

参数灵敏度分析的神经网络方法及其工程应用

陈太聪, 韩大建*, 苏成

(华南理工大学 土木工程系, 广东 广州 510640)

摘要: 在系统分析中, 参数灵敏度分析不仅为判断各系统参数的重要性大小提供了依据, 量化的灵敏度指标也是后续参数估计的前提。然而, 在多数实际系统中, 系统参数与系统状态间的显式函数关系不易得到, 导致一阶灵敏度指标无法直接求取。简化的单因素分析方法亦存在模型粗糙、精度不高的缺点。本文研究采用人工神经网络的高精度泛化映射, 通过少量样本的训练, 建立复杂系统中多个系统参数与系统状态间的近似映射关系, 继而推导得到统一的灵敏度计算列式。简单结构的神经网络方法和解析方法的对比计算显示了方法的有效性和可靠性。最后, 应用该法对某斜拉桥结构的荷载参数和刚度参数进行了考查, 得到一般性结论。

关键词: 灵敏度分析; 人工神经网络; 斜拉桥; 施工控制
中图分类号: O342; TP183 **文献标识码:** A

1 引言

现实系统中, 系统输出常常受多个参数的共同影响, 在系统模型化的过程中, 无必要也不可能对所有参数都加以考虑, 只需通过对影响程度大的主要参数的数值进行准确地估计, 即可用以建立合理可靠的系统模型。参数灵敏度分析的目的正是计算各系统参数对系统输出的影响因子, 从而对系统参数进行筛选, 所得影响因子亦用于后续参数估计。如今, 参数灵敏度分析在结构损伤识别、模型修正和非确定性分析等方面得到了越来越广泛的应用。

一般地, 系统模型由系统参数和系统输出通过一系列的方程构成。在复杂系统中, 由于系统方程过于复杂, 灵敏度指标(一般取为一阶灵敏度系数, 即系统输出对系统参数的一阶导数^[1])常常无法直接计算得到。常用的简化计算方法是进行单因素分析^[2-4], 即对某一系统参数进行微小摄动, 同时固定其它参数取值, 进行系统计算, 得到相应系统输出, 然后采用差分计算得到灵敏度大小。只有当系统参数数目较少, 其它参数保持对系统输出的不敏感性且变化幅度很小时, 采用单因素分析方法才能得到较为准确的灵敏度指标, 反之, 则会带来较大的误差, 所以常用作定性分析的手段。

神经网络作为人工智能和软计算中的主要技

术手段之一, 在近十年来得到了长足发展, 通过简单的矩阵加、乘计算, 即可实现对复杂非线性系统机制的近似模拟。本文研究通过神经网络对系统模型的数值模拟, 在网络非线性泛化映射的基础上, 推导得到系统输出对系统参数的一阶灵敏度矩阵的统一计算公式, 并应用于斜拉桥施工这一复杂非线性系统的参数灵敏度分析中。

2 参数灵敏度分析的神经网络方法

类似于人脑的作用机制, 神经网络通过有监督的指导进行学习, 所获得的知识成果存储于神经元间的联结之中, 由联结强度(权值)体现。对于后继的具同一内部机制的复杂问题, 该神经网络只需通过权值对神经元的激励即可实现正确响应。

根据神经元和联结的不同排列, 神经网络可以有众多不同的模型。其中, 多层感知器(Multi-Layer Perceptron, 简称MLP)模型是最为常用的网络模型。已有证明^[5](Kolmogorov 多层神经网络映射存在定理), 两层MLP网络可无限逼近任意阶次的非线性映射关系。因此, 结构简单的两层MLP网络被广泛应用于实际分析计算中。典型的两层MLP模型如图1所示。

在两层MLP网络中, 网络输出 o 与网络输入 p 之间的映射关系为

$$in_1 = w_1 p + b_1 \quad out_1 = f_1(in_1) \quad (1)$$

$$in_2 = w_2 out_1 + b_2 \quad o = f_2(in_2) \quad (2)$$

其中 p 为网络结构的输入向量, in_i 为第 i 层神经元的输入向量, w_i 为第 $i-1$ 层与第 i 层神经元间的连

收稿日期: 2003-02-28; 修改稿收到日期: 2003-07-08.

基金项目: 广东省自然科学基金(000387)资助项目.

作者简介: 陈太聪(1977-), 男, 博士生;

韩大建*(1940-), 女, 博士, 教授;

苏成(1968-), 男, 博士, 副教授.

