

离岸混凝土氯离子扩散系数的人工神经网络模型

卢显扬,杨健,刘清风,胡宇

(上海交通大学 船舶海洋与建筑工程学院,上海 200240)

摘要:为研究人工神经网络在离岸混凝土氯离子渗透中的应用,从已有文献中选用653组数据,建立网络结构为13-27-1的模型进行训练、预测。研究结果表明:人工神经网络能有效预测离岸混凝土中的氯离子扩散系数;水灰比,水泥、减水剂、外加剂(粉煤灰、矿渣、硅灰)、骨料的含量以及混凝土的抗压强度、养护机制、试验方法、暴露时间和暴露环境均会对氯离子扩散系数产生影响。

关键词:离岸混凝土;氯离子;扩散系数;人工神经网络

中图分类号:TU528

文献标识码:A

Prediction of chloride diffusion coefficients of offshore concrete structures using artificial neural networks

LU Xian-yang, YANG Jian, LIU Qing-feng, HU Yu

(1. School of Naval Architecture, Ocean & Civil Engineering, Shanghai Jiao Tong University, Shanghai 200240, China)

Abstract: An increasing attention has been directed to applying the artificial neural network (ANN) method in civil engineering. This paper examines the possibility of artificial neural network (ANN) to predict the chloride diffusion coefficient of concrete. A total 653 available sets of data from 13 literatures was used for establishing the network model. The developed ANN model used as many as 13 input variables, including water/cement ratio; the dosage of cement, superplasticizer, fly ash, granulated blast furnace, silica fume, aggregate; compressive strength; curing mechanism; testing method; testing time and environment to achieve one output parameter, referred to as chloride diffusion coefficient. The research results show that ANN is feasible in predicting the chloride diffusion coefficient in offshore concrete structures and the selected input variables are all correlated parameters.

Key words: offshore concrete structures; chloride diffusion coefficient; artificial neural networks

混凝土因其高性价比及耐久性而被广泛应用于基础设施中。然而对于处于离岸环境中的混凝土结构,由于介质的侵蚀,主要是氯离子的腐蚀,不仅会导致结构性能退化,还会产生高额维修费用。氯离子扩散系数表征了混凝土抵抗氯离子侵蚀的能力,研究人员对于定量计算氯离子扩散系数 D 做了大量的研究^[1-3]。然而金伟良^[4]等人的研究结果表明扩散系数 D 的取值受到一系列因素的影响,而这些因素难以在一个实验中全部考虑。人工神经网络具有自学习、自调整且能容忍一定误差的特点,非常适合用于多参数问题的求解。

近年来,人工神经网络在预测混凝土性质的应用上已经取得一定成果^[5-7],然而,目前对于混凝土耐久性,尤其是氯离子渗透的预测研究,仍有很大的提升空间,因为现有研究仅仅选取5~6个参数作为输入变量,并不足以得到一个全面综合的结论。为此,本文选取13个参数(水灰比,水泥、减水剂、粉煤灰、矿渣、硅灰、粗细骨料的含量以及水泥的抗压强度、养护机制、试验方法、暴露时间和试验环境)作为输入变量,氯离子扩散系数作为输出变量,建立人工神经网络。来自13篇文献^[8-20]的653组数据被分为训练组、验证组和测试组,对

收稿日期:2015-11-10

基金项目:国家自然科学基金资助项目(51378303,51508324);上海市“浦江人才计划”(13PJ1405200,15PJ1403800);教育部博士点新教师基金资助项目(20130073120074);上海市教委创新重点项目(14ZZ027)

作者简介:卢显扬(1990-),男,广东佛山人,硕士,主要从事离岸混凝土耐久性研究。

模型进行训练和调整。通过比较预测结果和试验数据来验证模型的有效性。

1 人工神经网络建模

典型的人工神经网络包含一个输入层, n 个隐藏层和一个输出层, 每层均由一定数量的神经元组成。合理的网络结构对于建立有效的网络模型至关重要。Hecht - Nielsen^[21] 已经论证了带一层隐藏层的 BP 网络能够以任意精度模拟所有线性方程, 并且他建议隐藏层的神经元数 n 按 $n = 2N + 1$ 选取, 其中 N 为输入层的神经元数, 即输入变量数。因此本文所建立的 BP 网络为 13 - 27 - 1 的三层神经网络。此外, 要注意的是有的变量是定性指标, 在输入网络前必须将其转化为定量指标。

