它们之间的 Euclidean 距离, 同时将制成计算表. n 个向量共有 $n(n-1)/2$ 个 Euclidean 距离, 根据需要, 可以使这些距离位于表的上三角或下三角部分. 由于该表对称, 则表中其余值也可以求出.

(3) 递归图是通过对比表中的每两个向量之间的距离用不同颜色来代表而形成的, 比如向量 X_1, X_2 之间的距离 $X_1 - X_2$ 与向量 X_1, X_3 之间的距离 $X_1 - X_3$ 就用不同的颜色来表示.

(4) 根据步骤(2)生成数据表后把数据分成若干列, 形成相应时间序列的向量 Γ .

(5) 向量 Γ 经排列共生成 n^2 个文件, 根据下面的式(1)和式(2)用来形成矩阵 $A = \{\Phi_1, \Phi_2, \dots, \Phi_n\}$,

$$\Psi = \frac{1}{M} \sum_{i=1}^M \Gamma_i \quad (1)$$

$$\Phi_n = \Gamma_n - \Psi \quad (2)$$

(6) M 是用来形成矩阵 A 所选择的图象或时间序列的个数, M 也叫做空间图象, 一套完整的图

象可以生成多个空间图象.

(7) 矩阵 A 生成后, 其相应的特征向量 u_i ($1 < i < M$) 便可获得.

(8) 最后, 向量 $\Omega = [\omega_1, \omega_2, \dots, \omega_n]$ 可以根据式(3)计算

$$\omega_k = u_k^T (\Gamma - \Psi) \quad (3)$$

当 ANN 训练后, 可以得到向量 Ω 的预测值, 并根据式(4)计算得到重组图象 Φ_f ,

$$\Phi_f = \sum_{i=1}^M \omega_i u_i \quad (4)$$

上述(1)~(8)的步骤是可逆的^[9].

2 算例分析

应用上述的 ANN 方法和图像识别技术, 基于平均风速和场地地面粗糙度, 对一双坡型, 四周封闭的大跨度膜结构不同点的风速时程进行了预测. 图2给出了预测双坡型膜屋盖风荷载的测点分布, 受篇幅限制, 这里只给出具有代表性点的位置. 这里只考虑 0° 风向角的情况, 对水平脉动风速进行了模拟, 水平脉动风速时程的目标谱采用 Davenport 谱, 考虑风的空间相关性.




图2 双坡型膜屋盖风荷载测点分布
Fig. 2 Wind load measuring points
on double-slope membrane roof

在对未加训练的点进行预测之前, 首先要将数据根据步骤1, 2进行预处理, 计算递归图并获取用来训练 ANN 的向量 Ω . 这里采用的 BP 神经网络如图1所示, 输入层的神经元为3或4个(注: 由于后面需要用到两个独立的神经系统, 而这两个系统中, 第一个系统的输入为3个神经元, 第二个系统的输入为4个神经元.), 输出层的神经元为1个, 隐层的神经元经过反复试算, 确定为18个, 此时的精度最好, 隐含层只需1个. 用来训练 ANN 的风速时间序列由 5 m/s , 10 m/s , 25 m/s , 30

m/s,40 m/s,50 m/s,60 m/s,70 m/s,80 m/s,90 m/s 共 10 种风速根据 AR 方法生成^[10]. 结构上接受训练的测点如图 2 中所示,共 4 个;输入变量高度 h 为 10 m 和 100 m;这里风速采用指数律,指数 k 按场地粗糙度类别 I ~ IV 分别取值为 0.12, 0.16,0.22,0.30^[11]. 则每一个高度上共有 160 个风速记录.

此处应用图像识别技术可以获得 160 个递归图,其中 16 个空间图像,每个图像有 10 个图形,这些图形相应的特征向量 $\mu_i(1 < i < 10)$ 也可以求得. 最后,用前面所述方法定义相应于每一时间序列的权值向量 $\Omega = [\omega_1, \omega_2, \cdots, \omega_M]$,训练 ANN 系统.

这里需要两个独立的神经系统,第一个系统的输入为 V_{10}, k ,高度 h . 第二个系统的输入除了第一个系统的相同向量外,还有第一个系统的输出值,其输出值用来定义向量 Ω . 当用 ANN 系统确定向量 Ω 后,就可以得到相应的时间序列. 因为如果 $dE = 1$,根据 1、2 所述,数据表中的文件就是所要预测点的法向分量,它是用 V_{max} 进行正交分解得到的.

用以上神经系统预测了当风速 $V_{10} = 25 \text{ m/s}, k = 0.19, h = 10 \text{ m}$ 时四个权值向量中的一个,表 1 给出其前 10 阶的值.

表 1 ANN 系统预测的向量 Ω 值
Tab.1 Vector Ω predicted by ANN

V_{max}	ω_1	ω_2	ω_3	ω_4	ω_5
16.87	313.5	167.4	313.3	283.4	-529.2
V_{max}	ω_6	ω_7	ω_8	ω_9	ω_{10}
16.87	164.3	-89.6	-289.1	-426.8	-712.7

受篇幅限制,图 3 只给出了训练点 1 的风速时程,采样时间间隔为 0.1 s,持续时间 200 s.




图 3 训练点 1 的风速时程
Fig.3 Wind series trained by ANN of point 1

表 2 给出了接受训练的有代表性的 6 个点模拟的风速时程的统计分析结果,得到其均值和均方差,并与目标(谱)值进行了对比.

