

基于解耦子波和优化神经网络的大坝变形预测

曹茂森^{1,2}, 任青文¹, 毛伟兵²

(1. 河海大学 土木工程学院, 江苏 南京 210098; 2. 山东农业大学 水利土木工程学院, 山东 泰安 271018)

摘要: 针对提高神经网络对大坝变形的预测能力, 在对 Murtagh 提出的、小波与神经网络相结合的、用于复杂时间序列预测的“三阶段”策略进行改进的基础上, 发展了一个解耦子波和优化神经网络优势联合的预测模型。首先, 利用冗余 Haar 小波变换的拟小波包特性提出了基于能量谱主峰重构的动力解耦空间构建技术, 并将其替代“三阶段”策略中的第 1 阶段, 从而为神经网络的应用创建了良好的平台; 再者, 利用最优脑外科医生进行网络结构修剪, 建立了神经网络自身优化的“优化-时新窗”技术, 并将其替代“三阶段”策略中的第 2 阶段, 从而优化了神经网络的内部环境。改进后的模型增强了对复杂动力系统的适应和处理能力。在大坝变形预测应用中, 多个评价指标说明, 该模型的性能比“三阶段”策略有显著提高。

关键词: 水利工程; 动力解耦; 神经网络优化; 预测模型; 冗余 Haar 小波变换; 最优脑外科医生技术

中图分类号: TV 64

文献标识码: A

文章编号: 1000-6915(2005)10-1751-07

NEW PREDICTION MODEL FOR DAM DEFORMATION BASED ON DECOUPLED WAVELET AND OPTIMAL NEURAL NETWORKS

CAO Mao-sen^{1,2}, REN Qing-wen¹, MAO Wei-bing²

(1. College of Civil Engineering, Hohai University, Nanjing 210098, China;

2. College of Hydraulic and Civil Engineering, Shandong Agriculture University, Tai'an 271018, China)

Abstract: The three-stage strategy, proposed by Murtagh, for complicated time series prediction with wavelet and neural networks is improved. Based on the improved strategy, a new prediction model of decoupled wavelet and optimal neural network is proposed to increase the ability of neural networks for dam deformation prediction. Firstly, a new space reconstruction technique based on the main peak reconstruction of energy spectrum of original data is developed using the quasi-wavelet-packet property of redundant Haar wavelet; and then, it is used to substitute for the first stage of the three-stage strategy to built a better neural networks operating platform. Secondly, the optimal-refreshing window technique for neural network self-optimization is developed by using the optimal brain surgeon technique to prune the networks coefficients, and the inner condition of the neural network is optimized by substituting it for the second stage of the three-stage strategy. The adaptability and the analyzing ability of the newly reformed model are increased for the prediction of complicated dynamic system. It is proved by many evaluating indices such as relative mean square error, cross-relation, normal mean square error and direction symmetry in a case of predicting dam deformation that its function is significantly improved as compared with that of the three-stage strategy.

Key words: hydraulic engineering; uncoupled dynamic space; neural network optimization; prediction model; redundant Haar wavelet transform; optimal brain surgeon technique

收稿日期: 2004-01-12; **修回日期:** 2004-04-02

基金项目: 国家自然科学基金资助项目(50379005); 水利部科技创新基金资助项目(SCX2000-56)

作者简介: 曹茂森(1971-), 男, 博士, 1997年毕业于河海大学建筑结构工程专业, 现任副教授, 主要从事土木工程健康诊断与安全性评价方面的教学与研究工作。E-mail: cmszhy@sohu.com。

