

基于神经网络简单集成的湖库富营养化综合评价模型

邓大鹏¹, 刘 刚², 李学德¹, 花日茂¹, 汤 锋¹

(1. 安徽农业大学资源与环境学院, 合肥 230036 2. 安徽省巢湖市环境保护监测站, 巢湖 238000)

摘要 根据中国水利部推荐的地表水富营养化控制标准,以叶绿素 a、总磷、总氮、化学需氧量和透明度为评价指标,采用线性插值方法生成均匀分布的训练样本,建立了用于湖泊、水库富营养化综合评价的神经网络简单集成模型,其个体网络采用反向传播网络。通过递增法分别确定个体网络隐含层节点数为 3,集成规模为 40。所有个体网络均采用弹性反传训练算法和带动量的梯度下降学习算法。将该模型应用于巢湖富营养化综合评价,结果表明该模型有效消除了单个反向传播神经网络对初始网络权重的敏感性,泛化能力得到显著的提高。该模型的评价结果与综合营养状态指数法差异极显著,而与插值评分法差异不显著,但相关性较高,相关系数分别为 0.9406 和 0.8891。通过对比分析,表明该模型较好地归纳了评价标准中的潜在评价规则,评价结果客观、可靠。

关键词 富营养化, 综合评价, BP (back propagation) 神经网络, 神经网络集成, 泛化能力

文章编号: 1000-0933 (2007) 02-0725-07 中图分类号: Q178, X171 文献标识码: A

A model based on simple ensemble of neural networks for comprehensive eutrophication assessment of lake and reservoir

DENG Da-Peng¹, LIU Gang², LI Xue-De¹, HUA Ri-Mao¹, TANG Feng¹

1 School of Resource and Environmental Science, Anhui Agricultural University, Hefei 23036, China

2 Chaohu Environmental Monitoring Station, Chaohu 238000, China

Acta Ecologica Sinica 2007 27 (2) 0725 ~ 0731.

Abstract :Based on Surface Water Eutrophication Control Standard recommended by Ministry of Water Resources of China , a simple neural network ensemble (NNE) model was constructed for comprehensive eutrophication assessment of lake and reservoir. This model adopted Chlorophyll a , Total Phosphorus , Total Nitrogen , Chemical Oxygen Demand and Secchi Depth as inputs , and the output is a continuous variable , which represents the trophic state. 1000 input/output pairs were produced with linear interpolation method according to the above standard. 100 pairs were selected randomly from all data pairs as testing sample , and the rest used as training sample. Back propagation (BP) neural network with same topology structure were applied to all subnets of this ensemble model and were trained using resilient back propagation and gradient descent with momentum as the learning algorithm. The number of hidden nodes of subnet and number of subnets of ensemble are 3 and 40 respectively , determined with the incremental method. All subnets were trained with different initial weights and bias. The results of using this model to assess the trophic state of Chaohu Lake , showed that this model is insensitive to initial weights , and the generalization ability is improved remarkably. With respect to assessment results , there is no apparent difference between this model and the interpolation scoring method , but there is significant difference

基金项目 安徽省高等学校青年教师科研资助计划资助项目 (2005jq1058)
收稿日期 2005-12-08 ; 修订日期 2006-06-09
作者简介 邓大鹏 (1974 ~) ,男,安徽怀宁人,硕士,主要从事人工智能在环境科学中的应用研究. E-mail : rexdeng@163. com

Foundation item :The project was supported by Science Research Sponsoring Plan for Young Teachers in College and University of Anhui Province (No. 2005jq1058)

Received date 2005-12-08 ; **Accepted date** 2006-06-09

Biography :DENG Da-Peng , Master , mainly engaged in application of artificial intelligence in environmental science ; E-mail : rexdeng@163. com

between this model and the comprehensive trophic level index method. The correlation coefficients of assessment results gained by this model and those by the comprehensive trophic level index method and the interpolation scoring method are 0.9406 and 0.8891, respectively. The results of contrast analysis indicate this model has learned the potential assessment rules from assessment standard, and assessment results of this model are objective and reliable.