表 2 ANN 系统的训练结果统计分析

Tab.2 Statistical analysis of ANN training results

点的位置	均值		方差	
	目标值	训练值	目标值	训练值
1	122.56	122.82	298.33	298.46
2	143.39	143.50	305.26	306.38
3	163.84	164.02	366.81	367.04
4	132.24	132.40	216.74	216.88
5	186.57	186.75	402.35	402.44
10	176.21	176.33	377.29	377.46

分析表 2,可以看出通过 ANN 模型训练出的结果与目标值非常接近,说明该模型已经可以用于对结构进行风荷载的预测.

图 4 预测了目标点 8 的风速时程,采样时间间隔 0.1 s,持续时间 200 s.




图 4 预测目标点 8 的风速时程
Fig.4 Wind series predicted by ANN of point 8

表 3 给出了未接受训练点的风速时程的统计结果,并与目标值进行了比较.

表 3 ANN 系统的预测结果统计分析
Tab.3 Statistical analysis of ANN predicted results

点的位置	均值		方差	
	目标值	训练值	目标值	训练值
6	153.27	153.40	368.14	368.30
7	203.58	203.77	408.34	408.65
8	176.22	176.40	370.53	370.65
9	226.49	226.69	438.22	438.35

从表 3 中可以看出,预测值和目标值比较接近,其中均值的最大绝对误差是 0.20,方差的最大绝对误差是 0.31,这样的误差在工程范围内是可以接收的. 因此笔者提出的 ANN 训练方法可以准确有效的预测结构的风荷载,从而证明了该方法的可行性.

除了准确性以外,该方法还有计算量小,速度快的明显优势. 一般方法训练 ANN 系统,要得到本文中 2 min 的风速时间序列所需的 1 200 个输出值,会需要大量的隐含层和神经元;而笔者由于引入了只有 10 个值形成的小维数向量 Ω ,训练时

只需含有18个神经元的一个隐含层就可以达到目标.因此,本方法减少了神经网络的隐含层数,同时也增加了计算结果的可靠性.

3 结论

结合图像识别技术和神经网络,提出了适用于大跨度结构风荷载模拟的方法.在已知地面粗糙度,随高度变化的平均风速及目标谱的条件下,应用本文方法可以预测结构上不同点的风速时程.基于图像识别技术的神经网络不仅能准确地预测出大跨度结构的风荷载,而且与普通神经网络相比,它能大大减少隐含层的数量,这样就大大减少了在ANN训练时所需的信息量,使计算效率大大提高,同时增强了计算结果的可靠性.

参考文献:

- [1] 中华人民共和国建设部 GB 50009-2001 建筑结构荷载规范[S].北京:中国标准出版社.
- [2] 赵林,王丽.基于BP神经网络的结构系统跟踪辨识方法[J].郑州大学学报:工学版,2005,26(1):50-53.
- [3] 顾明,周毅.神经网络方法在大跨度屋面风压研究中的应用[J].工程力学,2003,20(4):99-103.
- [4] 傅继阳,谢壮宁,倪振华.大跨度屋盖结构风压分布特性的模糊神经网络预测[J].建筑结构学报,2002,23(1):62-67.
- [5] 傅继阳,甘泉.大跨平屋盖结构风压分布特性的神经网络模型[J].华南理工大学学报,2003,31(8):62-66.
- [6] 丁幼亮,李爱群,杜东升,等.基于神经网络的大跨度空间结构脉动风荷载的随机模拟[J].特种结构,2006,23(2),1-3.
- [7] MULLER B, REINHARDT J, STRICKLAND M T. Neural networks [M]. vol. 55. Springer - Verlag, 1995.
- [8] ECKMANN J P, KAMPHORST O S, RUELE D. Recurrence plots of dynamical systems [R]. Europhysics Letters, 1987.
- [9] TURK M, PENTLAND A. Eigenfaces for recognition [J]. Journal of Cognitive Neuroscience, 1991,3(1):774-776.
- [10] 向阳,沈世钊,李君.薄膜结构的非线性风振响应分析[J].建筑结构学报,1999,20(6):38-46.
- [11] 陈政清,项海帆.桥梁风工程[M].北京:人民交通出版社,2005.

Application of ANN Based on Image Recognition Technique in Wind Load Simulation of Long-span Structures

SUN Fang-jin¹, ZHANG Da-ming², YIN Zhi-xiang¹

(1. Institute of Architecture and Civil Engineering, Liaoning Technical University, Fuxin 123000, China; 2. Technical and Economic Institute, Liaoning Technical University, Fuxin 123000, China)

Abstract: Through the combination of image recognition technique with ANN system, wind load simulation of long-span structures is presented. Two image recognition techniques, recurrence plot and eigenfaces recognition are employed to convert wind time series into image information. Then a large number of wind time series is transformed into short dimension vectors Ω . Finally, combined with multi-layer ANN system, simplified net work model is achieved to predict wind load for random spatial points. The proposed method is applied to simulate wind load for a long-span structure. The results agree well with the target results, and the proposed method can reduce ANN layers and improve calculating speed and reliability greatly. Thus, the proposed method is verified to be correct and efficient.

Key words: image recognition technique; ANN; wind load simulation; image information; calculation effectiveness