1.1 混凝土组成成分(8 个变量)

(1) 水灰比

水灰比被广泛认为是与氯离子扩散系数关联最密切的影响参数^[4], 这是因为水灰比和混凝土内部的孔隙率存在正相关关系, 而孔隙率越大意味着混凝土的抗氯离子渗透性能越差, 因而导致氯离子扩散系数较大。

(2) 水泥和减水剂的含量

对于相同的水灰比, 研究人员仍需要具体确定水和水泥用量, 因为越厚的水泥保护层意味着对内部钢筋的保护越好。此外, 减水剂的使用会显著减少用水量, 从而影响混凝土的工作性及耐久性^[22-23]。

(3) 外加剂(粉煤灰、矿渣、硅灰)含量

外加剂(本文指粉煤灰、矿渣和硅灰)的使用能显著影响试件的性能, 特别是能大幅提高混凝土抵抗氯离子渗透的能力^[17, 24-25]。金伟良、Shekarchi^[4, 13] 等人分别定量分析了这些外加剂含量对于氯离子扩散系数的影响并得到具体的表达式。

(4) 粗、细骨料含量

Prince^[26] 等人通过试验论证了骨料的渗透性对于氯离子的渗透有着非常密切的影响。而刘清风^[2] 等人也证实氯离子的扩散随着骨料含量的增加而减弱, 这是因为骨料含量越多, 混凝土内部的扩散通道就会越曲折, 因此氯离子在其中的运输就会受到抑制。

1.2 混凝土抗压强度(1 个变量)

根据 Al - Amoudi^[3] 等人的研究, 混凝土的渗

透性随着抗压强度的增加而降低, 因此抗压强度应作为输入的变量。

1.3 与试验过程相关的参数(4 个变量)

(1) 养护机制

合理的养护对于水泥浆体充分水化是至关重要的, 而水泥的水化程度又关系到混凝土的孔隙率, 得到充分水化的水泥, 其孔隙率较低, 因此渗透性较差。金伟良、Alizdeh^[4, 8] 等人均发现经过较长时间水养护(例如 28 d)的水泥浆体, 其氯离子扩散系数会比较小。

养护机制的定量化公式为: $a + 0.01 \times b$

式中, a 取决于养护方法, $a = 1$ 意味着没有养护或者在干燥空气中养护; $a = 2$ 意味着在潮湿空气中养护; $a = 3$ 意味着水养护; $a = 4$ 意味着在温度为 $(20 \pm 2)^\circ\text{C}$, 相对湿度为 95% 的环境中养护 28 d(也称为标准养护); $a = 5$ 特指文献[24]中的养护机制: 先标准养护 30 d, 然后在干燥空气中养护 90 d。 b 取决于养护时间, 例如 $b = 4$ 代表养护时间为 4 d, $b = 28$ 则意味着养护 28 d。要注意的是, 对于文献[24], b 取值为 0, 这是因为该养护机制包括两段养护时间, 并且已经专门用 $a = 5$ 来表示了。

因此, 假如混凝土试件在水中养护 14 d, 那么该输入值应为“3.14”。

(2) 试验方法

本文所选用的 653 组数据分别由两种试验方法得到: 暴露试验和电导率法。根据具体环境, 暴露试验又能分为现场暴露试验和实验室暴露试验。电导率法, 也叫 NEL 法, 是一种加速试验法, 通过施加外部电场, 驱使氯离子加速通过混凝土试件, 并且运用 Nernst - Einstein 方程来计算扩散系数^[18]:

$$D = \frac{RT\sigma_i}{Z_i^2 F^2 C_i}$$

式中 R 为气体常数 $(8.314 \text{ J/mol} \cdot \text{K})$; T 为绝对温度 (K) ; σ_i 为偏电导 (S/cm) ; F 为法拉第常数 (96500 C/mol) ; Z_i 为离子化合价; C_i 为离子浓度 (mol/cm^3) 。