Key Words: eutrophication; comprehensive assessment; back propagation (BP) neural network; neural network ensemble (NNE); generalization ability

水环境富营养化严重威胁到渔业生产、饮用水质量以及生态安全等诸多方面。因此,通过科学可靠的综合评价方法,及时、准确地掌握水环境尤其是湖泊、水库的富营养化状态,对环境污染控制与治理、环境规划和管理等工作极为重要。本质上,包括富营养化在内的环境质量综合评价问题,都是从 m 个评价指标输入空间到 n 个质量等级输出空间的非线性映射问题。因此,以处理非线性映射问题而著称的人工神经网络 (artificial neural network, ANN) 技术,在环境质量评价中获得较为广泛的应用^[1]。

我国学者在水环境富营养化评价方面,应用 ANN 技术相继建立了一些综合评价模型。在太湖富营养化评价中,任黎等提出了 8 级营养状态分级标准,采用叶绿素 a (chlorophyll a, Chla)、透明度 (secchi depth, SD)、总磷 (total phosphorus, TP)、总氮 (total nitrogen, TN) 和化学需氧量 (chemical oxygen demand, COD_{Mn}) 作为评价指标,利用 8 个分级标准界值数据作为训练样本,建立了用于太湖富营养化评价的 5-5-1 结构的 BP (back propagation) 网络模型^[2];韩涛等以 Chla、TP、TN、COD_{Mn} 和生物量为评价指标,根据 6 级营养状态分级标准,随机插值生成足够多数据作为训练样本,建立了结构为 5-8-6、输出为二进制的 BP 网络模型^[3];吴利斌等设立了 5 级营养状态分级标准,以 Chla、SD、TP、TN 和 COD_{Mn} 作为评价指标,通过线性插值生成足够多均匀分布的数据作为训练样本,建立了一个模糊神经网络模型^[4];曾光明等在对洞庭湖富营养化评价中,采用 TP、TN 和 COD_{Mn} 作为评价指标,将营养状态分为 5 级,利用 100 组国内主要湖泊历史监测数据和对应营养状态评价结果作为训练样本,建立了一个小波神经网络模型^[5]。楼文高分析了 2001 年以前报道的 ANN 富营养化评价模型在训练样本构造、隐含层数及其节点数设置、网络输出类型、测试样本设立等方面存在的问题;并以 Chla、TP、TN、COD_{Mn} 和生物量为评价指标,根据 6 级分级标准,采用随机插值方法生成足够多训练样本,同时设立测试样本,建立了一个 5-3-1 结构的 BP 网络,实际应用表明具有较高的泛化能力^[6]。

上述报道的神经网络评价模型,采用了不同的分级标准和评价指标,与我国目前广泛使用的分级标准和评价指标存在差异,模型的评价结果缺乏可比性,模型实用性和通用性差。仅采用分级标准界值作为训练样本,数据太少导致样本缺乏代表性,使神经网络根本不可能学习得到分级标准中的评价规则;而采用历史监测数据和相应评价结果作为训练样本,得到的神经网络模型只是对相应传统评价方法的模拟;采用随机插值方法得到的训练样本,其代表性颇受质疑。此外,在已报道的绝大多数 BP 网络模型中,隐含层节点数设置太多,不仅增大模型复杂度,而且易导致网络对训练样本的过拟合 (Over Fitting)。BP 网络对初始权重非常敏感,从不同的初始权重训练会得到不同的网络模型,严重影响网络评价结果的稳定性。多数文献没有说明如何解决 BP 网络对初始权重的敏感性,个别文献采用了固定初始权重的方法。除个别文献^[6]以外,其他的 BP 网络模型均未设立测试本来检验模型的泛化能力。神经网络的泛化能力是指经过学习或训练后的神经网络对测试样本或工作样本作出正确反应的能力。泛化能力是神经网络设计和训练过程中最受重视的问题,因为没有泛化能力的网络没有任何使用价值。

