

DOI: 10.19797/j.cnki.1000-0852.20190351

基于人工神经网络的河口区盐水入侵预报研究

周凡涵^{1,2}, 刘丙军^{1,2}, 胡家昱³, 杨芳⁴, 万东辉⁴, 胡晓张⁴

(1. 中山大学土木工程学院, 广东 珠海 519082; 2. 华南地区水循环与水安全广东省普通高校重点实验室, 广东 珠海 519082; 3. 广东省水利电力勘测设计研究院, 广东 广州 510635; 4. 珠江水利科学研究院, 广东 广州 510611)

摘要:针对传统神经网络方法在处理非平稳时间序列时易受噪声干扰而难以挖掘变量间相关关系的缺陷,利用考虑边界效应和时移不变性的多孔小波变化(AT)对数据进行预处理,构建基于小波-神经网络(WA-ANN)的盐水入侵预报模型,对珠江口门区磨刀门水道2008~2010年枯水期进行逐日盐度预报和验证。结果表明:小波-神经网络模型较好减缓了外界噪声对模型训练的干扰,其整体预报精度明显优于传统BP神经网络(BP-ANN)模型。在测试集两个枯水时段,小波-神经网络模型的日均盐度预报平均绝对误差(MAE)较BP神经网络模型分别减少17.5%和9.1%;日均盐度预报预见期越长,小波-神经网络模型较BP神经网络模型的预报精度优势越明显,1~3d预见期内纳什效率系数(NSE)分别增加0.75%、3.30%和10.36%。

关键词:磨刀门;盐水入侵;神经网络;小波分解

中图分类号:TV124

文献标识码:A

文章编号:1000-0852(2020)06-0055-08

近年来高强度人类活动和海平面持续上升,珠江河口区盐水入侵及其危害程度日益严峻,严重威胁沿岸广州、深圳、珠海、东莞、中山等城市居民的生命财产安全^[1]。该河口区水流、潮汐、气象、海温、地形变化等海陆要素交互作用激烈,致使盐水入侵存在高度不确定性、随机性等特征,加之近年来河口区河道挖沙、上游水利工程调度、海平面持续上升等影响,进一步增加了该河口区盐水入侵预报的难度^[2-3]。

当前,基于机器学习算法的数据驱动模型已被广泛应用于盐水入侵预报,其中以神经网络居多^[4-9]。机器学习方法虽然在建模中较处理好变量间的非线性关系,但却难以响应序列的非平稳性,且盐度序列中包含的大量噪声也容易干扰模型对变量关系的挖掘^[10]。如何处理盐度序列的非平稳特征,消除噪声对预报精度的影响,是实现河口区盐水入侵精准预报的难点之一。小波分析被誉为数学“显微镜”,由于其在信号多分辨

率分析与滤波方面的优势性,越来越多学者们将其作为数据预处理的手段,构建小波-机器学习模型,以提升模型性能。Adamowski等^[11]耦合了离散小波变换与人工神经网络,建立地下水位预测模型,继而将此方法应用于城市需水量预测^[12],发现小波-神经网络相比于传统预报方法能得到更高的预测精度;Belayneh等^[13]将具有时移不变性的A'Trous小波变换与神经网络、支持向量机结合,对Awash River Basin的干旱指数进行预测,发现小波分解能有效提升模型预测精度。但也有研究发现^[14-16],目前较为流行的离散小波变换(DWT)由于“边界效应”和时移变化的缘故,并不适用于实际预报问题,只有极大重叠离散小波变化(MODWT)和多孔小波(AT)可应用于实际预报。

珠江河口区盐水入侵受径流、潮汐、气象、海温、地形变化等多重海陆要素交互作用,导致其盐度序列变化呈现高度不确定性、非平稳性和扰动性。基于此,本

收稿日期:2019-11-10

基金项目:国家自然科学基金项目(51879289,91547108);国家重点研发项目(2017YFC0405900)

作者简介:周凡涵(1997-),男,湖南邵阳人,硕士研究生,主要研究方向为河口区水质预测。E-mail:zhoufh3@mail2.sysu.edu.cn

通讯作者:刘丙军(1976-),男,湖南益阳人,教授,博士,主要研究方向为水资源系统分析。E-mail:liubj@mail.sysu.edu.cn

文以磨刀门水道为典型研究区,选用适宜于处理非平稳序列的小波分析方法,结合神经网络机器学习算法,利用多组分预测框架构建了小波-神经网络(WA-ANN)预报模型,对该水道预见期 1~3d 日均盐度进行预测,并与传统 BP 神经网络模型(BP-ANN)进行对比,以期为该河口区盐水入侵预报提供一定的理论方法与技术参考。