1 引言

大坝观测数据反映了结构在环境和荷载作用下产生效应量的动态演化。采用合理的方法对其进行分析，可以对坝体结构的运行性态做出评价并可对未来状况做出预测。大坝观测数据的内在动力机制受多个因素影响，实际上是多个子动力源的耦合，比较明确的子动力源有水位、温度等。其主要动力特征表现为子动力源之间的叠加和飘移，并呈现出一定的混沌性质^[1]。这给常用的统计分析方法带来了一定的困难。目前，神经网络在时间序列建模中得到广泛应用，但其成功应用的一个先决条件是系统的动力机制具有相对的一致性^[2]。面对对象大坝观测数据这样的复杂系统，常用的神经网络方法常表现出一定的局限性。小波分析具有自适应地将信号进行多尺度分解的能力，可以对一个复杂动力系统实施“解耦”。解耦后的子系统为神经网络的应用创造了良好的外部平台。Murtagh 较早地提出了小波解耦特性与神经网络相结合进行时间序列预测的基本思想^[3]。在此基础上，多个学者从不同领域验证了该方法的有效性，尤其是对于复杂动力系统的预测，其比传统的 BP, RBF 等神经网络方法有明显优势^[4-7]。同时，BP 神经网络自身也存在一些不确定因素，如网络隐层结点数的选取、训练方案的设计等。将这些因素最佳化来优化神经网络的内部环境，从而有效地提高网络自身性能，已成为神经网络领域的一个研究热点。采用 GA 算法、Bayes 理论和 OBS(optimal brain surgeon)技术进行网络优化^[8-11]是比较新颖而有效的方法，其中的 OBS 技术理论上更直观且易实施。本文针对提高神经网络对大坝变形的预测能力，探讨了基于 OBS 技术的神经网络内部环境优化技术和基于冗余 Haar 小波变换的神经网络外部平台构建技术。在此基础上，对 Murtagh 提出的小波与神经网络相结合的“三阶段”策略^[3]进行了改进，发展了一个基于解耦子波和优化神经网络的预测模型。在大坝变形预测的实际应用中，该模型表现出了明显的优势。

2 冗余 Haar 小波变换

在小波与神经网络相结合进行时间序列预测的

“三阶段”策略中，最常用的小波变换方法是 *à trous* 算法^[12]。它的平移不变特征使子波与原始序列在时间上具有一致性，且能够保持某些暂态现象的完整性。这两个特征对于预测是非常重要的^[4]。该算法描述如下：

假设采样序列 $\{c_0(k)\}$ 是 k 时间点上函数 $f(x)$ 与尺度函数 $\phi(x)$ 的数量积：

$$c_0(k) = \langle f(x), \phi(x-k) \rangle \tag{1}$$

$\phi(x)$ 相应于低通滤波器，且满足二进方程：

$$\frac{1}{2} \phi\left(\frac{x}{2}\right) = \sum_l h(l) \phi(x-l) \tag{2}$$

式中： h 为由 $\phi(x)$ 确定的一系列离散低通滤波器。由此可以得到，尺度 i 上

$$c_i(k) = \sum_l h(l) c_{i-1}(k + 2^{i-1}l) \tag{3}$$

两相邻尺度差为

$$w_i(k) = c_{i-1}(k) - c_i(k) \tag{4}$$

则集合 $W = \{w_1, w_2, \dots, w_p, c_p\}$ 为初始采样序列 $\{c_0\}$ 直到分辨率 p 的小波变换，其中 $w_i (i \in N, i < p)$ 为细节信号， c_p 为背景信号。

c_0 的小波分解表示为

$$c_0(t) = c_p(t) + \sum_{i=1}^p w_i(t) \tag{5}$$

此方程即 *à trous* 算法的重构公式。

à trous 算法中的低通滤波器 h 一般采用三阶 B 样条。近来 Murtagh 指出了三阶 B 样条用于时变数据流预测的一些不足，主要是在末端实施内积时须用到未知信息。同时指出采用 Haar 小波，与之相应的滤波器为 (0.5, 0.5)，可避免此不足。采用该小波的 *à trous* 算法称为冗余 Haar 小波变换：