神经网络集成 (neural network ensemble, NNE) 是一种可以显著提高泛化能力的工程化神经计算技术,并已经成为机器学习和神经计算领域的研究热点。一个广泛被接受的 NNE 定义是:“NNE 是用有限个神经网络对同一个问题进行学习,集成在某输入示例下的输出由构成集成的各神经网络在该示例下的输出共同决定”^[7]。当 NNE 用于模式分类时,其输出通常由个体网络的输出通过绝对多数投票法或相对多数投票法产

生 ;当 NNE 用于回归估计时 ,其输出通常由个体网络的输出通过简单平均或加权平均产生。一般而言 ,采用加权平均可以得到比简单平均更好的泛化能力 ,但在神经网络集成的规模较大时 ,适于使用简单平均^[7-8]。

NNE 能提高泛化能力的原因 ,目前的解释包括两个方面 :一是由于 NNE 中个体网络在学习陷入不同的局部极小 ,各局部极小的负作用相互抵消 ,从而减小泛化误差 ;二是 NNE 可以消除初始权重对学习系统复杂性的影响 ,降低了整个学习系统的复杂性 ,从而提高 NNE 的泛化能力^[8]。

在上述研究的基础上 ,利用 MathWorks 公司开发的 MATLAB 软件 ,通过以下途径建立具有良好泛化能力、稳定性、通用性和实用性的湖泊、水库富营养化 NNE 综合评价模型 : (1) 根据我国目前广泛使用的富营养化评价标准 ,采用线性插值方法构造均匀分布训练样本 ,提高训练样本对评价标准的代表性 ,并设立测试样本 ; (2) 根据测试误差和训练误差的变化趋势 ,通过递增法确定最佳的网络隐含层节点数和 NNE 的规模 ; (3) 同时训练多个结构相同但初始权重不同的 BP 个体网络来构建 NNE 评价模型。

1 NNE 模型的建立

1.1 评价指标、评价标准的确定

中国环境监测总站于 2001 年底推荐以 Chla、TP、TN、COD_{Mn}、和 SD 为评价指标 ,采用 0 ~ 100 之间的连续分值对湖库营养状态进行分级 ,以综合营养状态指数法 (comprehensive trophic level index method ,下简称 TLI 法) 评价。该方法中各评价指标的权重是根据历史数据计算得到的^[9]。

中国水利部在全国水资源调查评价中采用了相同的营养状态分级标准 ,并给出了具体的各指标分级区间 (表 1) ,并采用评分法 (scoring method ,插值评分或就高不就低评分 ,本文采用插值评分 ,下简称为 SCO 法) 。该方法采用等权加和计算营养状态分值 ,没有考虑到各评价指标对营养状态的不同贡献^[10]。

以表 1 作为湖泊、水库的富营养化评价标准 ,并据此建立足够数量的训练样本 ,用于 NNE 模型的训练。

表 1 地表水富营养化控制标准
Table 1 Control standard for eutrophication of surface water

营养状态 Trophic state	评分值 Score	叶绿素 a Chla (mg·m ⁻³)	总磷 TP (mg·L ⁻¹³)	总氮 TN (mg·L ⁻¹)	化学需氧量 COD _{Mn} (mg·L ⁻¹)	透明度 SD (m)
贫营养 Oligotropher	10	0.5	0.001	0.02	0.15	10.00
	20	1.0	0.004	0.05	0.40	5.00
	30	2.0	0.010	0.10	1.00	3.00
中营养 Mesotropher	40	4.0	0.025	0.30	2.00	1.50
	50	10.0	0.050	0.50	4.00	1.00
	60	26.0	0.100	1.00	8.00	0.50
富营养 Eutropher	70	64.0	0.200	2.00	10.00	0.40
	80	160.0	0.600	6.00	25.00	0.30
	90	400.0	0.900	9.00	40.00	0.20
	100	1000.0	1.300	16.00	60.00	0.12