通过比较可以发现, 由实验室暴露试验所得到的氯离子扩散系数数值往往是最大的, 这是由于在实验室中所创造的试验环境往往比实际暴露环境更恶劣, 氯离子含量更高; 而现场暴露试验所得到的氯离子扩散系数又比电导率法所得到的数值大。因此需要区分试验中所使用的试验方法。试验方法的定量化表示如下: 1 = 现场暴露试验, 2

= 实验室暴露试验,3 = 电导率法。

(3) 暴露时间

随着水化反应的不断进行,混凝土内部的孔隙将不断减小,因此氯离子扩散系数会随着暴露时间的增长而不断降低^[4]。Thomas^[17]等人给出定量描述扩散系数与时间关系的经验公式。要注意的是,对于电导率法,时间的输入值为“0”。

(4) 暴露环境

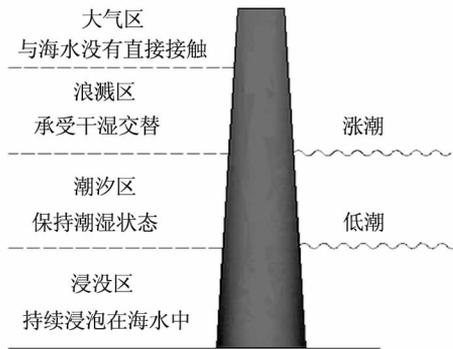


图1 离岸混凝土暴露区域

Fig.1 Different exposure environments of offshore concrete structures

根据与海水的接触关系,结构所处的暴露环境可具体分为大气区、浪溅区、潮汐区和浸没区,如图1所示。干湿交替有利于氯离子渗透与扩散,因此浪溅区往往是破坏最严重的区域;而比起浸没区,潮汐区的混凝土由于能接触空气,因此该区域的氯离子扩散系数一般仅次于浪溅区;而由

于缺乏充足的水分与空气,大气区处的氯离子扩散系数往往是最底的。正因为扩散系数会受到暴露区域的影响,因此在计算时需要分区域考虑。暴露环境的定量化表示如下:0 = 电导率法,1 = 大气区,2 = 浪溅区,3 = 潮汐区,4 = 浸没区。

2 网络训练效果

2.1 相关系数 R 及相对误差

选定1个输入层、1个隐藏层、1个输出层以及13个输入变量、27个隐藏层神经元和1个输出变量的网络结构后,将来自文献中且经过归一化处理的653组数据输入到神经网络中,经过多次训练与学习后得到针对训练样本的输出结果。如前所述,相关系数 R 以及误差能够用来考察一个神经网络的训练效果。图2为本次训练的相关系数 R。从图中可以看到,训练阶段以及总体训练的 R 值分别为 0.992 1 和 0.991 9,表明预测值与目标值非常接近,训练效果非常好;而测试阶段以及验证阶段的 R 值分别为 0.991 2 和 0.992 1,这不仅进一步说明所建立的人工神经网络具有很高的精确性,还说明它具有很强的外推能力,能够基于某个地方的氯离子扩散历史有效预测未来的氯离子扩散情况。