1 研究区域及数据来源

作为珠江流域八大口门之一的磨刀门水道,是西江主要泄洪输沙出口,位于西江水系下游河段,总长度约为 50km,径流量约占珠江入海总流量的 28%,是沿途城市(中山、珠海、江门)的重要水源地。磨刀门水道属弱感潮河段,其潮汐规律为不规则半日混合潮,盐水入侵距离与低潮位有着较大的相关性^[7-10]。近年来,磨刀门水道盐水入侵现象逐年频繁、持续时间延长、强度增大,从 20 世纪 90 年代开始,便接连出现数起盐水入侵事件^[9]。

本研究对位于磨刀门上游的平岗站进行了逐日盐度预测,研究时段为 2001~2009 年九个枯水期。所选的预报因子包含前期盐度、日最低潮位、日均径流量。其中,潮位观测数据来自磨刀门口门外三灶站的日最低潮位序列,径流观测数据选用上游三水、马口站的逐日合流量序列。站点分布及地理位置如图 1 所示。

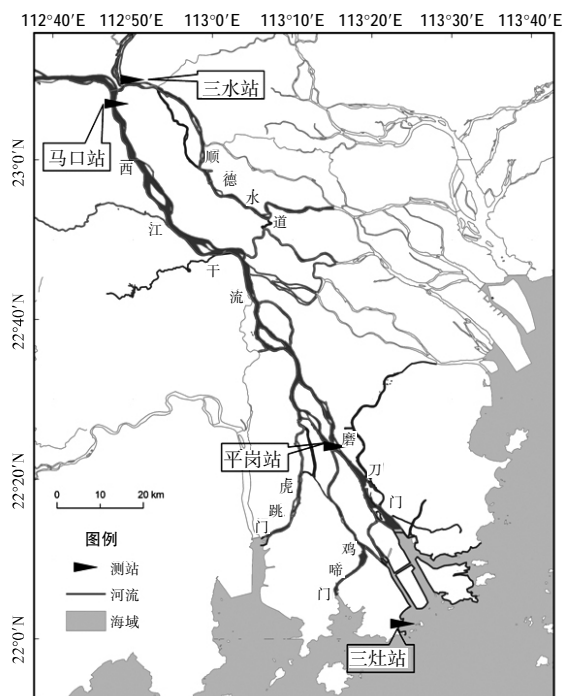


图 1 研究区站点与水系

Fig.1 Stations and water system in the study area

2 研究方法

为处理磨刀门水道盐水入侵的非平稳特征,本文选取基于“多组分预测框架”的小波-神经网络模型(WA-ANN)进行日均盐度预测。首先使用多孔小波变换(AT)对盐度及预报因子时间序列进行分解,得到较为平稳的多项子序列;其次,针对盐度序列分解后的各子序列依次建立神经网络模型,采用预报因子子序列进行分项预报;最终,将盐度子序列预报结果进行线性叠加集成,得到盐度序列预测结果。

2.1 预报因子选取

预报因子的选取对于盐水入侵预报模型至关重要,本文同时考虑了内源驱动因子(前期盐度)和外源驱动因子(径流、潮位)对盐度的影响。依次计算不同提前时间(1~15d)下的预报因子与盐度序列的互信息(Mutual Information, MI),选择 MI 较大的因子作为最优预报因子,筛选结果如表 1 所示。

互信息(MI)是一种非参数统计方法,可用公式表达为:

$$MI(X;Y)=\frac{1}{N}\sum_{i=1}^N\ln\frac{P_{X,Y}(x_i,y_i)}{P_X(x_i)P_Y(y_i)} \quad (1)$$

在实践中,由于 $P_X(x_i)$ 难以计算,一般使用核函数进行估算:

$$\hat{P}_X(x_i)=\frac{1}{N}\sum_{j=1}^N\frac{1}{(2\pi)^{d/2}\lambda^d(\det S)^{1/2}}\exp\left(\frac{-[x_i-x_j]^TS^{-1}x_i-x_j-}{2\lambda^2}\right) \quad (2)$$

式中: i,j 为观测样本编号; $\hat{P}_X(x_i)$ 为 x_i 处的密度核函数估计值; d 、 S 和 \det 分别为向量 X 的维度、协方差矩阵和行列式运算符; λ 为窗口带宽。

2.2 人工神经网络

人工神经网络是一种通过模仿生物神经网络结构而产生的计算模型,其具有高效的并行运算能力,能进行高度非线性映射,并且拥有一定的稳定性和容

表1 最优预报因子
Table1 The optimal predictors

预见期	预报因子组合		
	前期盐度	径流	低潮位
1d	S(t-1)、S(t-2)	F(t-2)	T(t-3)
2d	S(t-2)、S(t-3)	F(t-2)	T(t-3)
3d	S(t-3)、S(t-4)	F(t-3)	T(t-3)