$$c_j(k) = \frac{1}{2} (c_{j-1}(k) + c_{j-1}(k - 2^j)) \tag{6}$$

$$w_j(k) = c_j(k) - c_{j-1}(k) \tag{7}$$

在 Murtagh 新近发表的文^[3, 4]中，采用冗余 Haar 小波变换与神经网络相结合的“三阶段”策略，在多个领域时间序列的预测应用中，收到良好效果。

3 神经网络优化

神经网络自身优化的技术核心是网络结构的优化和训练策略的改进。近期，在研究方面出现了 GA

算法、Bayes 理论和 OBS 等神经网络自身优化技术^[8-11], 其中 OBS 技术更易于理解和程序实现。这里采用 OBS 技术进行网络结构修剪, 并基于其发展了“优化-时新窗”学习策略。

3.1 OBS 技术

神经网络由默记(memorization), 达到泛化(generalization)的网络结构优化技术已逐渐得到关注。其中较有效且容易实施的是 Hassibi 和 Stork 提出的, 基于误差函数所有二阶微分的最优脑外科医生 OBS 网络结构修剪技术^[11]。该方法描述如下:

误差函数的泰勒级数展开式表示为

$$\delta E = \left(\frac{\partial E}{\partial W} \right)^T \delta W + \frac{1}{2} \delta W^T H \delta W + O(\|\delta W\|^3) \quad (8)$$

式中: E 为误差函数, W 为网络系数空间, $H = \partial^2 E / \partial W^2$ 为 Hessian 矩阵。

当网络训练至 E 达到极小值时, 式(8)中的第 1, 3 项可忽略, 剩余第 2 项。OBS 技术的基本思路是:

(1) 根据原始序列先验知识, 设计一个初步网络结构, 并训练至允许误差精度;

(2) 寻找系数 q , 它满足条件: 将其置 0, 即相应结点连接被剪断, E 的增加最小, 即

$$\min_q \left\{ \min_{\delta W} \left(\frac{1}{2} \delta W^T H \delta W \right) \right\} \quad (9)$$

(3) 将与 q 相应的 E 的增加与预先设定的阈值 F 比较, 若小于 F , 则将系数 q 删去, 并随之更新剩余系数空间;

(4) 重复(2), (3)步, 直至无系数满足删去条件, 即得到修剪后的网络结构。该技术的关键是计算 H^{-1} 。

该方法优于 MB(magnitude based)和 OBD(optimal brain damage)方法的地方, 在于其利用了误差函数的所有二阶微分^[11], 有效地提高了精度和准确性; 并在每次系数删去后随之更新剩余系数空间, 使泛化能力逐步提高且避免了网络的重新训练。但该方法引入了一个阈值 F , 它直接决定了网络的最终修剪结构, 因此其合理取值是关键的。

3.2 “优化-时新窗”学习策略

基于 OBS 技术, 发展了“优化-时新窗”神经网络学习策略, 其示意图如图 1。该策略在学习过程中, 不但进行网络结构的优化, 而且实施动力机制的时新, 从而使网络达到最佳性能。该策略采用传统的 BP 学习方法, 在 Norgaard 发展的 NNSYSID 系统辅助下得到了良好的程序化实现。基本步骤如下:




图 1 优化-时新窗学习策略

Fig.1 Study strategy of optimal-refreshing window

(1) 集合划分: 将原始序列 H 划分成集合 Y 和 $C(Y \gg C)$, 如图 1 所示。其中 C 含有最新状态采样点, 称为优化-时新窗。

(2) 初步网络模型确立: 根据先验知识确定输入层、输出层结点数, 并初步确定隐层结点数^[13]。初步网络模型对集合 Y 进行学习, 提取序列的基本动力机制。

(3) 网络结构优化: 将 OBS 技术中的阈值 F 设为较大值(保证步骤(2)中所得网络模型的系数均可以被执行删去操作)。发挥优化-时新窗 C 的“优化”作用, 将集合 C 作为验证集来指导最优网络结构的确定。每次系数删去且更新剩余系数空间后, 随之用集合 C 检测此时网络结构的泛化能力。这里, 式(8)中的误差函数是对 C 的泛化检验误差。整个修剪过程产生出一条关于网络结构与泛化能力的动态变化曲线, 其中较稳定的低泛化误差值相应的网络结构即为最优网络结构。

