

两种神经网络海啸波检测算法比较

张晓娟, 李国富, 刘颀, 张爽, 商红梅, 梁捷

(国家海洋技术中心, 天津 300112)

摘要: 简要介绍国内外海啸检测方法现状;设计并比较反向传播神经网络(BP)、径向基函数神经网络(RBF)两种神经网络检测算法,采用美国“海啸事件深海评估及报告系统”(DART)数据验证算法有效性,同时将其与传统多项式插值检测算法的预测残差进行对比,使用均方根误差衡量预测值和观测值的残差。仿真结果表明新算法可降低均方根误差,其中绝对值大于10 mm的大残差数量降幅约90%~100%。

关键词: 海啸检测;反向传播神经网络;径向基函数神经网络;时间序列模型

中图分类号: P731.25 **文献标识码:** A **文章编号:** 1003-0239(2026)04-0016-08

0 引言

海啸是由于海底地震、火山活动、海底滑坡或者气象变化导致的大量水体的位移,尤其是垂直位移,进而生成抵岸巨浪,淹没内陆、侵袭港口,给沿岸民众生命安全和财产造成严重灾难^[1]。21世纪以来,已先后发生两次特大海啸灾害,分别是2004年印度洋海啸事件和2011年日本海啸事件。由于海底板块活动频繁,太平洋是全球遭受海啸侵袭最多的海域,有记录的223起海啸事件中,约80%发生在太平洋沿岸。我国虽濒临太平洋,但东部岛链的屏障作用降低了海啸发生概率,但仍被国际学界认定为易受海啸影响的国家。海啸与风暴潮、海浪等其他海洋灾害不同,海啸预警是与时间赛跑的“游戏”,需在数分钟内制作完成海啸预警产品;作为预警产品的核心环节,准确、快捷、有效的海啸波检测和预警,对全球各滨海国家至关重要^[2]。

1949年,美国建立全球首个国家级海啸预警中心——太平洋海啸预报中心(Pacific Tsunami Warning Centre, PTWC, 又名太平洋海啸预警中心);此后俄罗斯、日本等国家也相继建立各自的海啸预警中心。1986年,美国正式投用海啸事件深海评估

及报告系统(Deep-ocean Assessment and Reporting of Tsunami, DART),至今已在太平洋、大西洋海域布放了50多套海啸监测浮标,建立起海啸浮标监测网^[3]。联合国教科文组织政府间海洋学委员会(Intergovernmental Oceanographic Commission, IOC)成立后,组建了太平洋海啸预警与减灾系统政府间协调组(Intergovernmental Coordination Group for the Pacific Tsunami Warning and Mitigation, ICG)。我国的海啸预警业务体系自2004年印度洋海啸之后起步建设,2011年日本地震海啸后进入高速发展阶段;2012年国家海洋环境预报中心开发完成第一代依托全球地震监测分析系统搭建的海啸预警业务平台,2016年新一代海啸预警业务系统投入使用。该系统集成全球海底地震监测、全球水位监测、太平洋海啸并行预报模型、海啸情形数据库和海啸产品制作发布等12个子系统,可与太平洋海啸预警中心、中国地震台网中心、国家气象信息中心等国内外业务与数据中心实时联通,形成海啸预警标准业务流程。地震纵波传播速度(约为3~8 km/s)比海啸波传播速度(约为0.14~0.27 km/s)快30倍左右,时差优势有利于开展早期预报;但对7级以上海底地震的测量易缺乏准确性和实时性评估^[3]。新

收稿日期: 2025-10-09。

基金项目: 自然灾害防治技术装备工程化攻关专项(TC210H00L/48)。

作者简介: 张晓娟(1980-),女,工程师,硕士,主要从事数据处理和算法研究。E-mail: zxj927@eyou.com

一代海啸预警业务系统在地震信息研判基础上新增水位监测系统,大大提升了预警结果的准确性和时效性,可将我国海啸预警的时效性大幅缩短至10 min以内^[2]。

基于DART系统实测观测数据,海啸数值模拟技术得到提升,可实现海啸淹没风险的量化研究。该技术流程为:先利用实测初始海啸波修正地壳形变反演的海啸源参数,然后基于高精度地形数据和高密度网络求解非线性浅水方程,模拟海啸波的全域演化过程,提升近岸社区定点淹没预报的时效性和可靠性^[2]。美国国家海洋和大气管理局(National Oceanic and Atmospheric Administration, NOAA)已将海啸浮标监测数据同化至海啸分裂法模型(Method of Splitting Tsunami, MOST),单点预报准确率可达80%以上^[2]。因此,提升海啸浮标对海啸波的观测识别精度,能够推动海啸预报的精细化发展。