注:S(t-1)、S(t-2)为提前 1d 盐度、提前 2d 盐度;F(t-2)为提前 2d 日均流量;T(t-3)为提前 3d 日最低潮位。其他预报因子同理。

错性。本文选用了神经网络中应用较为广泛的BP神经网络(BP-ANN),隐含层层数为1层^[20]。由于神经网络内部结构的不确定性,隐含层节点数的选取是个较困难的工作,一般通过试错法确定。本文初定隐含层节点数为2~20个,依次建立19种不同结构的模型,以在训练期中表现最好的隐含层节点数确定最优模型结构,所筛选的各神经网络模型最优隐含层节点数见表3和表5。由于神经网络中权值、阈值的初始化和调整过程也存在着不确定性,因此本文采用集合预报的思想,根据前面确定的最优模型结构进行20次模型训练,得到20个模型,筛选出其中训练效果最好的10个模型,并将其用于测试期的预测,对10个预测结果取平均值作为最终预测结果^[21]。本文采用梯度类中最为经典、高效的Levenberg-Marquardt方法训练神经网络;采用Nguyen-Widrow方法进行权重初始化;隐含层节点的传递函数选用对数S型函数(logsig);输出层节点的传递函数选用线性函数(purelin);训练的误差目标函数选用均方误差(MSE);最大迭代次数设为100次;学习率设为0.01。此外,由于预报对象(盐度)为非负数,因此,将预报结果中出现的负数取零。

2.3 小波变换

小波变换可以通过对母小波进行缩放和平移将信号分解为时域和频域上的分量。在预报问题中,较为流行的是使用Mallat算法的离散小波变换(DWT-MRA),而近期有学者^[15]指出,由于DWT-MRA不具备时移不变性,以及它在分解、重构过程中均需要用到“未来”数据,其并不适用于预报问题。而采用冗余算法的多孔小波变换(AT)可以保证分解序列的时移不变性以及避免因重构序列而使用“未来”数据的不现实性,其更适用于预报问题。因此,本文选用多孔小波变换(AT)分解时间序列。

由于盐度序列受海陆相多种因素交互影响而变化剧烈,本文选取局部化特性良好的haar小波作为小波基,其更容易在动态的时间序列中检测出局部变化^[22]。

小波分解层数依照经验公式^[23]确定为3层,见式(3)。

$$L=\text{int}(\log(N))$$

(3)

式中:L为小波分解层数;N为序列样本个数。

2.4 多组分预测框架

小波-神经网络的建立有多种框架,本文采用多组分预测框架,即“分解-预测-集成”框架,如图2所示。此框架由4个步骤实现。

(1)同时将盐度序列与各预报因子序列进行AT小波分解,每项原始序列均分解得到D1、D2、D3、A1、A2、A3(D为细节系数、A为近似系数)子序列。其中,当AT小波分解层数为3层时,重构序列只需用到第1~3层细节系数和第3层近似系数^[19],因此盐度序列的预测分量只选取D1、D2、D3和A3子序列,而舍弃A2和A3子序列。

(2)计算盐度序列分解分量(D1-A3)与各预报因子原始序列(ORI)、分解分量(D1-A3)的互信息(MI),选取MI最大值对应的预报因子分解分量作为最优预报因子分量,结果如表2所示。

(3)依次对各盐度序列分量(D1-A3)建立共4个神经网络模型,并利用表2的最优预报因子分量进行预报(每个模型的预报方法与2.2节相同),得到盐度序列预测分量(D1-A3)。

(4)对盐度序列预测分量进行线性叠加集成,见式(4),得到盐度预测最终结果。

$$X(t)=D1(t)+D2(t)+D3(t)+A3(t)$$

(4)

式中:X为集成后的盐度预测序列;D1、D2、D3为第1~3层细节系数的预测结果;A3为第3层近似系数的预测结果;t为时间。

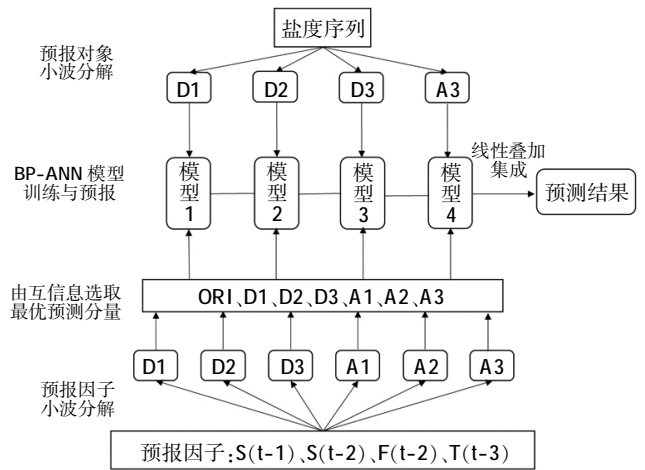


图2 多组分预测框架
Fig.2 Multicomponent method

表2 最优预报因子分解分量
Table2 The best decomposition component for each predictor

预测分量	预报因子						
	S(t-1)	S(t-2)	S(t-3)	S(t-4)	F(t-2)	F(t-3)	T(t-3)
D1	ORI	ORI	ORI	ORI	A3	A2	D3
D2	D1	ORI	ORI	ORI	A3	A3	D3
D3	D2	A1	ORI	ORI	A1	A3	D3
A3	A1	ORI	ORI	ORI	A3	A2	A2