(4) 动力机制时新: 将集合 H 作为学习集送入最优网络模型进行学习。由于 OBS 的系数更新功能, 此时实质上是步骤(3)中与验证集 C 有关的样本转化为学习集, 因此简单易行。此操作发挥了优化-时新窗 C 的“时新”作用, 使步骤(3)优化后的网络模型突出学习了新知识, 更新了动力机制, 为预测作准备。

(5) 预测: 用步骤(4)中得到的网络模型对未来信息进行预测。

该策略中优化-时新窗 C 的作用是至关重要的, 它不但从实际出发解决了 OBS 技术中阈值 F 的设立问题, 客观确定了最优网络结构; 而且作为最新学习材料使最优网络模型时新了动力机制, 达到最佳预测状态。优化-时新窗 C 的重要作用决定了其维数是一个重要参量。 C 的维数对基本动力机制的捕获和“优化”、“时新”作用的发挥有着直接影响, 从某种程度上决定了整个网络性能。从理论

上分析, C 的维数与输入维数具有性质上的一致性, 但确定输入维数的方法较多且结果并不完全一致。笔者从大量试验中认为, 将 C 的维数取为关联维数法^[14]、HA 指数法^[15]和 ARD 法^[10]分别确定的输入维数的平均值是比较理想的。

4 基于解耦子波和优化神经网络的预测模型

Murtagh 提出的小波变换与神经网络的结合技术可归纳为“三阶段”策略: (1) 小波变换将原始序列分解为多尺度子波序列; (2) 每个尺度子波独立实施神经网络预测; (3) 叠加单尺度子波预测值, 得到原始序列预测结果。小波所起的作用是将复杂任务分解为相对简单的子任务, 用子任务为神经网络的应用创造良好平台。该方法的思路是开创性的, 但其没有更多地注重有关技术细节。比如神经网络与小波分解中存在的一些不确定因素, 这些不确定因素对网络性能有着一定的影响, 对这些因素进行优化将是进一步提高网络性能的潜力源。这里用神经网络自身优化、动力解耦空间构建技术来对这些不确定因素进行优化, 并将两者有机地植入“三阶段”策略, 构成一个性能得到显著提高的预测框架——基于解耦子波和优化神经网络的预测模型。

4.1 神经网络自身优化

“三阶段”策略中没有考虑向神经网络内部“挖潜”, 以提高网络性能。节 3 中已详述了神经网络自身优化的方法。用神经网络的优化和预测替换“三阶段”策略的第 2 阶段会有效地提高模型预测能力。

4.2 动力解耦空间构建

小波分解的目的是将原始动力系统“解耦”, 得到由若干个简单子系统构成的动力解耦空间, 而实际操作中小波分解的几个不确定因素影响了解耦的实施。首先, 分解层数难以准确确定。如果分解层数过少, 子系统依然具有较高复杂性, 起不到“解耦”的作用; 分解层数过多, 元素之间应有的联系被打断, 子系统形不成一个有机体系; 再者, 按 *à trous* 算法的尺度二进性进行分解, 有可能将一个相对完整的子系统打破。这些因素都直接影响预测效果, 但应用中对其重视不够, 相关解决对策论述更少。本文对冗余 Haar 小波变换和系统动力特征进行了深入分析, 提出了基于拟小波包特性和重构能量谱主峰的动力解耦空间构建方法, 用以对这些不确定因素实施最佳化。

拟小波包特性: 冗余 Haar 小波变换的基本操作是上一层序列被分解为高、低频两个子序列, 且两子序列叠加可以重构上一层序列。因此冗余 Haar 小波变换具有“分频子波可加性递归重构”的特性。对该特性进行推广:

$$c_0 = w_1 + w_2 + \dots + w_p + c_p = w_1 + (w_{21} + w_{22}) + \dots + (w_{p1} + c_{p2}) + c_p \quad (10)$$