1.2 训练样本、测试样本的建立及工作样本

在表 1 所列各指标的各分级区间内均匀插值生成 100 个样本 ,共计 1000 个样本 ,然后从每个区间的样本中随机抽取 10 个共计 100 个样本作为测试样本 ,余下 900 个样本作为训练样本。对训练样本的输出数据添加服从均值为 0、标准差为 0.1 的正态随机噪声。添加较小的随机噪声可以防止训练样本过于平滑 ,同时也是提高泛化能力的一种有效方法 ,这等价于 ANN 结构设计中的正则化方法^[11]。

所有样本利用 MATLAB 中用 premnmx 函数进行预处理 ,即利用最大、最小值将所有数据压缩至 [-1 , +1] 区间内 ,输出结果利用 postmnmx 函数解压缩^[12]。

工作样本为巢湖东半湖 2004 年全年 12 个月的监测数据 (表 2) ,并给出 TLI 和 SCO 方法的评价结果。

1.3 个体 BP (back propagation) 神经网络的设置

1.3.1 网络训练误差和测试误差的计算

训练误差 (也称网络误差或网络性能) ,用来衡量网络对训练样本的拟合精度。本模型中其计算函数采

用 mse (mean squared error 均方误差)。网络测试误差用测试样本误差的均方差表示,即也采用 mse 函数计算。

表 2 2004 年度巢湖东半湖营养状态监测数据

Table 2 Monitored data for trophic indicators of east Chaohu Lake in 2004							
月份 Month	叶绿素 a Chla (mg·m ⁻³)	总磷 TP (mg·L ⁻¹)	总氮 TN (mg·L ⁻¹)	化学需氧量 COD _{Mn} (mg·L ⁻¹)	透明度 SD (m)	TLI 值 TLI score	插值评分值 Interpolation Score
1	6.54	0.127	1.284	3.34	0.35	53.25	58.29
2	9.40	0.039	1.358	4.72	0.45	51.66	55.00
3	8.22	0.082	1.320	5.03	0.38	54.36	58.24
4	5.91	0.086	0.450	6.00	0.45	50.55	53.58
5	6.13	0.123	2.220	7.96	0.30	59.41	63.26
6	7.84	0.137	1.470	4.66	0.45	55.14	58.29
7	8.26	0.019	1.090	4.00	0.40	48.03	52.80
8	8.79	0.064	1.660	4.15	0.40	53.38	57.55
9	7.29	0.088	0.840	4.00	0.30	52.58	57.98
10	5.93	0.050	0.660	3.81	0.30	49.29	55.09
11	4.69	0.086	0.550	1.63	0.40	44.55	51.13
12	3.51	0.075	0.520	3.45	0.35	47.26	53.04

1.3.2 拓扑结构的确定

个体 BP 网络采用 3 层前馈神经网络结构,即输入层、一个隐含层和输出层。湖泊富营养化状态的评价指标有 5 个,评价结果为 1 个 0~100 之间(预处理后应为-1~1 之间)的评分值(连续型变量),因此模型的输入节点为 5,输出节点为 1。隐含层节点数根据网络结构最精简的原则,利用递增法确定最佳的隐含层节点数:即建立隐含层节点数从 1 开始的 BP 网络,每种结构的网络重复训练 50 次,但每次均采用不同的随机连接权重初始化,观察网络的平均测试误差、训练误差随隐含层节点数增加的变化趋势,确定最佳隐含层节点数。

1.3.3 激励函数和训练参数的确定

网络隐含层激励函数采用 tansig 函数,输出层激励函数采用 purelin 函数。
个体 BP 网络的训练算法采用弹性反向传播算法。在 MATLAB 中该训练算法通过调用 trainrp 函数实现。连接权重和阈值的学习采用带动量的梯度下降学习算法,在 MATLAB 中通过调用 learnngdm 函数实现。其中动量常数采用默认值 0.6,学习速率采用默认值 0.01。