3 结果分析

以 2001~2006 年 5 个枯水期为训练期,2006~2008 年 2 个枯水期为验证期,2008~2010 年 2 个枯水期为测试期,三个数据集的数量分别为 685、250、172。模型的评价指标采用了纳什效率系数(NSE)、均方根误差(RMSE)和平均绝对误差(MAE)。

3.1 AT 小波分解结果

将原始盐度序列进行 AT 小波分解,分解层数为 3 层,分解结果如图 3 所示。由图 3 可知,使用 haar 小波将原始盐度序列分解为波动剧烈的细节系数(D1、D2、D3)和形似原序列的近似系数(A1、A2、A3),其中,细节系数蕴含着盐度序列中高频部分的信息;而近似系数则蕴含着低频部分的信息。可以发现,分解层数越深(D1→D3,A1→A3),高频分量和低频分量的波动越弱。这是由于,随着分解的深入,信号中蕴含的能量及信息被不断地提取,从而使得分量序列变得越发平滑。此外,由分量与原始序列的确定性系数(R^2)可知,对于细节系数 D1-D3,分解越深,分量与原始序列的相关性越大(R^2 越大)。这是由于,D1 至 D3 的信号频率逐渐降低,分量中包含的除噪声以外的有效信息随之增多,因此与原始序列更相似。而对于近似系数 A1-A3,分解越深,分量与原始序列的相关性越小(R^2 越小)。这主要是因为,随着分解的深入,近似系数中越来越多

的信息被提取至细节系数中,从而使其与原始序列的相似性也逐渐降低。

3.2 WA-ANN 模型各分量预测结果

通过多组分预测框架构建 WA-ANN 模型进行预测,其预测分量的测试期评价结果如表 3 所示。其中,当预见期为 1d 时,所筛选的神经网络模型对 D1、D2、D3 和 A3 分量预测的最优隐含层节点数分别为 18、6、11 和 14;当预见期为 2d 时,对应的最优隐含层节点数分别为 11、6、12 和 16;当预见期为 3d 时,分别为 18、17、10 和 8。此外,由表 3 可知,模型对于低频信号(A3)的预测精度要明显高于高频信号(D1-D3)的。事实上,各分量的频率大小关系为:D1>D2>D3>A3,而预测结果的 NSE 大小关系则恰好相反:D1<D2<D3<A3,说明各分量的预测精度随信号频率增大而降低。原因分析:低频部分的信号往往是受长时因素影响而产生的,变化过程相对缓慢,较易预测;而高频信号主要受短时因素影响,包含了大量噪声,波动迅速且不规则,因此较难预测。从表 3 还可看出,虽然模型对低频信号的预测精度要高于高频信号的,但其 RMSE 和 MAE 却更大,说明高频信号蕴含的能量(可理解为波动幅度)要远小于低频信号的,因此,即使集成了较难预测准确的高频信号(D1-D3),模型的最终预测结果也不会受到很大程度的负面影响,这也为多组分预测框架提供了可行性。