将 w_2 视为一独立序列, 可被二次分解为 w_{21}, w_{22} ; 同样, w_p 可被二次分解为 w_{p1}, w_{p2} 。此关系对于更深层次也成立, 这样原始序列便有多个分解形式。其高频可分性及原始序列的多种重构表示在一定程度上与小波包相类似。这里称冗余 Haar 小波变换的这种性质为拟小波包特性。

重构能量谱主峰: 能量谱表征了动力系统的动力特征, 其中主峰分布标明了系统的基本动力结构且每个主峰代表一个相对完整的动力子系统。小波分解应使动力解耦空间与原系统保持能量谱的一致性, 以保证动力特征在小波分解前后保持一致性。这是由重构能量谱主峰进行动力解耦空间构建的指导思想。

具体实施方法: 首先对原始序列进行能量谱分析并按式(10)对原始序列执行层数比较多的小波分解; 然后对所有子波进行能量谱分析并由邻近子波能量谱组合重构原始序列能量谱主峰; 最后将相关子波进行叠加, 形成次生子波, 每个次生子波代表一个动力子系统, 而次生子波序列构成动力解耦空间。

动力解耦空间较好地克服了小波分解中的不确定因素, 使之更好地与分析对象相适应。用其替换“三阶段”策略的第 1 阶段会为神经网络应用提供优良的外部平台, 从而会提高预测能力。

4.3 “三阶段”策略的改进

对“三阶段”策略进行神经网络自身优化和动力解耦空间构建改进后, 得到基于解耦子波和优化神经网络的预测模型, 其基本框架如图 2 所示。该模型内、外部优势的“强强联合”, 预期会提高模型性能。




图 2 “三阶段”改进策略

Fig.2 Mended three-stage strategy

5 实例分析及性能评价

5.1 实例分析

某混凝土拱坝高 90 m，坝顶弧长 247 m，坝顶厚 20 m。从坝顶测点 3 的水平位移观测资料中，截取某一含有 500 个数据点的区段作为分析对象并记为集合 A ，其过程线如图 3。将集合 A 划分为 H (前 460 个数据点)、 T (后 40 个数据点)两个子集。基于解耦子波和优化神经网络的预测模型通过对历史数据 H 的学习，对未来变形进行预测。将预测结果与实测值 T 进行比较，从而对模型性能进行评价。




图 3 集合 A 过程线

Fig.3 Process line of set A

为了在子系统层面上进行不同网络模型的性能评价，对 T 进行与 H 同步的操作，得到与动力解耦空间相对应的测试空间。实际操作中，为了避免端效应，动力解耦空间和测试空间在 A 的基础上实现：首先对 A 实施小波分解及重构能量谱主峰操作，再划分为两个空间。基于拟小波包特性和重构能量谱主峰，构建 H 的动力解耦空间如图 4 所示。

由 ARD 法确定输入维数并由关联维法、HA 法和 ARD 法分别确定的输入维数的平均值作为优化-时新窗 C 的维数，结果见表 1。

每个子系统独立进行神经网络优化与预测。例如子系统(b)优化前、后的神经网络结构如图 5, 6 所示。图中实、虚线直观地反映了大于、小于零的系数的分布状况。经过优化，网络系数由最初的 36 个(30 个连接系数和 6 个偏差)减少为 17 个(14 个连接系数和 3 个偏差)，减少了 52%，这将有效地提高网络的泛化能力。进一步将集合 H 送优化后的神经网络模型进行学习，使其动力机制得到时新，达到最佳预测状态。