1.3.4 网络训练的停止准则

通常结束网络训练是根据目标训练误差,或测试样本误差不再下降,或者最大训练次数,或者以上停止准则的结合。实际上,目标训练误差的设置往往依靠主观经验,如果设置太小,可能导致过拟合,或者网络根本无法达到,设置太大,网络尚未收敛就结束训练,同样导致泛化能力低。采用测试样本误差不再下降(即早期停止法,early stopping)作为停止准则来防止过训练,要求训练算法不能收敛太快,而且有时其效果不佳。为了确保网络收敛时才结束训练,只设置最大训练次数作为唯一停止准则。根据预试验的观察,网络训练到 300~500 次后网络训练误差下降极其缓慢,甚至不再下降,因此确定最大训练次数为 1000 次。

1.4 NNE 模型的设置

NNE 规模(即个体网络的个数),太大将需要更多的计算时间,太小则不能发挥 NNE 的作用。因此,采取递增法来确定最佳的 NNE 规模,即从 5 开始,以 5 为步长逐步扩大 NNE 规模,每个规模的 NNE 分别训练 10 次,根据 NNE 测试误差和平均误差随其规模递增的变化趋势来选择适宜的规模。NNE 的输出为所有个体网络输出的简单平均。

为了进行比较,建立了一个同 NNE 个体网络完全相同的单个 BP 网络模型(single back propagation,简称 SBP),并采用与 NNE 完全相同的训练样本和测试样本。

2 结果与分析

2.1 隐含层节点数和 NNE 规模的确定

网络的平均测试误差、训练误差随隐含层节点数增加的变化趋势见图 1。当隐含层节点数增加到 3 以后,网络测试误差和训练误差下降不再明显。因此,具有 3 个隐含层节点数的网络结构是最精简的。

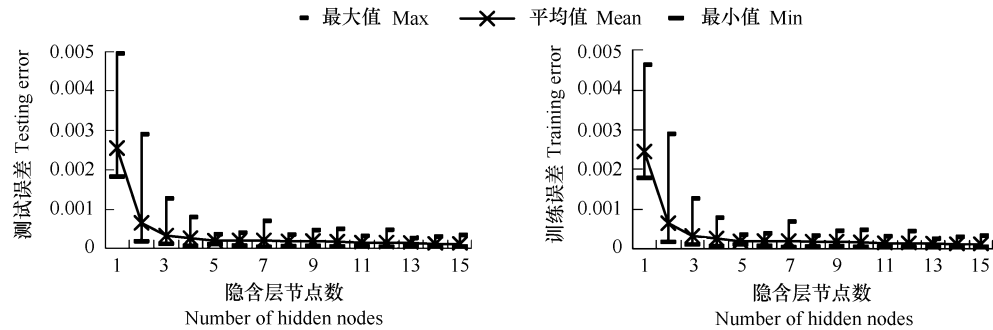


图 1 神经网络测试误差、训练误差随隐含层节点数的变化
Fig. 1 Changes of testing and training error as hidden nodes increasing

确定隐含层节点后,进行 NNE 规模递增试验,结果见图 2。NNE 平均测试误差和训练误差随其规模的递增,不断波动,规模大于 35 以上,测试误差和训练误差的变动相对稳定。规模为 40 的 NNE,其最大测试误差和最大训练误差最小,同时平均测试误差仅次于规模为 65 的 NNE。因此确定 NNE 规模为 40。