1 海啸预警浮标监测原理

在“海啸预警浮标研发与应用示范项目”的支持下,国家海洋技术中心牵头开展了海啸预警浮标系统研制工作(浮标架构见图1)。布设在深海海底的海啸监测仪可采集全域水体高精度水位信息(现有海啸波精密观测技术可识别低至1 cm的微弱海啸信号^[4]);原始观测数据经由海啸波识别算法处理




图1 国家海洋技术中心海啸预警浮标架构

Fig.1 Tsunami warning buoys of the National Marine Technology Center

后生成报文,利用水声通信传输至海面锚系浮标,最终由卫星通信终端将监测信息回传至海啸预警中心,实现海啸全过程预警监测。海啸波识别算法是该浮标系统的关键技术之一。

海啸波是一种浅水波(见图2),是满足水深与波长比值 $h/\lambda < 0.05$ (其中 h 为水深, λ 为波长)的重力波^[5],其波速与水深的1/2次方成正比。当海啸波由深水区传入浅水区,波速减小、水体堆积导致波高增大,由此引发海啸灾害。由于海啸波是浅水重力波,其波长远大于水深,水质点随水深的运动规律满足:运动轨迹呈椭圆形,椭圆短轴等于波振幅并随水深增加而线性减小,海底位置短轴长度为零,水质点仅做水平往复运动;椭圆长轴是波长和振幅的函数,不随水深发生变化。基于该运动特征,海底压力传感器可捕捉水质点运动引发的压力变化并在深海海底进行测量。而海浪、风生波等深海深水波长远小于水深,按照深水波理论:水质点运动轨迹呈圆形,其半径随水深增加而指数衰减,在半波长深度处,质点的运动半径、流速和压力仅为海表面处的4%,这类水质点运动产生的作用力在抵达海底前已基本耗散^[6]。深海环境具备低频滤波特性,可滤除海浪、风生波等高频扰动信号,仅保留低频浅水波信号。因此,在海底布设海啸浮标搭载毫米级压力传感器,用于感知包含海啸波在内的浅水波波幅。




图2 浅水波概念图

Fig.2 Conceptual diagram of shallow water waves

海洋中的浅水波通常包括潮汐波和环境杂波,且以长期存在的潮汐波为主,海啸波是偶发的浅水波,当海啸发生时,有规律的潮汐波会与海啸波叠加。因此,为了检测海啸波,需要将海啸波从潮汐波中识别出来。潮汐波的变化规律已研究成熟:基于分潮理论,采用最小二乘法计算分潮调和常数;基于调和分析的潮汐预报基本每年都遵循固定的

循环周期,预报误差为 20~30 cm。但海啸波波高很小,为厘米级别,该方法的预测残差太大,无法满足预报要求^[7-8]。

已有一些文献提出从原始水位观测数据中检测或分离海啸信号的方法,主要包括:多项式插值法^[9]、神经网络方法^[10]、基于近岸海啸检测仪器的数字滤波器法^[11-13]等。对海啸特征检测算法性能优劣的评价指标为:算法对海啸波检测的灵敏度和虚警概率有无改善;算法在实际操作中是否具备可行性。

2 海啸特征检测算法原理

本节介绍当前 DART 项目正在使用的深海海啸预警多项式插值算法,并与两种新的人工神经网络(Artificial Neural Network, ANN)算法,即反向传播神经网络(Back Propagation, BP)和径向基函数神经网络(Radial Basis Function, RBF)进行对比,验证两种 ANN 算法相对于多项式插值算法是否具备提高预警精度的能力。