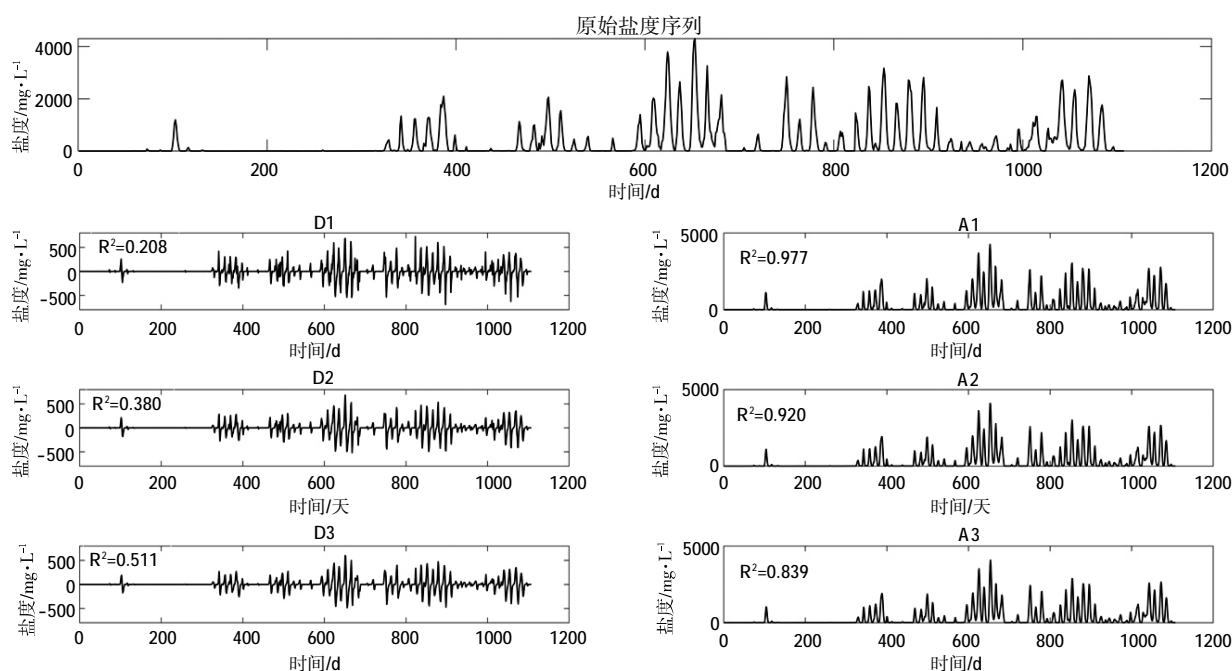


图3 经 AT 小波分解所得的盐度时间序列分量

Fig.3 The components of salinity time series that are obtained by the decomposition of AT

表3 预测分量测试期评价结果
Table3 Evaluation of predicted components from testing set

预测 分量	预见期 1d				预见期 2d				预见期 3d			
	模型结构	NSE	RMSE	MAE	模型结构	NSE	RMSE	MAE	模型结构	NSE	RMSE	MAE
D1	4-18-1	0.608	89.415	55.169	4-11-1	0.509	100.155	61.162	4-18-1	0.477	103.312	67.670
D2	4-6-1	0.898	41.175	26.010	4-6-1	0.656	75.508	49.458	4-17-1	0.617	79.638	49.657
D3	4-11-1	0.949	27.192	18.015	4-12-1	0.777	57.133	37.101	4-10-1	0.673	69.188	43.695
A3	4-14-1	0.995	42.982	26.146	4-16-1	0.970	108.120	70.896	4-8-1	0.884	212.340	145.237

3.3 WA-ANN 模型与 BP-ANN 模型预测结果对比

将传统神经网络模型(BP-ANN)与小波-神经网络模型(WA-ANN)的预测效果进行比较,预测过程如图 4 所示,预测实际误差如图 5 所示。

(1)分析图 4~5 可知,在对测试集 2008~2009 年、2009~2010 年两个枯水时段的日均盐度预报中,WA-ANN 模型的预报精度明显优于 BP-ANN 模型。其中,模型在对这两个枯水时段的盐度预测中,分别出现了高估和低估的预测偏差,而在 WA-ANN 模型预测中,此偏差有所减弱。鉴于此,进一步计算分析了 WA-ANN 模型与 BP-ANN 模型在两枯水时段预测的平均绝对误差(MAE),如表 4 所示。分析表 4 可知,WA-ANN 模型相比于 BP-ANN 模型在两枯水时段盐度预报中,能够有效减小预测值的 MAE,平均减小幅度分别为 17.5%和 9.1%。原因分析:由于两模型采用 2001~2006 年枯水期数据作为训练集,与测试集(2008~2010 年枯水期)相隔较久远,期间盐度与径流、潮汐间的关系可能有所变化;且外源驱动因子仅考虑了径流与潮汐,而盐水入侵也会受到如:人类活动、海平面上升、气候变化等影响,所以在预报过程中难免会出现此类预测偏差。而之所以在 WA-ANN 模型中预测偏差有所减弱,这是因为小波分解可以帮助模型更容易识别变量间相关性变化的规律、减小模型受噪声影响的程度,使得模型拥有更强的灵活性和鲁棒性,从而一定程度上减小了模型在不同枯水时段上出现的预测偏差,但

仍较为明显。

(2)两模型的预测精度评价结果如表 5 所示,其中,当预见期为 1~3d 时,各 BP-ANN 模型所筛选的最优隐含层节点数分别为 10、12 和 17。分析表 5 可知,随着盐度预报预见期的延长,WA-ANN 模型较 BP-ANN 模型在预报精度上的优势越加明显。其中,预见期为 1d 时,NSE 的提升幅度仅为 0.75%;预见期 2d 时,提升幅度可达到 3.30%;当预见期为 3d 时,提升幅度最高为 10.36%。由表 4 也可看出,WA-ANN 模型相比于 BP-ANN 模型对两枯水时段盐度预测误差的减小幅度也是随预见期延长而增大的。这说明,总体上利用 WA-ANN 模型进行盐度预测