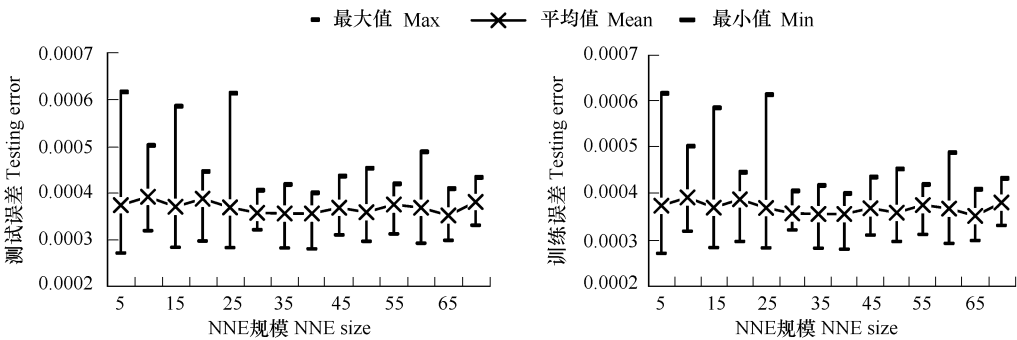


图 2 NNE 泛化误差随 NNE 规模增加的变化趋势
Fig. 2 Changes of NNE testing and training error as NNE size increasing

2.2 NNE 与 SBP 模型的比较

根据以上参数设置,利用 MATLAB 神经网络工具箱建立 NNE 和 SBP 模型。分别在不同随机数字发生器状态下运行 NNE、SBP 模型各 10 次,两种模型对工作样本评价结果的平均值及变异度见表 3。

表 3 NNE 和 SBP 模型对工作样本评价结果的变异指标

项目 Item		月份 Month											
		1	2	3	4	5	6	7	8	9	10	11	12
NNE	平均值 Mean	54.78	54.68	56.48	56.64	62.71	56.63	53.04	54.94	54.94	53.55	49.87	52.93
	标准差 Standard deviation	0.402	0.384	0.272	0.254	0.553	0.379	0.329	0.501	0.191	0.157	0.401	0.226
	变异系数 (%) Variation coefficient	0.733	0.702	0.482	0.448	0.882	0.669	0.620	0.912	0.347	0.293	0.804	0.427
SBP	平均值 Mean	55.59	56.07	57.41	55.83	64.53	57.45	54.25	56.76	55.14	53.77	50.00	52.76
	标准差 Standard deviation	2.688	2.803	1.943	1.416	2.502	2.416	2.900	3.483	1.325	1.567	1.908	1.095
	变异系数 (%) Variation coefficient	4.835	5.000	3.384	2.536	3.877	4.206	5.346	6.137	2.404	2.915	3.816	2.075

显然,NNE 模型对 12 个工作样本 10 次评价结果的标准差和变异系数都很小,而且均显著小于 SBP 模型。图 3 则更直观地显示了 NNE 评价结果的稳定性。这说明采用 NNE 方法建立的神经网络评价模型,非常有效地消除了单个 BP 网络受初始权重的影响而导致输出结果的不稳定性,从而具有良好的鲁棒性和泛化能力。

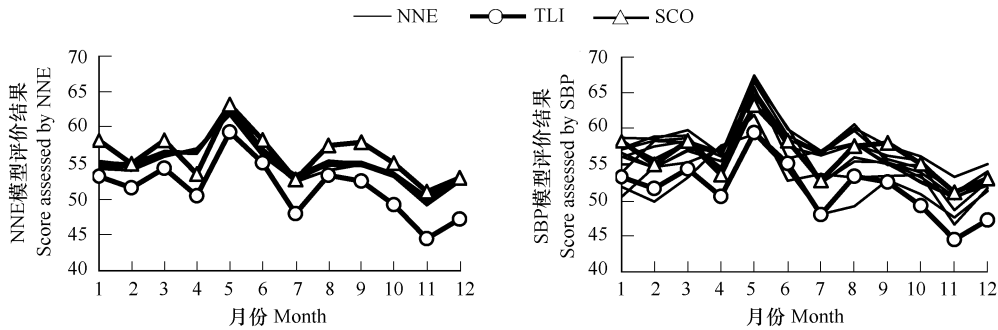


图3 NNE、SBP、TLI 和 SCO 对工作样本的评价结果
Fig. 3 Assessment results of working sample by NNE ,SBP ,TLI and SCO