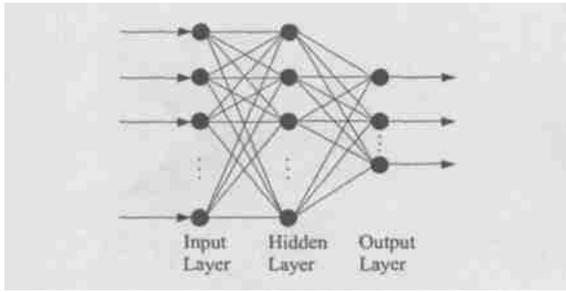


图 1 两层MLP模型
Fig 1 Two-layerMLP model

接权值矩阵, b_i 为第 i 层神经元的偏置向量, f_i 为第 i 层神经元的 Sigmoid 转化函数, out_i 为第 i 层神经元的输出向量, o 为网络结构的输出向量。

网络输出 o 相对于网络输入 p 的灵敏度矩阵可由下式计算得到:

$$\frac{\partial o}{\partial p} = \frac{\partial o}{\partial n_2} \frac{\partial n_2}{\partial out_1} \frac{\partial out_1}{\partial n_1} \frac{\partial n_1}{\partial p} = [f_2(in_2)] \cdot w_2 \cdot [f_1(in_1)] \cdot w_1 \quad (3)$$

一般情况下, 受MLP网络 Sigmoid 转化函数的数值计算范围限制, 在实际应用中, 系统参数向量 x 和系统输出向量 z 不能直接作为网络输入 p 与网络输出 o 进行神经网络映射, 必须预先进行归一化处理。设归一化过程为

$$p = Ax + B, \quad o = Cz + D \quad (4)$$

其中, 常系数矩阵 A, B 和 C, D 分别对应网络输入层和输出层的归一化转化矩阵和偏量矩阵。

结合式(3)和式(4), 可得系统输出向量 z 相对于系统参数向量 x 的灵敏度矩阵为

$$\frac{\partial z}{\partial x} = \frac{\partial z}{\partial o} \frac{\partial o}{\partial p} \frac{\partial p}{\partial x} = C^{-1} \cdot [f_2(in_2)] \cdot w_2 \cdot [f_1(in_1)] \cdot w_1 \cdot A \quad (5)$$

通常情况下, 隐层 Sigmoid 转化函数 f_1 常取为双曲正切函数, 输出层 Sigmoid 转化函数 f_2 常取为线性函数:

$$f_1(y) = \frac{e^y - e^{-y}}{e^y + e^{-y}}, \quad f_2(y) = y \quad (6)$$

相应地, 有

$$[f_1(y)] = 1 - [f_1(y)]^2, \quad [f_2(y)] = 1 \quad (7)$$

则式(5)可具体表达为

$$\frac{\partial z}{\partial x} = C^{-1} \cdot w_2 \cdot \{1 - [f_1(in_1)]^2\} \cdot w_1 \cdot A = C^{-1} \cdot w_2 \cdot \{1 - [f_1(w_1 Cx + w_1 D + b_1)]^2\} \cdot w_1 \cdot A \quad (8)$$

式(8)就是两层MLP网络用以求解系统输出

相对于系统参数的灵敏度矩阵的一般表达式。在MLP网络结构训练完成后, w_1, b_1, w_2 即为常系数矩阵, A, C, D 等归一化矩阵和偏量矩阵也为常系数矩阵, 因此, 灵敏度矩阵 $S = [\partial z / \partial x]$ 由系统参数 x 唯一确定, 且计算形式统一。

如图2所示的悬臂梁结构, 截面惯性矩 $I = 1$, 集中荷载 $P = 10$; 而弹性模量 E 和梁长 L 分别为 $[1, 2]$ 及 $[10, 11]$ 间的不确定数值。现考查梁端挠度 v 相对于弹性模量 E 和梁长 L 的灵敏度指标。

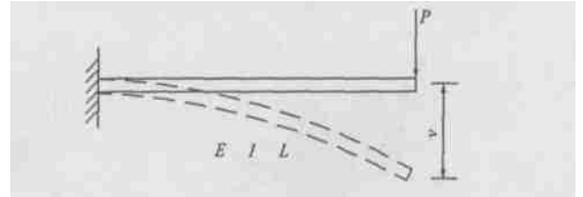


图 2 悬臂梁结构
Fig 2 Cantilever beam structure

梁端挠度 v 的线性解析解及相应于 E 和 L 的灵敏度指标分别为

$$v = \frac{PL^3}{3EI} = \frac{10L^3}{3E}, \quad \frac{\partial v}{\partial E} = -\frac{10L^3}{3E^2}, \quad \frac{\partial v}{\partial L} = \frac{10L^2}{E} \quad (9)$$