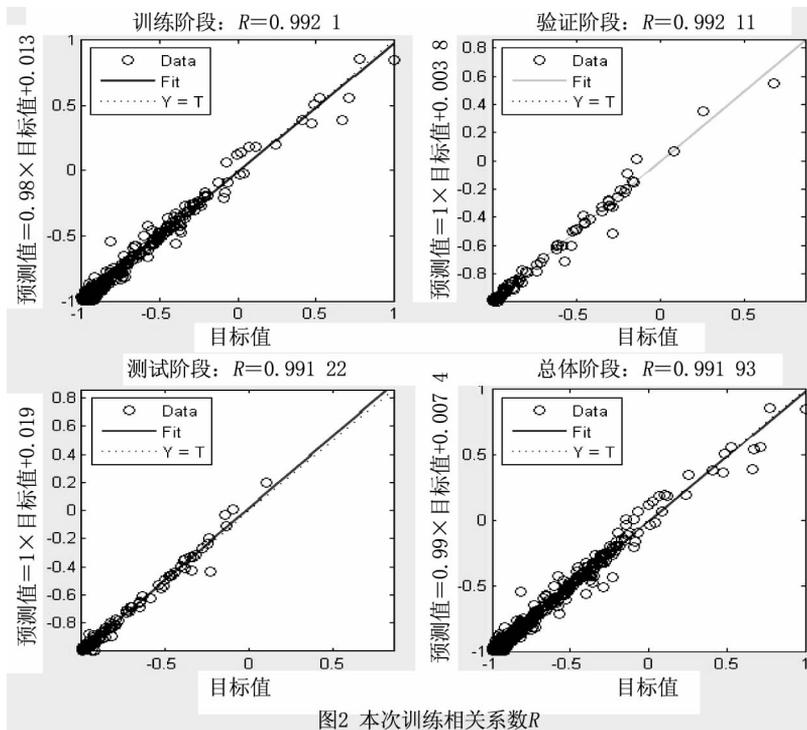


图2 本次训练相关系数R

Fig.2 The root of absolute fraction variance (R) of the ANN model

图3为本次训练的相对误差,图中数字为误差累计出现的频率。由图3可以看到,多达90%的数据其相对误差小于10%,其中82%的数据相对误差甚至小于5%。尽管其中出现相对误差超过50%,甚至超过100%的数据,但这可认为是实验失误所造成的错误或者部分数据超出神经网络调节能力所导致的。因此图3的结果进一步证实了所建立神经网络的精确性。

2.2 对引用文献的预测效果

尽管所建立的神经网络模型具有很高的相关系数以及较小的相对误差,但是仍需要具体考察对于引用文献的预测结果来衡量其有效性。表1和表2分别为本文所建立的人工神经网络对文献[21]和文献[23]的预测结果与对比。由表1可以

看到,对于文献[21]的预测,最大及最小误差分别为4.273%及0.123%,平均误差值仅为1.664%,并且所有“目标值/预测值”的数值均非常接近1,意味着预测值非常接近目标值,因此所建立的神经网络模型能有效的预测文献[21]中的氯离子扩散系数。有意思的是,对于文献[23]的预测似乎并不如对文献[21]的精确。由表2可以看到,最大误差为57%,而平均误差为16.652%,这两项数值均比表1对应数值高。然而表2的预测结果总体上仍然令人满意,因为有40%的数据误差小于10%,同时有70%的数据误差小于25%。对于“目标值/预测值”,除了7个数据之外,其余数据(约占总数据的75%)的数值均位于0.7~1.3之间,意味着预测值仍然非常接近目标值。