表 5 WA-ANN 与 BP-ANN 模型的预测精度对比
Table5 Difference of prediction accuracy
between WA-ANN and BP-ANN models

预见期	模型种类	模型结构	NSE	RMSE	MAE
1d	BP-ANN	4-10-1	0.936	167.505	103.948
	WA-ANN		0.943	157.748	97.298
	优化幅度		0.75%	5.82%	6.40%
2d	BP-ANN	4-12-1	0.787	305.888	185.968
	WA-ANN		0.813	286.762	172.413
	优化幅度		3.30%	6.25%	7.29%
3d	BP-ANN	4-17-1	0.618	410.144	246.481
	WA-ANN		0.682	373.851	216.508
	优化幅度		10.36%	8.85%	12.16%

注:优化幅度为 WA-ANN 相对 BP-ANN 在某项评价因子上表现提升的百分比。对于 NSE 为增大的百分比,对于 RMSE 和 MAE 为减小的百分比。

表4 WA-ANN与BP-ANN模型在测试集两枯水时段预测的平均绝对误差
Table4 Mean absolute error for WA-ANN and BP-ANN models in two drought periods from testing set

平均绝对误差(MAE)	预见期 1d		预见期 2d		预见期 3d		平均
	BP-ANN	WA-ANN	BP-ANN	WA-ANN	BP-ANN	WA-ANN	
2009-1-1 至 2009-2-28	49.13	43.93	89.47	76.84	105.24	75.86	
减小幅度		10.6%		14.1%		27.9%	17.5%
2009-10-15 至 2010-2-4	132.58	125.16	235.07	212.47	318.27	279.56	
减小幅度		5.6%		9.6%		12.2%	9.1%




图4 WA-ANN与BP-ANN模型的盐度预测过程
Fig.4 Salinity process predicted by WA-ANN and BP-ANN models




图5 WA-ANN与BP-ANN模型的盐度预测误差
Fig.5 Prediction error for WA-ANN and BP-ANN models

的效果要优于使用BP-ANN模型预测的,且优势随预见期延长而明显。原因分析:由于盐度序列的自相关性很强,当预见期较短时,预报因子主要依赖于前期盐度,而这种相关性往往是简单的、较平稳的,使用BP-ANN足以进行预测;随着预见期延长,前期盐度与原始盐度的相关性迅速降低,预报因子逐渐依赖于外源驱动因子(径流、低潮位),而外源

驱动因子与盐度序列的相关性是复杂的、波动的,因此,采取小波变换对信号分解后再进行预报有助于模型识别盐度序列与外源驱动因子间的复杂关系,从而提升预报精度。

4 结论

受径流、潮汐、气象、海温、地形变化等多重海陆要素交互作用,河口区盐度时间序列有着较明显的非

平稳性,传统机器学习方法难以克服盐度序列中噪声的干扰,致使预报精度偏低。本文采用考虑时移不变性和边界效应的多孔小波分解(AT)对时间序列进行预处理,通过多组分预测框架构建基于小波-神经网络(WA-ANN)的盐水入侵预报模型,对磨刀门水道平岗站日均盐度进行了预见期1~3d的预测,得出如下结论:

(1)耦合了多孔小波分解(AT)的小波-神经网络模型(WA-ANN)相比于传统的单一神经网络模型(BP-ANN)在各预见期的预报精度均有一定程度的提升,且能有效减小模型在不同枯水时段上出现的预测偏差(高估、低估现象),使模型在2008~2010年两个枯水时段盐度预测的平均绝对误差(MAE)分别减小了17.5%和9.1%。这主要是因为小波变化能将非平稳时间序列分解为不同时间尺度下的子序列,让原来隐藏于变量间的复杂关系更容易被模型识别,使得模型拥有更强的灵活性。同时,小波分解也减缓了噪声对模型训练的干扰,从而提高了模型的泛化能力,有效避免过拟合现象,使得模型拥有更强的鲁棒性。

(2)小波分解对模型预报精度的提升幅度随预见期延长而增大,如:预见期1~3d的纳什效率系数(NSE)提升幅度依次为0.75%、3.30%和10.36%。这主要是因为预见期较短时,盐度自相关性很强,预报因子中前期盐度占主导地位,与盐度序列的相关关系较为简单,单一神经网络(BP-ANN)足以预报准确;而随着预见期的延长,预报因子中外源驱动因子逐渐占主导地位,与盐度序列的相关关系复杂,且更易受噪声扰动,因此小波分解对模型预报精度的提升作用也更明显。