取网络结构为 $N_{2 \times 10 \times 1}$, 输入层神经元对应弹性模量 E 及梁长 L , 输出层神经元对应梁端挠度 v 。经 30 组样本训练收敛后, 神经网络计算结果及相对于解析解的误差如图3和表1所示。其中, 总体误差水平指标定义为

$$S_{err} = \sqrt{\sum_{i=1}^N (d_{NN} - d_0)^2} / \sqrt{\sum_{i=1}^N d_0^2} \quad (10)$$

式中 d_{NN} 为神经网络计算结果, d_0 为解析结果, N 为计算点数。

表 1 计算结果的误差特征

Tab. 1 Characteristics of error on solutions			
	v	$\partial v / \partial E$	$\partial v / \partial L$
最大误差	- 0.4764	- 3.9602	- 3.2611
最小误差	0.9564	13.6964	17.0159
平均误差	0.0116	0.6782	1.2064
误差标准差	0.2395	3.1718	4.1225
总体误差水平	0.01%	0.14%	0.53%

由图3和表1可见, 基于神经网络对梁端挠度的高精度模拟输出之上, 由网络结构计算得到的输入-输出灵敏度矩阵相当接近于解析结果, 误差指标令人满意, 显示了神经网络求解参数灵敏度的有效性和可靠性。

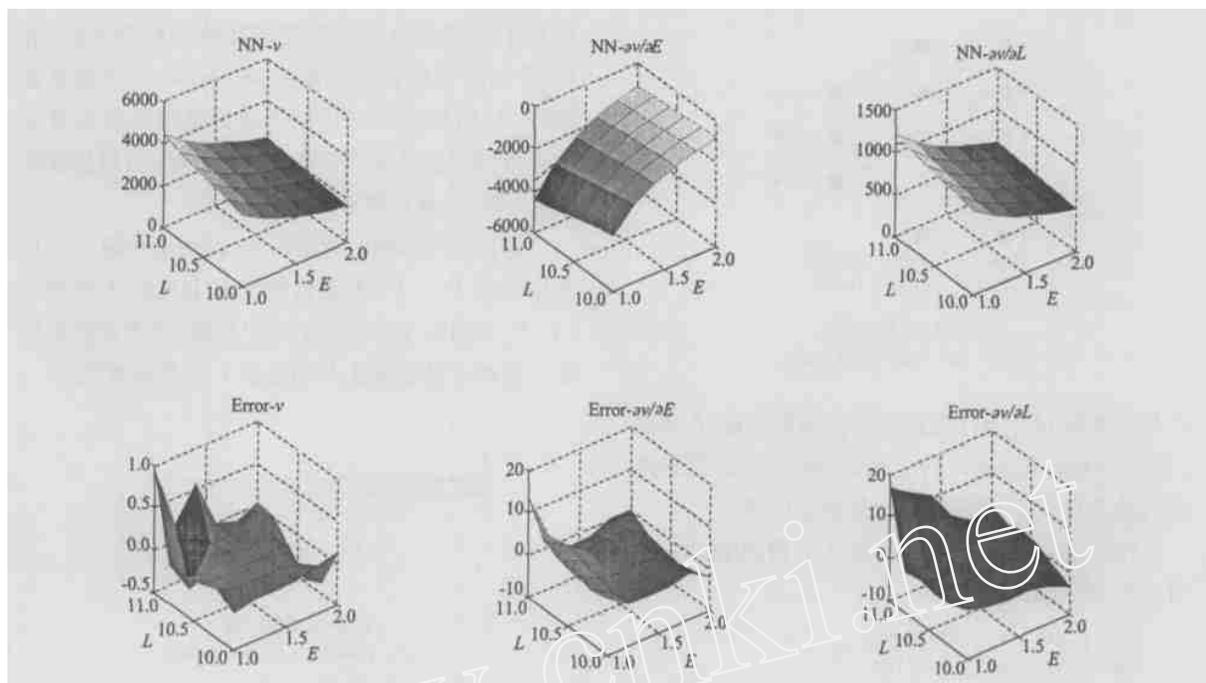


图 3 神经网络的计算结果及相对于解析解的误差
Fig. 3 NN's solution and error to analytical ones

3 斜拉桥施工参数灵敏度分析

崖门大桥是广东省西部沿海高速公路上的一座大型双塔单索面预应力混凝土斜拉桥,主桥全长为 668 m,跨径组合为 50 m + 115 m + 338 m + 115 m + 50 m。大桥主梁采用牵索挂篮悬臂浇筑方法施工。全桥整体结构如图 4 所示。