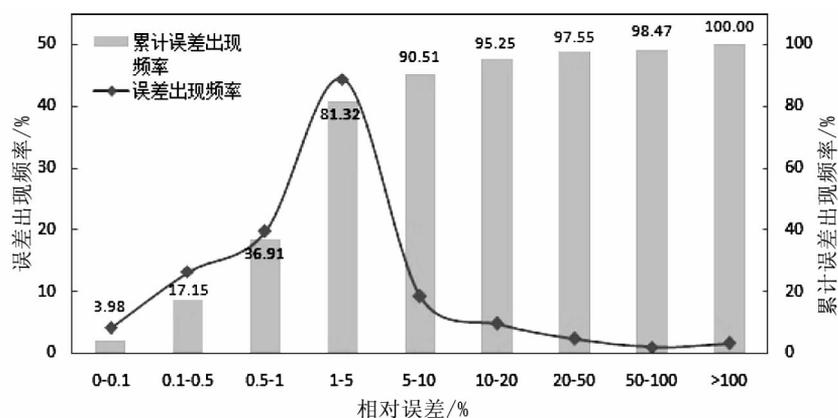


图3 本次训练相对误差

Fig.3 The relative error frequency of the ANN model

表1 对文献[21]的预测效果

Tab.1 Predictions for literature [21] using the established ANN model

序号	目标值 / $10^{-8} \text{ cm}^2 \cdot \text{s}^{-1}$	预测值 / $10^{-8} \text{ cm}^2 \cdot \text{s}^{-1}$	误差 /%	目标值 /预测值	序号	目标值 / $10^{-8} \text{ cm}^2 \cdot \text{s}^{-1}$	预测值 / $10^{-8} \text{ cm}^2 \cdot \text{s}^{-1}$	误差 /%	目标值 /预测值
1	4.978	5.059 341	1.634	0.983 923	9	4.852	5.059 341	4.273	0.959 018
2	4.788	4.750 148	0.791	1.007 969	10	4.725	4.750 148	0.532	0.994 706
3	4.661	4.560 465	2.157	1.022 045	11	4.535	4.560 465	0.562	0.994 416
4	4.535	4.439 95	2.096	1.021 408	12	4.408	4.439 95	0.725	0.992 804
5	4.915	5.059 341	2.937	0.971 47	13	4.883	5.059 341	3.611	0.965 145
6	4.788	4.750 148	0.791	1.007 969	14	4.756	4.750 148	0.123	1.001 232
7	4.63	4.560 465	1.502	1.015 247	15	4.439	4.560 465	2.736	0.973 366
8	4.471	4.439 95	0.694	1.006 993	16	4.376	4.439 95	1.461	0.985 597

表2 对文献[23]的预测效果

Tab. 2 Predictions for literature [23] using the established ANN model

序号	目标值 / $10^{-8} \text{ cm}^2 \cdot \text{s}^{-1}$	预测值 / $10^{-8} \text{ cm}^2 \cdot \text{s}^{-1}$	误差 /%	目标值 /预测值	序号	目标值 / $10^{-8} \text{ cm}^2 \cdot \text{s}^{-1}$	预测值 / $10^{-8} \text{ cm}^2 \cdot \text{s}^{-1}$	误差 /%	目标值 /预测值
1	1.51	1.321 028	12.515	1.143 05	14	1.81	1.406 247	22.307	1.287 114
2	0.61	0.894 018	46.560	0.682 313	15	2.54	1.984 633	21.865	1.279 833
3	0.82	1.234 115	50.502	0.664 444	16	6.55	6.387 083	2.487	1.025 507
4	0.53	0.390 92	26.242	1.355 775	17	10.15	9.343 026	7.950	1.086 372
5	0.75	0.844 788	12.638	0.887 797	18	2.97	2.256 667	24.018	1.316 1
6	2.15	1.543 506	28.209	1.392 932	19	2.79	2.918 798	4.616	0.955 873
7	0.84	1.321 028	57.265	0.635 869	20	1.32	1.431 654	8.459	0.922 011
8	0.81	0.894 018	10.373	0.906 022	21	2.37	2.327 731	1.784	1.018 159
9	0.89	0.844 788	5.080	1.053 519	22	6.83	6.343 992	7.116	1.076 609
10	6.88	9.315 937	35.406	0.738 519	23	13.45	13.773 77	2.407	0.976 494
11	11.7	11.852 62	1.304	0.987 123	24	3.65	3.265 245	10.541	1.117 833
12	2.22	1.431 519	35.517	1.550 8	25	0.8	0.716 055	10.493	1.117 233
13	4.47	2.972 972	33.491	1.503 546	26	3	2.806 338	6.455	1.069 009

出现上述两篇文献预测效果不相同的原因在于人工神经网络本质上是一个模式识别的过程。当输入参数比较复杂时,网络模型就会需要更多的运算时间及步数来调整权值和阈值,从而识别输入参数的模式。对比表1和表2可以发现,针对“目标值/预测值”,表1中的数值最大相差0.602,而表2中的差值最大达到12.84,这意味着文献[21]中的数据比较集中而文献[23]的数据比较离散。因此神经网络能够轻易的识别文献[21]的数据模式从而产生精确的预测,而对文献[23]的预测相对较差。值得注意的是,在表2“目标值/预测值”的前半部分出现了数值的波动,持续在0.63~1.55间跳动,这表明神经网络在经历着模式识别的过程;当识别持续进行并接近完成时,正如表2后半部分数据所示,“目标值/预测值”的波动明显减弱,仅在0.92~1.28间跳动,同时平均误差也大幅减小,意味着预测精度得到提高。