各个子系统的优化神经网络预测结果见图 7(a) ~ (d)。将各个子系统预测结果进行叠加，得到原始序

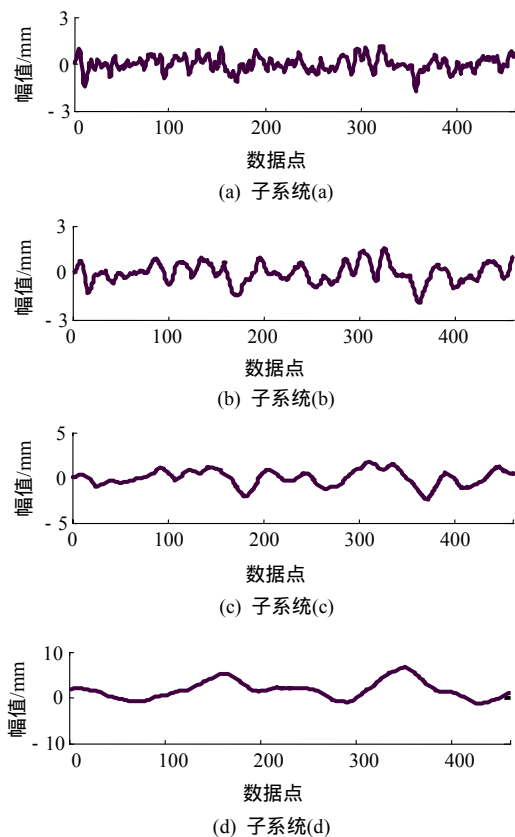


图 4 H 的动力解耦空间

Fig.4 Decoupled dynamic space of set H

表 1 输入维数和 C 的维数

Table 1 Dimensions of input and C

子系统	(a)	(b)	(c)	(d)
输入维数	3	5	9	13
优化-时新窗 C 维数	5	6	11	13




图 5 初步确立的网络结构

Fig.5 Preparatory neural network structure




图 6 优化后网络结构

Fig.6 Optimal neural network structure

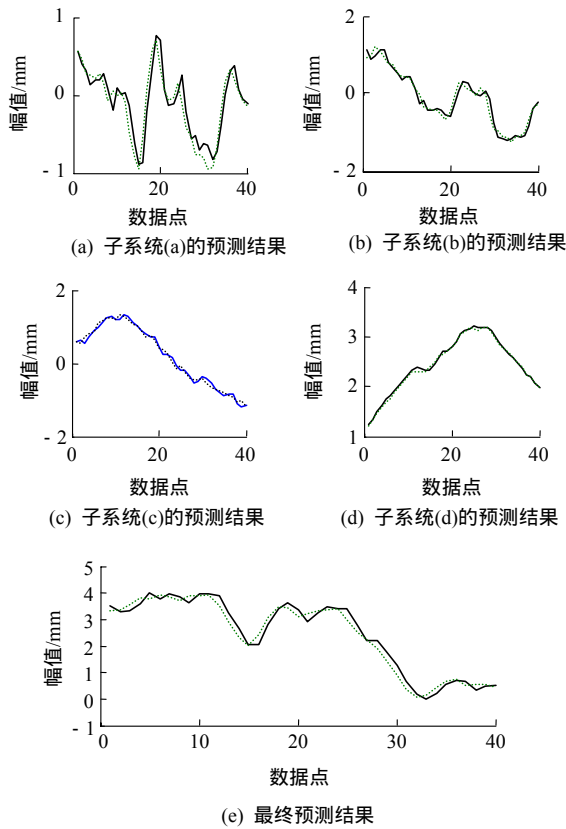


图7 大坝变形的一步预测

Fig.7 One-step predictions of dam deformation

列的最终预测结果，见图 7(e)。图中实线为一步预测值，虚线为实测值，即集合 T 。

5.2 性能评价

对人工神经网络模型性能进行评判的准则很多。为了达到全面、客观地对文中所提方法给予评价，选用相对均方误差(relative mean square error, RMSE)、(cross-relation, CR)、标准均方误差(normal mean square error, NMSE)、方向对称性(direction symmetry, DS)等 4 种度量指标^[6, 16]，从不同角度对网络性能进行标度：

$$RMSE = \lg \left| \frac{\sum_{k=1}^N [y(k) - \hat{y}(k)]^2}{\sum_{k=1}^N y(k)^2} \right| \quad (11)$$