受训练期与测试期样本时间间隔较大、外源驱动因子考虑不足等因素影响,小波分解模型在日均盐度预报中仍存在一定的误差。后续研究可考虑加入充足外源驱动因子、采用滚动修正预报等方式进一步完善,不断提升预报精度。

参考文献:

- [1] 陈荣力, 刘诚, 高时友. 磨刀门水道枯季咸潮上溯规律分析 [J]. 水动力学研究与进展, 2011,26(3):312-317. (CHENG Rongli, LIU Cheng, GAO Shiyu. Analysis of the mechanism on the saltwater intrusion in Modaomen estuary [J]. Chinese Journal of Hydrodynamics, 2011,26(3):312-317. (in Chinese))
- [2] 程香菊, 詹威. 珠江西四口门盐水入侵数值模拟及分析 [J]. 水利学报, 2012,39(5):554-563. (CHENG Xiangju, ZHAN Wei. Numerical simulation and analysis of saltwater intrusion to four western watercourses of Pearl River estuary [J]. Journal of Hydraulic Engineering, 2012,39(5):554-563. (in Chinese))
- [3] 宋晓飞, 石荣贵, 孙聆晏, 等. 珠江口磨刀门盐水入侵的现状与成因分析 [J]. 海洋通报, 2014,33(1):7-15. (SONG Xiaofei, SHI Ronggui, SUN Lingyan, et al. Status and cause of saltwater intrusion in Modaomen, Pearl River estuary [J]. Marine Science Bulletin, 2014,33(1):7-15. (in Chinese))
- [4] Bowden G J, Maier H R, Dandy G C. Input determination for neural network models in water resources applications. Part 2. Case study: forecasting salinity in a river [J]. Journal of Hydrology, 2005,301(1):93-107.
- [5] Huang W, Foo S. Neural network modeling of salinity variation in Apalachicola River [J]. Water Research, 2002,36(1):356-362.
- [6] Maier H R, Dandy G C. The use of artificial neural networks for the prediction of water quality parameters [J]. Water Resources Research, 1997,32(32):1013-1022.
- [7] 陈记臣, 查悉妮, 卓文珊, 等. 基于 AdaBoost 算法和 BP 神经网络的咸潮模拟研究 [J]. 人民珠江, 2017,38(1):5-10. (CHEN Jichen, ZHA Xini, ZHAO Wenshan, et al. Simulation study of saline intrusion based on AdaBoost algorithm and BP neural network [J]. Pearl River, 2017,38(1):5-10. (in Chinese))
- [8] Suen J P, Lai H N. A salinity projection model for determining impacts of climate change on river ecosystems in Taiwan [J]. Journal of Hydrology, 2013,493(493):124-131.
- [9] 路剑飞, 陈子桑. 珠江口磨刀门水道盐度多步预测研究 [J]. 水文, 2010,30(5):69-74. (LU Jianfei, CHEN Zishen. Salinity prediction at Modaomen waterway in estuary of Pearl River [J]. Journal of China Hydrology, 2010,30(5):69-74. (in Chinese))
- [10] Zhou T, Wang F, Yang Z. Comparative analysis of ANN and SVM models combined with wavelet preprocess for groundwater depth prediction [J]. Water, 2017,9(10):781.
- [11] Adamowski J, Chan H F. A wavelet neural network conjunction model for groundwater level forecasting [J]. Journal of Hydrology, 2011,407(1-4):28-40.
- [12] Adamowski J, Fung Chan H, Prasher S O, et al. Comparison of multiple linear and nonlinear regression, autoregressive integrated moving average, artificial neural network, and wavelet artificial neural network methods for urban water demand forecasting in Montreal, Canada [J]. Water Resources Research, 2012,48(1).
- [13] Belayneh A, Adamowski J, Khalil B, et al. Long-term SPI drought forecasting in the Awash River basin in Ethiopia using wavelet neural network and wavelet support vector regression models [J]. Journal of Hydrology, 2014,508(2):418-429.
- [14] Du K, Zhao Y, Lei J. The incorrect usage of singular spectral analysis and discrete wavelet transform in hybrid models to predict hydrological time series [J]. Journal of Hydrology, 2017,552:44-51.
- [15] Quilty J, Adamowski J. Addressing the incorrect usage of wavelet-based hydrological and water resources forecasting models for real-world applications with best practices and a new forecasting framework [J]. Journal of Hydrology, 2018,563(2018):336-353.
- [16] Zhang X, Peng Y, Zhang C, et al. Are hybrid models integrated