在用系统模型对斜拉桥的整个施工进度进行描述时,由悬臂施工的特点决定,系统参数(几何参数,刚度参数,荷载参数等)对系统输出状态(全桥合拢阶段的线形和内力状态)的影响通过递进的多个不同结构体系加以实现,系统方程的数目随施工阶段数的增多而增多,同时方程形式也随结构的生长越趋复杂,综合而言,系统参数与系统输出间

无法通过某一显式函数关系直接联系,最终导致系统输出对系统参数的灵敏度指标无法直接求得。如前所述,神经网络以其高精度的泛化映射能力为解决该问题提供了一个有效的手段。

以下就以主梁弹性模量 E 和主梁钢筋混凝土自重 ρ 这两个非确定结构参数为例,考查它们对全程施工至合拢后的全桥索力偏差状态的影响程度。

取全程施工至全桥合拢阶段的索力偏差状态为

$$F(T) = \sum_{i=1}^N \left[\frac{T_i(E, \rho) - \bar{T}_i}{\bar{T}_i} \right]^2 \quad (11)$$

式中 $T_i(E, \rho)$ 对应于实际 E 值和实际 ρ 值的第 i 根斜拉索的索力计算值, \bar{T}_i 则对应于理论值 $E = 3.5 \times 10^4 \text{ kN/m}^2$ 和理论值 $\rho = 2.6 \times 10^{-4} \text{ kN/m}^3$ 的第 i

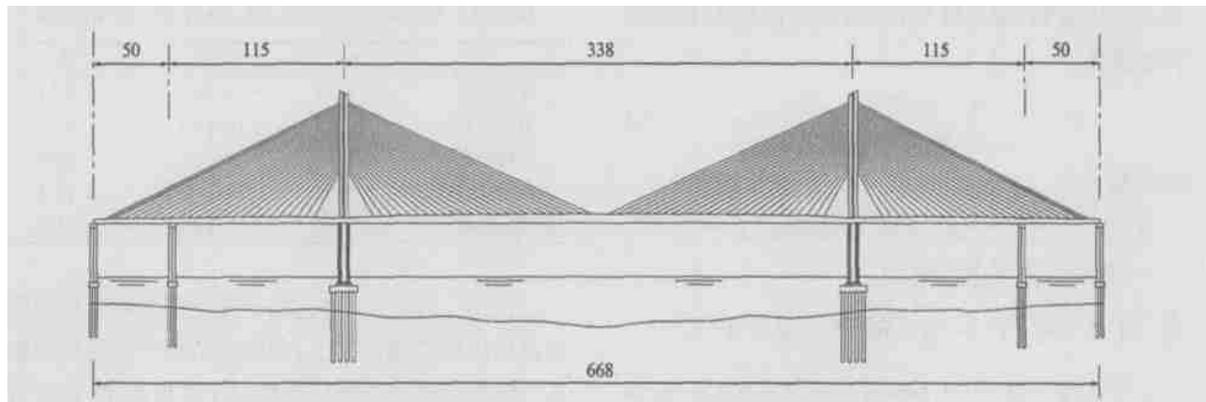


图 4 崖门大桥全桥整体结构(单位: m)
Fig. 4 Yamen cable-stayed bridge (unit: m)