多项式插值算法通过对潮汐波建模,比较深海海底潮汐波的预测值和包含潜在海啸信号的观测数值,计算水位残差,判断此残差值是否超出北太平洋潮汐波杂波噪声的经验阈值^[9],如超出表示存在海啸波,以此监测海啸的发生和传播。

2.1 深海海啸预警的多项式插值算法

插值技术是数字信号处理中常用的一种技术,用于对离散采样信号进行恢复和重构。插值算法用于潮汐波高度预测的原理见图 3。DART 项目中采用多项式插值算法预测潮汐波波幅。

$$H_p(t') = \sum_{i=0}^3 w(i) H^*(t - idt) \quad (1)$$

式中: t' 为预测时间步长(即以 $t - idt$ 为预测起始时间值); $H^*(t - idt)$ 表示时刻 $t - idt$ 为中心点的一段时间内采样值的平均(通常为分钟级), dt 为采样时间间隔;系数 $w(i)$ 取值来自于牛顿插值法^[9]。

2.2 人工神经网络海啸检测算法

目前,BP 和 RBF 模型已经成为模拟非线性函数的最成功的人工神经网络模型。它们属于前馈型有监督神经网络,但分别为全局和局部逼近神经网络

图 3 潮汐波采样和预测过程

Fig.3 Tidal wave sampling and prediction process

络^[14-18]。

此方法的海啸预测原理为:通过学习已知点和预测点之间的映射关系对潮汐波建模,在较短预测时间内进行数据插值预测。因潮汐波随季节动态变化,且变化相对缓慢,因此可归为非线性慢时变系统,即系统参数的更新速率远低于输入、输出对应关系的变化速度,即可通过不断更新参数或结构,实现对原系统输入、输出关系的较好拟合^[19-20]。同时,因为潮汐波序列的幅度随时间呈动态变化且波动幅度较大,因此潮汐波时间序列为非平稳过程,但其高阶差分序列具备平稳性。基于此,下文对潮汐波数据开展时间序列分析。

对 IOC 网站公布的、美国布放于日本海附近的 DART 浮标(152.07°E, 30.533°N, 编号 21413)所获取的海平面数据进行快速傅里叶变换(Fast Fourier Transform, FFT)^[21],结果显示潮汐波的主周期为 12 h、24 h,即半日潮或全日潮,同时还存在其他周期、幅值为数厘米~数十厘米的杂波(见图 4)。其他 DART 站点的数据也可以做傅里叶变换并输入神经网络进行海啸波预测。对以上时间序列进行取样、分析、建模操作。取样时长间隔(时间步长)过大会增加模型复杂度;时间步长过小可能使模型过度关注噪声。本文依据 FFT 分析的幅频图(见图 4)选取合适的阈值频率。

常用的时间序列主要模型为自回归模型(Autoregressive model, AR)、滑动平均模型




图4 潮汐波幅值阈值频率选择依据及局部显示

Fig.4 Threshold frequency of tidal wave amplitude and its local display

(Moving Average Model, MA)、自回归滑动平均模型 (Auto-Regressive Moving Average Model, ARMA) 和差分自回归滑动平均模型 (Auto-Regressive Integrated Moving Average Model, ARIMA)。对潮汐波分析可知: 可对该随机过程进行高阶差分以去除趋势和周期项, 利用单位根 (Dickey-Fuller) 检测等方法开展平稳性检测, 初步判定该序列适配 ARIMA 模型。假设潮汐波经过 d 阶差分后可表示为平稳随机过程, 其模型为^[20,22]:

$$z_t^* = \phi_1 z_{t-1} + \phi_2 z_{t-2} + \cdots + \phi_p z_{t-p} + a_t + \varphi_1 a_{t-1} + \varphi_2 a_{t-2} + \cdots + \varphi_q a_{t-q} \quad (2)$$