CR =

$$\sqrt{1 - \frac{\sum_{k=1}^N [y(k) - \hat{y}(k)]^2}{\sum_{k=1}^N [y(k) - \frac{1}{N} \sum_{k=1}^N y(k)]^2}} \quad (12)$$

$$NMSE = \frac{1}{N\sigma^2} \sum_{k=1}^N [y(k) - \hat{y}(k)]^2 \quad (13)$$

式中： σ^2 为相应于预测集的实测集 T 中数据点的方差。

$$DS = \frac{1}{N} \sum_{k=1}^N H(y(k) * \hat{y}(k)) \quad (14)$$

DS 即正确预测目标值方向的次数与预测样本容量的比率。

为了评价基于解耦子波和优化神经网络的预测模型的性能，将“三阶段”策略作为水平 ；用动力解耦空间代替“三阶段”策略中的第 1 阶段得到水平 ；进一步用优化神经网络替换“三阶段”策略中的第 2 阶段得到水平 。对不同水平上的模型性能进行上述多指标测度，在指标对比中，进行网络性能评价。具体结果见表 2。

表 2 模型性能评价

Table 2 Performance assessment of models

模型水平	系统	RMSE	CR	NMSE	DS
“三阶段”策略(I)	整体	- 4.893 7	0.971 2	0.023 10	0.945 0
	子系统(a)	- 1.977 6	0.962 5	0.014 90	0.850 0
	子系统(b)	- 3.593 8	0.972 5	0.009 40	0.950 0
	子系统(c)	- 5.041 0	0.977 3	0.003 20	0.991 0
	子系统(d)	- 8.587 8	0.989 6	0.000 68	1.000 0
动力解耦空间替换 (I)中第 1 阶段(II)	整体	- 5.014 9	0.983 6	0.011 40	0.967 5
	子系统(a)	- 1.991 2	0.962 9	0.014 10	0.850 0
	子系统(b)	- 3.647 2	0.974 2	0.008 60	0.965 0
	子系统(c)	- 5.042 1	0.979 4	0.003 20	0.991 0
	子系统(d)	- 8.588 1	0.990 1	0.000 66	1.000 0
优化神经网络替换 (II)中第 2 阶段()	整体	- 5.162 1	0.987 7	0.010 10	0.975 0

比较水平 ， 可以看出，水平 中动力解耦空间提供的动力特性相对一致、具有有机完整性的子系统，为神经网络应用提供了比水平 更优良的外部平台。该平台使子系统预测能力得到增强，从而有效地提高了整个网络的预测能力；比较水平 ， 可以看出，水平 中神经网络自身优化的实施，改进了网络性能，使得每个子系统的独立预测能力进一步增强，从而使整个网络的预测能力得到显著提高。因此，在实际大坝变形这一复杂动力系统的预测应用中，基于解耦子波和优化神经网络预测模型的可行性、有效性得到证明。

6 结 论

本文利用 OBS 技术，发展了“优化-时新窗”

神经网络优方法,从而使神经网络自身的内部环境得以优化;并利用冗余 Haar 小波变换,发展了基于拟小波包特性和重构能量谱主峰的动力解耦空间构建方法,从而为神经网络的应用创造了优良外部平台。在此基础上,通过对 Murtagh 提出的小波与神经网络“三阶段”策略进行了改进,提出了预测能力得到有效提高的基于解耦子波和优化神经网络的预测模型。在大坝变形预测中,通过多指标、多层次对模型性能进行评价,说明文中所提出模型比“三阶段”策略有明显优势,具有自己的特色。

参考文献(References):