2.3 NNE 与 TLI 和 SCO 方法的比较

从图 3 还可以看出,SCO 方法评价结果体现出的 2004 年全年巢湖东半湖营养状态的变动趋势和 TLI 一致,但前者评价结果均重于后者。NNE 模型评价结果表现出的变动趋势,在总体上与前两种方法基本一致。NNE 对工作样本 10 次评价结果的平均值与 SCO 和 TLI 评价结果之间的相关系数,分别为 0.9406 和 0.8891;而 SCO 和 TLI 之间的相关系数达到 0.9640。用 NNE 模型 10 次评价结果的平均值,分别与 SCO 和 TLI 方法进行配对 *t* 检验,结果表明,NNE 与 SCO 差异不显著,但与 TLI 差异极显著(*p* 分别取 0.05 和 0.01)。

NNE 评价结果与 TLI 和 SCO 方法相比,多数变动幅度均存在差异,尤其是对前四个月的评价结果。通过对表 2 所示的评价标准进行分析,可以看出该标准中 SD 和 COD_{Mn} 指标的取值范围最窄,这就意味着这两个指标取值的较小变化,会引起分值的较大变化,即对最终的富营养化状态影响力大。因此,根据这个标准得到的富营养化综合评价模型应对这个两个指标赋予较大的权重。由于 SD 指标在工作样本的 12 组数据中变动不大,因而 COD_{Mn} 的变动所产生的影响体现得非常明显。计算 NNE 模型 10 评价结果的平均值与 COD_{Mn} 取值的相关系数,结果为 0.9107。而 SCO 和 TLI 方法的结果与该指标取值的相关系数都不高,分别为 0.6678 和 0.7757。

基于 ANN 理论的 NNE 模型属于黑箱模型,通过学习来归纳训练样本中的规则,并以网络连接权重的形式储存。上述分析表明了该模型较好地归纳了评价标准中的评价规则,通过自学习实现了对各评价指标权重的分配。

3 讨论和结语

NNE 模型依据的水环境富营养化评价标准是目前我国广泛使用的,符合实际工作的要求,NNE 模型对巢湖营养状态的评价结果与目前通用的评价方法具有较好的相关性,但又不是完全的拟合,这说明该模型对评价指标权重的分配与 SCO 和 TLI 方法是不同的,同时,权重分配是通过基于评价标准构造的训练样本学习得到的,没有人为因素影响,评价结果客观公正;与单个 BP 网络模型相比,NNE 方法有效地消除了神经网络对初始权重的敏感性,显著提高了神经网络的鲁棒性和泛化能力,评价结果比单个神经网络更稳定、可靠。因此,NNE 模型具有很高的可靠性以及很强的通用性和实用性。但要在实际工作中应用,需要将训练后得到的各个体网络的权重保存下来,并用高级计算机程序设计语言实现 NNE 模型的可视化,才能方便地被使用和推广。

ANN 的简单集成方法易于实现,因此在环境质量评价中,该方法比单个神经网络模型具有更高的推广和应用价值。但要注意的是,NNE 中的个体网络一定要互异。最简单实现互异的方法就是使每个个体网络具

有不同的初始权重 ,复杂的方法还包括对不同的个体网络采用不同的训练样本、个体网络拓扑结构互异以及个体网络其他参数互异等。

NNE 模型使用了 40 个个体网络 ,采用简单平均输出集成方法。进一步的研究可以考虑降低 NNE 规模 ,采用加权输出集成方法 ,以减少训练和计算的时间消耗。

Reference :

[1] Chen A ,Luo Y T. Advances on application of artificial neural network methods in environmental science. Chongqing Environmental Science , 2003 , 25 (9) : 65 — 70.

[2] Ren L ,Dong Z C ,Li S H. Application of artif icial neural network model to assessment of Taihu Lake eutrophication. Journal of Hohai University (Natural Sciences) , 2004 , 32 (2) : 147 — 150.