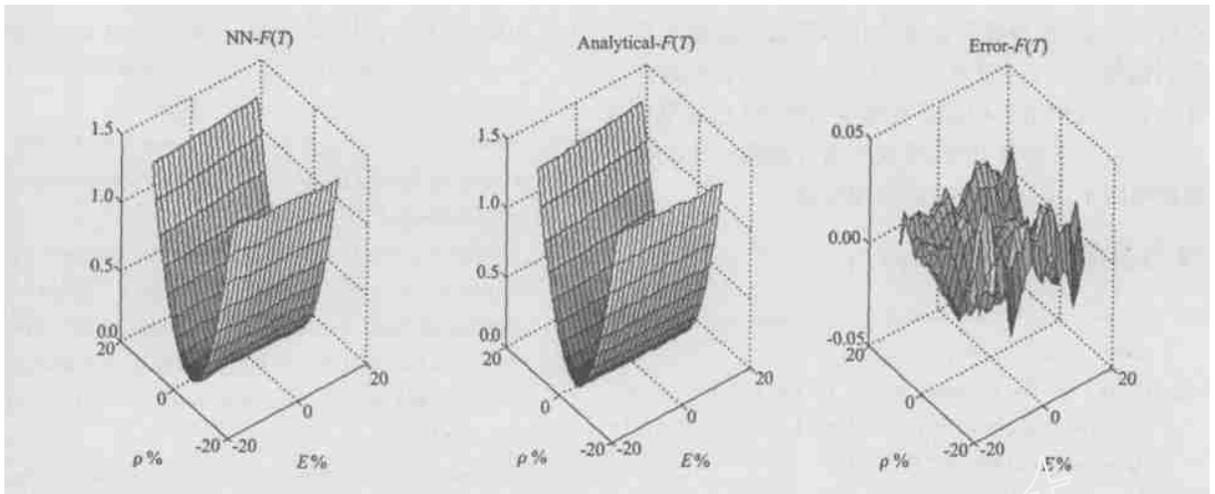


图 5 $F(T)$ 计算结果
Fig 5 Results of $F(T)$

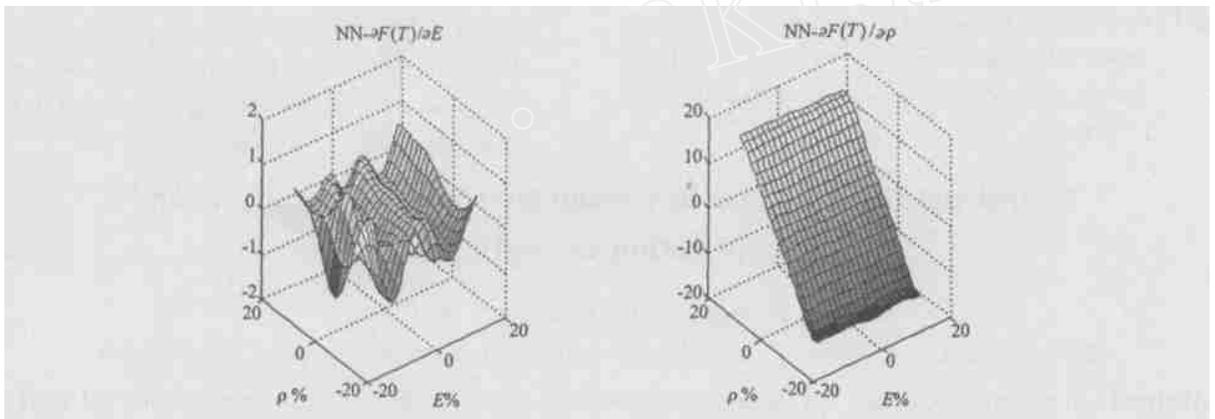


图 6 灵敏度指标的神经网络计算结果
Fig 6 NN's solution of sensitivity indices

根斜拉索的设计索力值, N 为斜拉索根数。

网络结构取为 $N_{2 \times 20 \times 1}$, 两个输入层神经元分别为实际 E 值和 ρ 值, 输出层神经元为索力偏差状态。网络的训练数据通过全过程的施工模拟计算^[6,7] (共 51 个施工阶段) 得到, 计算过程考虑几何和材料非线性的影响, 即大变形效应、 P - 效应、斜拉索刚度效应以及与时间相关的混凝土收缩徐变效应^[8-10]。根据工程实际情况, 假设实际弹性模量 E 和钢筋混凝土自重 ρ 为理论值附近 $[-15\%, 15\%]$ 内的不确定数值。

经 36 组样本训练收敛后, 针对 $21 \times 21 = 441$ 对 (E, ρ) 值进行的网络模拟输出、解析结果及相应误差如图 5 所示, 误差特征如表 2 所示。由图 5 和表 2 可知, 构造的神经网络结构对系统机制的模拟精度令人满意, 将网络参数代入式 (8) 计算得到相应灵敏度指标, 结果如图 6 所示。由图 6 所示灵敏度结果可知, 混凝土自重 ρ 的偏差比主梁弹模 E 的偏差对斜拉桥施工的最终索力状态所造成的扰动更