3 结论

1) 人工神经网络能用于预测离岸混凝土的氯离子扩散系数,并且具有足够高的精度。

2) 所选用的输入变量:水泥水灰比,水泥、粉煤灰、GGBS、硅灰、减水剂、粗骨料、细骨料含量,抗压强度,养护机制,试验方法,暴露时间以及暴露环境都会影响氯离子在离岸混凝土中的扩散。

3) 庞大的数据库对于建立有效的人工神经网络至关重要,并且输入变量的性质会影响网络的预测效果。除了本文所选用的13个输入参数,未来的研究还可以补充更多的影响参数,从而提高

该人工神经网络模型的应用前景。

参考文献:

- [1] JONES M R, DHIR R K, GILL J P. Concrete surface treatment: effect of exposure temperature on chloride diffusion resistance[J]. Cement and Concrete Research, 1995, 25(1): 197-208.
- [2] LIU Q F, LI LY, EASTERBROOK D, et al. Multi-phase modeling of ionic transport in concrete when subjected to an externally applied electric field[J]. Engineering Structures, 2012(42): 201-213.
- [3] AL-AMOUDI OSB, AL-KUTTI WA, AHMAD S, et al. Correlation between compressive strength and certain durability indices of plain and blended cement concretes[J]. Cement and Concrete Composites, 2009(31): 672-676.
- [4] 金伟良, 薛文, 陈驹. 海岸及近海混凝土材料耐久性设计指标的影响参数分析[J]. 建筑结构学报, 2011, 32(12): 86-97.
- [5] PALA M, OZBAY E, OZTAS A, et al. Appraisal of long-term effects of fly ash and silica fume on compressive strength of concrete by neural network[J]. Construction and Building Materials, 2007(21): 384-394.
- [6] SARIDEMIR M. Prediction of compressive strength of concrete containing metakaolin and silica fume by artificial neural networks[J]. Advances in Engineering Software, 2009(40): 350-355.
- [7] KHAN MI. Mix proportions for HPC incorporating multi-cementitious composites using artificial neural networks[J]. Construction and Building Materials, 2012(28): 14-20.
- [8] ALIZADEH R, GHODS P, CHINI M, et al. Effect of curing conditions on the service life design of RC structures in the Persian Gulf Region[J]. Journal of Materials in Civil