式中: z_t^* 表示经过差分处理后的平稳时间序列在 t 时刻的值, z_{t-i} 表示平稳序列在历史时刻 $t-i$ 的值; i 为滞后阶数; p 自回归模型的阶数; ϕ_i 自回归系数, 表示过去的历史 z_{t-i} 对 z_t^* 的影响权重。 a_t 表示在 t 时刻的白噪声误差项, a_{t-j} 表示历史 $t-j$ 时刻的白噪声误差项; j 为误差项的滞后阶数; q 表示滑动平均阶数; φ_i 表示移动平均系数, 表示 a_{t-j} 对 z_t^* 的影响。

较为简洁的时间序列定阶方法有偏相关定阶法和准则函数定阶法, 常用的准则函数定阶包括最小信息准则 (Akaike information criterion, AIC) 以及贝叶斯信息准则 (Bayesian Information Criterion, BIC)。根据其原理, 在样本量趋于无穷时, AIC 准则定阶结果往往大于实际模型阶次, 而 BIC 准则得到的模型阶次更接近真实阶数, 因此本文采用 BIC

准则。公式为:

$$\text{BIC}(p, q) = 2\ln L + k \cdot \ln(n) \quad (3)$$

式中: p, q 表示模型阶次; $\ln(n)$ 表示对应的最大似然函数 L 的对数。

经计算, 该潮汐波时间序列为 ARIMA(3, 1, 2) 模型, 因此可以用 4 个时刻的历史数据预测未来 t 时刻数据; 由于预测点 t 与 $t \pm 1$ 时刻的实测数据与预测值较为接近, 可近似看作线性变化, 可通过对预测值线性插值得到细化结果。因此, 本文只对 BP 神经网络权重进行线性加权, 由此建立四点输入的 BP 神经网络用于预测。在此基础上选取 BP 神经网络隐层节点数、权值等参数, 将训练样本数据输入神经网络, 训练网络参数, 使预测结果满足目标函数, 均方根误差 (Root Mean Square Error, RMSE) 最小。同理, 由于 t 与 $t \pm 1$ 时刻的实测数据与预测值接近, 又可近似为二次插值关系, RBF 神经网络为输入数据的二次函数, 因此对 RBF 神经网络的参数做线性调整即可改变输出的二次函数趋势, 因此对 RBF 网络中心点、方差和权重进行线性加权实现二次插值, 以此作为预测值。由此可建立四点输入 BP、RBF 神经网络开展预测, 设计两种神经网络的隐层、输出层数等结构参数; 以目标函数 RMSE 最小训练网络权值参数。

2.2.1 BP 法的网络结构

BP 神经网络采用三层结构, 即单隐含层的三层感知器结构^[15-19], 其输入、输出数据的向量公式为:

$$o = f_o\{B^2 + W^2 f_i(W^1 P + B^1)\} \quad (4)$$

单变量表达式为:

$$o = f_o\left\{b_l^2 + \sum_{j=1}^m w_j^2 f_i\left[b_j^1 + \sum_{i=1}^n w_{ij}^1 x_i^1\right]\right\} \quad (5)$$

式中: b_l^2 为 l 层第 i 偏置值; w_j^2 为 l 层的 j 节点; x_i^1 为第 1 层第 i 输入。隐含层激活函数 f_i 常用单 (双) 极性 Sigmoid 函数形式, 输出函数 f_o 多采用线性函数如 Purelin 函数; 激活函数对输入数据做映射变换, 对映射结果加权求和后输出, 以此实现潮汐波的数据预测。

2.2.1.1 BP 法的激活函数等的选择

通常 BP 神经网络参考经验公式和试凑法选择隐含层节点数, 经验公式为:

$$m = \sqrt{nu} \quad (6)$$

式中: m 为隐含层节点数; n 为输入层节点数; u 为输出层节点数。

结合时间序列的阶次分析,采用 $n = 4$ 输入,计算得到隐含层节点数为2,其中训练数据选用标注站点2009年11—12月海底潮汐采样数据,测试数据为2010年1月采样数据。

以上参数的BP神经网络结构为:

$$H_p(t') = f_o \left\{ b_1^2 + \sum_{j=1}^m w_{j1}^2 f_1 \left[b_j^1 + \sum_{i=0}^3 w_{ij}^1 H^*(t - i\Delta t) \right] \right\} \quad (7)$$