- [1] 汪树玉, 刘国华, 杜王盖, 等. 大坝观测数据中的混沌现象[J]. 水利学报, 1999, (7): 22-26. (Wang Shuyu, Liu Guohua, Du Wanggai, et al. Chaotic phenomenon in observation data of dam monitoring[J]. Journal of Hydraulic Engineering, 1999, (7): 22-26. (in Chinese))
- [2] Müller K R, Kohlmorgen J, Plawelzik K. Analysis of switching dynamics with computing neural networks[R]. Tokyo: Univ. Tokyo, 1997.
- [3] Aussem A, Murtagh F. Combining neural networks forecasts on wavelet-transformed time series[J]. Connection Science, 1997, 9(1): 113-121.
- [4] Aussem A, Campbell, Murtagh F. Wavelet-based feature extraction and decomposition strategies for financial forecasting[J]. J. Computational Intelligence in Finance, 1998, 6(2): 5-12.
- [5] Zhang B L, Coggins R, Jabri M A, et al. Multiresolution forecasting for futures trading using wavelet decompositions[J]. IEEE Transactions on Neural Networks, 2001, 12(4): 765-775.
- [6] 李贤彬, 丁晶, 李后强. 基于子波变换序列的人工神经网络组合预测[J]. 水利学报, 1999, (2): 1-6. (Li Xianbin, Ding Jing, Li Houqiang. The combination forecasting using artificial neural network based on wavelet transformed sequences[J]. Journal of Hydraulic Engineering, 1999, (2): 1-6. (in Chinese))
- [7] Soltani S, Boichu D, Simard P, et al. The long-term memory prediction by multiscale decomposition[J]. Signal Processing, 2000, 80(10): 2195-2205.
- [8] 杨晓红, 刘乐善. 用遗传算法优化神经网络结构[J]. 计算机应用与软件, 1997, 14(3): 59-65. (Yang Xiaohong, Liu Leshan. Optimization of neural networks by genetic algorithm[J]. Computer Application and Software, 1997, 14(3): 59-65. (in Chinese))
- [9] 郭晓婷, 朱岩. 基于遗传算法的进化神经网络[J]. 清华大学学报(自然科学版), 2000, 40(10): 116-119. (Guo Xiaoting, Zhu Yan. Evolutionary neural networks based on genetic algorithms[J]. Journal of Tsinghua University(Science and Technology), 2000, 40(10): 116-119. (in Chinese))
- [10] Penny W D, Roberts S J. Bayesian neural networks for classification: how useful is the evidence framework? [J]. Neural Networks, 1999, 12(6): 877-892.
- [11] Hassibi B, Stork D G. Second-order derivatives for network pruning: optimal brain surgeon[A]. In: Advances in Neural Information Processing Systems 5[C]. [s. l.]: Morgan Kaufmann, 1993. 164-171.
- [12] Shensa M J. Discrete wavelet transforms: wedding the à trous and Mallat algorithms[J]. IEEE Transactions on Signal Processing, 1992, 40(10): 2464-2482.
- [13] Jenkins M. Approximate analysis of structural grillages using a neural network[J]. Proc. Inst. Civ. Eng. Struct. Build., 1997, 122: 335-363.
- [14] Zhang Sheng, Liu Hongxing, Gao Duntang, et al. Determining the input dimension of a neural network for nonlinear time series prediction[J]. Chinese Phys., 2003, 12(6): 594-598.
- [15] He X, Asada H. A new method for identifying orders of input-output models for nonlinear dynamic systems[A]. In: Proc. American Control Conf.[C]. San Francisco: [s. n.], 1993. 2520-2523.
- [16] 陈哲, 冯天谨, 张海燕. 基于小波神经网络的混沌时间序列分析与相空间重构[J]. 计算机研究与发展, 2001, 38(5): 591-596. (Chen Zhe, Feng Tianjin, Zhang Haiyan. Chaotic time series analysis and phase space reconstruction based on wavelet neural networks[J]. Journal of Computer Research and Development, 2001, 38(5): 591-596. (in Chinese))