- Engineering, 2008(20): 2-8.
- [9] 左江波. 基于人工神经网络的粉煤灰混凝土氯离子扩散系数预测[D]. 衡阳: 南华大学, 2012.
- [10] 李红辉. 大掺量粉煤灰高性能混凝土研究[D]. 北京: 北京建筑工程学院, 2007.
- [11] 曹文涛, 余红发, 胡蝶, 等. 粉煤灰和矿渣对表观氯离子扩散系数的影响[J]. 武汉理工大学学报, 2008, 30(1): 48-51.
- [12] COSTA A, APPLETON J. Chloride penetration into concrete in marine environment - part 1: main parameters affecting chloride penetration [J]. Materials and Structures, 1999(32): 252-259.
- [13] SHEKARCHI M, RAFIEE A, LAYSSI H. Long-term chloride diffusion in silica fume concrete in harsh marine climates [J]. Cement and Concrete Composites, 2009(31): 769-775.
- [14] MUSTAFA MA, YUSOF KM. Atmospheric chloride penetration into concrete in semi-tropical marine environment [J]. Cement and Concrete Research, 1994, 24(4): 661-670.
- [15] 元成方, 牛荻涛. 海洋大气环境下粉煤灰混凝土耐久性研究[J]. 硅酸盐通报, 2012, 31(1): 1-6.
- [16] GHODS P, CHINI M, ALIZADEH R, et al. The effect of different exposure conditions on the chloride diffusion into concrete in the Persian Gulf Region [C]// Banthia N, et al. Proceedings of the ConMAT Conference. Vancouver, Canada: University of British Columbia, 2005.
- [17] THOMAS MDA, BAMFORTH P B. Modeling chloride diffusion in concrete: Effect of fly ash and slag [J]. Cement and Concrete Research, 1999(29): 487-495.
- [18] LENG FG, FENG NQ, LU X Y. An experimental study on the properties of resistance to diffusion of chloride ions of fly ash and blast furnace slag concrete [J]. Cement and Concrete Research, 2000(30): 989-992.
- [19] 薛文, 金伟良, 横田弘. 养护条件与暴露环境对氯离子传输的耦合作用[J]. 浙江大学学报: 工学版, 2011, 45(8): 1416-1422.
- [20] 金立兵. 多重环境时间相似理论及其在沿海混凝土结构耐久性中的应用[D]. 杭州: 浙江大学, 2008.
- [21] HECHT - NIELSEN R. Theory of the back-propagation neural network [J]. International Joint Conference on Neural Network, IJCNN, 1989, 1(1): 593-605.
- [22] MORIN V, TENOUDJI FC, FEYLESSOUFI A, et al. Superplasticizer effects on setting and structuration mechanisms of ultra high-performance concrete [J]. Cement and Concrete Research, 2001(31): 63-71.
- [23] MASAHIRO O, MAKOTO H, HAJIME O. Effect of superplasticizer on self-compactability of fresh concrete [J]. Journal of the Transportation Research Board, 1997, 1574(1): 37-40.
- [24] KAYALI O, ZHU B. Corrosion performance of medium-strength and silica fume high-strength reinforced concrete in a chloride solution [J]. Cement and Concrete Composites, 2005(27): 117-124.
- [25] FARAHANI A, TAGHADDOS H, SHEKARCHI M. Prediction of long-term chloride diffusion in silica fume concrete in a marine environment [J]. Cement and Concrete Composites, 2015(59): 10-17.
- [26] PRINCE WF, JONES MR, TING SC, et al. Effect of aggregate porosity on chloride ingress into concrete [A]. Dhir RK, Newlands MD, Paine KA (eds). Role of Concrete in Sustainable Development. London: Thomas Telford Publishing, 2003: 287-297.

(责任编辑 王利君)

(上接第4页)

- of Wind Engineering and Industrial Aerodynamics, 1993, 48(2-3): 221-239.
- [5] LI Q S, YANG K, WONG C K, et al. The effect of amplitude-dependent damping on wind-induced vibrations of a super tall building [J]. Journal of Wind Engineering and Industrial Aerodynamics, 2003, 91: 1175-1198.
- [6] LI Q S, XIAO Y Q, WONG C K, et al. Field measurements of typhoon effects on a super tall building [J]. Engineering Structure, 2004, 26: 233-244.
- [7] TAMURA Y, SUGANUMA S. Evaluation of amplitude-dependent damping and natural frequency of building during strong wind [J]. Journal of Wind Engineering and Industrial Aerodynamics, 1996, 59: 115-130.
- [8] OKADA K, NAKAMURA Y, SHIBA K, et al. Forced vibration tests of ORC200 symbol tower, part 1 test methods and results [J]. Summaries of Technical Papers of the An-

nual Meeting of Architectural Institute of Japan. 1993, Structures 1: 875-876. (in Japanese)

- [9] TOSHIHIDE K, KOYAMA S, OKAWA I. Strong Motion Records in Buildings from the 2011 off the Pacific coast of Tohoku Earthquake, Building Research Data No. 135 [R]. Building Research Institute, 2012. (in Japanese)
- [10] HUANG N E, SHEN Z, LONG S R, WU M C, SHIH H H, ZHENG Q, YEN N C, TUNG C C, Liu H H. The Empirical mode decomposition and the Hilbert spectrum for nonlinear and nonstationary time series analysis [J]. Proceedings of the Royal Society A, 1998, 454: 903-995.
- [11] COLE H A. On-line failure detection and damping measurement of aerospace structure by random decrement signature [M]. Washington: National Aeronautics and Space Administration, 1973.

(责任编辑 李军)