式中: $H_p(t')$ 为 t' 时刻潮汐波预测值, H^* 为一段时间(如10 min)的平均采样值; i, j 为输入、隐含层数; t 为采样时间点的中心时刻, Δt 为采样间隔; $m = 2$ 。 w_{ij}^l 为第 l 层神经元第 i 节点输入到第 j 节点的权值系数; b_j^l 为 l 层 j 节点偏置; f_l 为 l 层的激活函数。

算法测试了不同激活函数下BP神经网络预测结果的RMSE,经验证明隐含层可选用logsig或tansig函数,输出层采用purelin线性激活函数;结合计算经验,设置RMSE < 3 mm时终止训练。

2.2.1.2 BP法的神经网络训练

BP网络训练准则为输出误差平方和(以及RMSE)最小,即 $E = \frac{1}{2} \sum_{l=1}^K (d_l - o_l)^2$ 为最小,式中 l 为输出序号, d 为期望输出即监督值。学习过程利用梯度下降法调整权值,使网络输出值尽可能接近监督值;训练过程加入输入数据打乱等技巧,避免输入数据过于接近导致训练陷入局部极值。

2.2.2 RBF神经网络训练及结构

RBF神经网络包括输入层、隐含层和输出层,输入层到隐含层以径向基函数作为激活函数,隐含层到输出层通过权值线性链接。表达式为:

$$o = f_o \{ B^2 + W^2 \text{radbas}(\|P - X\|B^1) \} \quad (8)$$

式中:径向基函数(radbas)采用多元Gauss(高斯)函数; P 表示输入; X 表示函数的中心点向量; B^1 表示扩展常数的倒数向量。不同隐节点的径向基对应不同的向量和参数。中心点向量采用聚类算法初步确定,扩展常数选取聚类族群的方差值。本文首先基于聚类得到高斯函数的参数,结合输入与监督值利用最小二乘法粗略求解输出权值,再利用梯度下降微调所有参数,直到输出精度满足要求。

基于潮汐波时间序列分析,同样选择 $n = 4$ 采样点输入,避免过多数据点输入导致过拟合。隐层节点数根据训练目标精度选取,在神经网络训练过程中增加隐层节点,可无限逼近预设精度^[14-17]。网络结构为:

$$H_p(t') = f_o \left(\sum_{j=1}^h w_{j1}^2 \left(\exp \left(-\frac{1}{2\sigma_j^2} \|H^*(T - U\Delta t) - C_j\|^2 \right) \right) + b_1^2 \right) \quad (9)$$

式中: $H_p(t')$ 、 H^* 分别为预测值、分钟级平均值; i, j 分别为输入层数、隐含层数; $T = [t, t, t, t]^T$ 为输入向量中心时刻; $U = [0, 1, 2, 3]^T$ 为与中心时刻向量的时间间隔(采样周期)的倍数; Δt 为采样周期; C_j, σ_j 分别为第 j 隐层节点的激活函数即径向基函数的中心点向量和扩展常数; w_{ij}^l 为 l 层第 i 节点到下层神经元第 j 节点的权值系数; b^2 为第二层输出偏置; h 为满足神经网络输出误差需求的隐含层节点数,一般 h 与残差拟合精度正相关。输出层激活函数同样采用线性函数,即 f_o 为purelin函数。

3 神经网络与基础多项式插值海啸检测算法的预测性能比较

本节分别从常规海况和实际发生海啸两种场景下,开展潮汐波预测和海啸波检测效果对比。

3.1 海啸存在与缺失场景下的预测性能

3.1.1 无海啸场景

硬件环境: Intel(R) Core(TM) i5处理器, 4G内存, 64位 Windows 7操作系统; 软件环境: Dev C++ 5.11 搭载 32 位 GNU 科学库 (GNU Scientific Library, GSL)。训练过程见2.2.1和3.2.2小节, 采用海况正常的DART 21413站点2010年10月1日—11月30日共5 856组数据训练网络。选取评价指标为: RMSE、计算耗时、过拟合风险(Overfit Risk, O_R, 用训练集和测试集的RMSE差值表示), 结果见表1, 以此衡量3种算法对海面高度的预测效果。BP和RBF的过拟合风险数值接近且整体偏小, 过拟合风险较低; 多项式插值不存在过拟合风险, 运行较为稳定, 针对不同预测时长仅需修改少量参