表 2 $F(T)$ 的误差特征

Tab. 2 Characteristics of error on $F(T)$

	最大误差	最小误差	平均误差	误差标准差	总体误差水平
$F(T)$	0.0215	0.0495	0.0035	0.0112	1.79%

显剧烈, 大部分情况下, 前者影响多达后者的 10 倍, 全面地说明了在斜拉桥施工过程中进行混凝土自重控制的重要性。对于如主梁标高、构件内力等结构状态的计算也得到了类似结论, 限于篇幅, 不再赘述。

4 结 语

基于神经网络结构对复杂非线性机制的泛化映射能力, 本文探讨了它在系统参数灵敏度分析中的可行性, 推导得到两层 MLP 网络计算参数灵敏度指标的实用公式。在经过较少量样本训练得到的网络结构能高精度模拟系统输出的情况下, 用以计算参数灵敏度指标, 公式统一, 且操作简单, 算例结果显示模拟计算的精度令人满意。尤其是对于复杂

非线性系统,在精确灵敏度指标不能通过直接求导得到的情况下,采用该法计算,能得到多个非确定性参数共同作用下的定量灵敏度指标,较之常用于定性分析的单因素分析,更能全面并准确地反映参数影响因子,显示了一定的实用价值。

参考文献(References):

[1] Saltelli A, et al *Sensitivity Analysis*[M] Chichester: Wiley, 2000

[2] Haftka R T, Adelman H M. Recent developments in structural sensitivity analysis [J] *Structural Optimization*, 1989, **1**(2): 137-152

[3] Tong M, et al Numerical modelling for temperature distribution in steel bridges [J] *Computers & Structures*, 2001, **79**(6): 583-593

[4] Brownjohn J M W, Xia P Q. Dynamic assessment of curved cable-stayed bridge by model updating [J] *Journal of Structural Engineering, ASCE*, 2000, **126**(2): 252-260

[5] Hornik K, et al Multilayer feedforward networks are universal approximators[J] *Neural Networks*, 1989, **2**(5): 359-366

[6] Reddy P, et al Simulation of construction of cable-stayed bridges[J] *Journal of Bridge Engineering, ASCE*, 1999, **4**(4): 249-257.

[7] Abraham D M, Halpin D W. Simulation of the construction of cable-stayed bridges [J] *Canadian Journal of Civil Engineering*, 1998, **25**(3): 490-499.

[8] Tang M C. Analysis of cable-stayed girder bridges [J] *Journal of Structural Division, ASCE*, 1971, **97**(5): 1481-1496

[9] Fleming J F. Nonlinear static analysis of cable-stayed bridge structures[J] *Computers & Structures*, 1978, **10**(4): 621-635

[10] Kang Y J, Lee J S. Time-dependent analysis of cable-supported prestressed concrete bridges [A] *Proceedings of the 5th International Conference on Computing in Civil and Building Engineering [C]* ASCE, 1993: 25-32

Neural network method in parameter sensitivity analysis and its application in engineering

Chen Taicong, Han Dajian*, Su Cheng

(Department of Civil Engineering, South China University of Technology, Guangzhou 510640, China)

Abstract: In system modelling, the parametric sensitivity analysis is known to be the fundamental work. By applying the sensitivity analysis, the obtained quantitative sensitivity indices (the first-order derivative of system output over system parameter) can then be used for ranking different parameters, as well as identifying the important ones. In most practical systems, however, the explicit functional relationship between system parameters and system output is too complex to be derived and as a result, the first-order derivative sensitivity indices are unable to be computed. The common-used simplified method, single source analysis by use of the finite difference algorithm, has the disadvantage of low accuracy due to the rough model. In this paper, an artificial neural network method is studied to compute the sensitivity indices. Two-layer perceptron is the most widely used type of artificial neural network owing to the simple structure and the ability of high-accuracy simulating of any order nonlinear function. From the mathematical relationships between output variables and input parameters in the trained two-layer perceptron, the first-order derivative sensitivity indices can then be deduced in exact mathematical terms of both normalized and raw input/output data. By this artificial neural network method, the sensitivity indices of multiple parameters are able to be computed at one time through uniform and simple formula, regardless of the system characteristic, i.e. static or dynamic, one stage or multiple stages. Numerical results on one simple structure are presented to show the efficiency and reliability of the proposed method. Finally, the proposed method is employed in the parameter study of cable-stayed bridge construction practice, and valuable information about the influences of stiffness parameter and load parameter on construction control targets is obtained.

Key words: sensitivity analysis; neural network; cable-stayed bridge; construction control