- with data preprocessing techniques suitable for monthly streamflow forecasting? Some experiment evidences [J]. Journal of Hydrology, 2015,530(2015): 137-152.
- [17] 苏程佳, 陈莎, 陈晓宏. 基于随机森林模型的咸潮预报[J]. 热带地理, 2018,38(3):432-439. (SU Chengjia, CHEN Sha, CHEN Xiaohong. Saltwater intrusion forecasting based on random forest [J]. Tropical Geography, 2018,38(3):432-439. (in Chinese))
- [18] 王艺霖, 苏程佳, 陈晓宏. 磨刀门水道枯水期咸潮变化趋势及成因[J]. 水资源保护, 2019,35(2):37-43. (WANG Yilin, SU Chengjia, CHEN Xiaohong. Change trend and cause of salt tide in Modaomen Channel during dry seasons [J]. Water Resources Protection, 2019,35(2):37-43. (in Chinese))
- [19] 闻平, 陈晓宏, 刘斌. 磨刀门水道咸潮入侵及其变异分析 [J]. 水文, 2007,27(3):65-67. (WEN Ping, CHEN Xiaohong, LIU Bin. Analysis of tidal saltwater intrusion and its variation in Modaomen channel [J]. Journal of China Hydrology, 2007,27(3):65-67. (in Chinese))
- [20] Hsu K L, Gupta H V, Sorooshian S. Artificial neural network modeling of the rainfall-runoff process [J]. Water Resources Research, 1995,31(31):2517-2530.
- [21] Wang W, Van Gelder P H, Vrijling J, et al. Forecasting daily streamflow using hybrid ANN models [J]. Journal of Hydrology, 2006,324(1-4):383-99.
- [22] Maheswaran R, Khosa R. Wavelet - Volterra coupled model for monthly stream flow forecasting [J]. Journal of Hydrology, 2012,450-451.
- [23] Nourani V, Komasi M, Mano A. A multivariate ANN-wavelet approach for rainfall-runoff modeling [J]. Water resources management, 2009,23(14):2877.

Study of Estuarine Salinity Prediction Based on Wavelet Artificial Neural Network

ZHOU Fanhan^{1,2}, LIU Bingjun^{1,2}, HU Jiayu³, YANG Fang⁴, WAN Donghui⁴, HU Xiaozhang⁴

(1. School of Civil Engineering, Sun Yat-Sen University, Zhuhai 519082, China; 2. Key Laboratory of Water Cycle and Water Security in Southern China of Guangdong High Education Institute, Zhuhai 519082, China; 3. Guangdong Hydropower Planning & Design Institute, Guangzhou 510635, China; 4. The Pearl River Hydraulic Research Institute, Guangzhou 510611, China)

Abstract: In view of that the traditional neural network methods in the treatment of non-stationary time series are susceptible to noise and difficult to dig the correlation between variables, wavelet decomposition method based on a trous algorithm (AT), which considered boundary effect and shift invariance well, was used to preprocess the data. Then the wavelet-neural-network (WA-ANN) model for saltwater intrusion prediction was constructed. Daily salinity forecast was carried out in the dry season from 2008 to 2010. The results show that the wavelet-neural-network (WA-ANN) model could reduce the interference of external noise, and its prediction accuracy is obviously better than the traditional BP-neural-network (BP-ANN) model. In the two dry periods from testing set, the mean absolute error (MAE) of WA-ANN model is 17.5% and 9.1% less than that of the BP-NN model. Besides, the longer prediction period of salinity is, the more obviously WA-ANN model outperformed BP-ANN model in salinity forecasts. The Nash efficiency coefficient (NSE) increases by 0.75%, 3.3% and 10.36% when the prediction period are 1, 2 and 3 days respectively.

Key words: Modaomen waterway; saltwater intrusion; artificial neural network; wavelet decomposition

《水文》杂志征订启事

《水文》杂志是由水利部主管,水利部信息中心(水利部水文水资源监测预报中心)主办,国内外公开发行的我国水文水资源专业的学术性科技期刊,系我国地球物理学类和水利工程类全国中文核心期刊、中国科技核心期刊、中国科学引文数据库来源期刊、《中国学术期刊(光盘版)》全文收录期刊、中国期刊网和“万方数据——数字化期刊群”入网期刊。

刊登内容:水文水资源基础理论研究,水文站网规划设计,水文测验技术,水文资料处理与服务,水文水资源分析计算,水文情报预报,水资源调查评价,水环境、水生态监测与水质预测,新技术在水文水资源方面

的应用,测验仪器设备的研制,国内外水文水资源科技进展综述、评述以及有关信息和动态等。

出版发行:《水文》杂志为双月刊,每逢双月 25 日出版,国内由北京报刊发行局总发行,全国各地邮局均可办理订阅手续,邮发代号:2-430,每册定价 20 元,全年共 120 元;国外由中国国际图书贸易总公司(地址:北京 399 信箱,邮政编码:100044)发行,代号:BM511。

通讯地址:北京市白广路二条 2 号,100053,电话:(010)63202029; 传真:(010)63203550;

E-mail:j.hyd@mwr.gov.cn

投稿网址: <http://sw.allimga.net/ch/index.aspx>