[3] Han T ,Li H E ,Peng W Q. Application of neural network based on MATLAB toolbox to the evaluation of lake eutrophication. Water Resources Protection , 2005 , 21 (1) : 24 — 26.

[4] Wu L B ,Shang S Y ,Yue H J ,Ma Q Y. Study on evaluation of eutrophication of lakes based on fuzzy neural network. Journal of Inner Mongolia Agricultural University , 2004 , 25 (4) : 67 — 70.

[5] Zeng G M ,Lu H W ,Jin X C ,Xu M. Assessment of the water quality and nutrition of the Dongting Lake with wavelet neural network. Journal of Hunan University (Natural Sciences) , 2005 , 32 (1) : 91 — 94.

[6] Lou W G. Eutrophication assessment model using artificial neural networks for lakes and reservoirs. Journal of Fisheries of China , 2001 , 25 (5) : 474 — 478.

[7] Sollich P ,Krogh A. Learning with ensembles : how over-fitting can be useful. In :Touretzky D S ,Mozer M C and Hasselmo M E , eds. Advances in Neural Information Processing Systems 8. Cambridge : MIT Press , 1996. 190 — 196.

[8] Wei H K. Theory and practice of structure design of neural networks. Beijing : National Defense Industry Press , 2005.

[9] Wang M C ,Liu X Q ,Zhang J H. Evaluation method and classification standard on lake eutrophication. Environmental Monitoring in China , 2002 , 18 (5) : 47 — 49.

[10] Department of Planning and Programming , Ministry of Water Resources of China. Detailed Technical Rules for Integrated Programming of National Water Resources. [http ://ghjh. mwr. gov. cn/](http://ghjh.mwr.gov.cn/).

[11] An G. The effect of adding noise during backpropagation training on a generalization performance. Neural Computation , 1996 , (8) : 643 — 671.

[12] Research and Development Center of Fecit Science and Technology. Theory and implementation of neural network with MATLANB 7. Beijing : Publishing House of Electronics Industry , 2005.

参考文献 :

[1] 陈安 ,罗亚田. 人工神经网络方法在环境科学领域应用进展. 重庆环境科学 , 2003 , 25 (9) : 65 ~ 70.

[2] 任黎 ,董增川 ,李少华. 人工神经网络模型在太湖富营养化评价中的应用. 河海大学学报 (自然科学版) , 2004 , 32 (2) : 147 ~ 150.

[3] 韩涛 ,李怀恩 ,彭文启. 基于 MATLAB 的神经网络在湖泊富营养化评价中的应用. 水资源保护 , 2005 , 21 (1) : 24 ~ 26.

[4] 吴利斌 ,尚士友 ,岳海军 ,马清艳. 利用模糊神经网络对湖泊富营养化程度进行评价的研究. 内蒙古农业大学学报 , 2004 , 25 (4) : 67 ~ 70.

[5] 曾光明 ,卢宏伟 ,金相灿 ,徐敏. 洞庭湖水体水质状况及运用小波神经网络对营养状态的评价. 湖南大学学报 (自然科学版) , 2005 , 32 (1) : 91 ~ 94.

[6] 楼文高. 湖库富营养化人工神经网络评价模型. 水产学报 , 2001 , 25 (5) : 474 ~ 478.

[8] 魏海坤 编著. 神经网络结构设计的理论与方法. 北京 : 国防工业出版社 , 2005.

[9] 王明翠 ,刘雪芹 ,张建辉. 湖泊富营养化评价方法及分级标准. 中国环境监测 , 2002 , 18 (5) : 47 ~ 49.

[10] 中国水利部水利规划计划司. 全国水资源综合规划技术细则. [http ://ghjh. mwr. gov. cn/](http://ghjh.mwr.gov.cn/).

[12] 飞思科技产品研发中心编著. 神经网络理论与 MATLAB 7 实现. 北京 : 电子工业出版社 , 2005.