表1 3种算法的性能比较

Tab.1 Comparison of the three algorithms' performance

算法	RMSE/mm	计算耗时/s	参数量	O_R/mm
多项式插值	3.216 8	0.164 3	4	—
BP	2.658 8	11.06	14	0.282 0
RBF	2.171 5	166+0.18+0.205	73	0.293 0

数,计算量较低。计算耗时和算法的计算量正相关:RBF算法训练耗时较长,聚类算法单次运算约0.2 s,输出层权重利用最小二乘法求解约为0.18 s,神

经网络训练时长约166 s;计算量从大到小排序为:RBF>BP>多项式插值。


利用上述5 856组数据训练完成的网络,对2011年1月的海面高度进行预测,统计3种算法中预测残差落在[-10 mm,10 mm)区间、绝对值大于10 mm的样本数量分布,结果见表2。3种算法中大残差区间(≥ 10 mm和 ≤ -10 mm)的样本数量为RBF<BP<多项式插值。相较于多项式插值算法,RBF算法可将大残差样本完全消除,降幅100%,BP算法中大残差样本的数量降低约70%。

表2 2011年1月预测残差区间分布样本数量统计

Tab.2 Distribution statistics of forecast residuals in January 2011

算法	残差区间										
	≤ -10	-8	-6	-4	-2	0	2	4	6	8	≥ 10
多项式插值	7	35	134	329	586	745	630	320	125	42	8
BP	4	13	68	307	675	858	678	283	64	11	1
RBF	0	2	44	311	870	1033	553	130	19	0	0

残差拟合结果显示,残差分布基本符合高斯分布特征(见图5),近似白噪声。



注:柱形对应统计数,折线对应误差出现概率

图5 预测残差直方图和高斯拟合

Fig.5 Histogram of prediction residuals and Gaussian fitting

3.1.2 日本2011年大海啸场景

使用DART 21413站点2011年3月11日日本大海啸实测数据验证报警效果。图6为海啸实际发生




图6 日本大海啸海面高度

Fig.6 Sea surface height of the great Japan tsunami

时实测海面高度,图7为3种算法的预测结果。3月11日06:15(世界时),3种算法的预测残差均超出太平洋海啸警报检测门限,触发海啸预警,该时刻之后各算法的预测值均出现偏差和异常。实验证明该套算法可有效实现海啸预警,两种神经网络算法都可以准确触发日本大海啸报警。




图7 海啸发生时(局部)和其后预测残差

Fig.7 Prediction residuals during and after a tsunami

3.2 算法稳定性

利用 DART 21413 站点 2010 年 10—11 月海平面数据训练神经网络,对 2011 年 1—12 月潮汐波开展预测;选取 2011 年 1 月、4 月、6 月、8 月、9 月、12 月数据进行测试,预测效果见图 8。两种神经网络算法的残差和 RMSE 随时间变化的相关性较弱,残差均值稳定在 $(-0.6 \text{ mm}, 0.6 \text{ mm})$ 区间内;无偏性略弱于多项式插值算法,但全年残差累加和具备趋于零的一致性。

3 种算法中, RBF 法、BP 法预测的 RMSE 均低于多项式插值法。2011 年 9 月、10 月海面高度预测 RMSE 表现为 RRB 与 BP 的差值 $\leq 0.3 \text{ mm}$, 其余 5 个月预测 RMSE 表现为 $\text{RBF} < \text{BP}$; 两种算法的全年预测性能稳定。但测试时间延长至 2014 年 12 月时, RBF 法、BP 法的参数已经不满足要求,需要重新训练;多项式插值无需重新标定参数,稳定性更优,同一站点可长期沿用同一套计算参数。

4 结论

综上所述,神经网络算法的计算复杂度为 $\text{RBF} > \text{BP} > \text{多项式插值}$, 预测精度为 $\text{RBF} > \text{BP} > \text{多项式插值}$, 相较于多项式插值, RBF 可将绝对值大于 10 mm 的大残差完全剔除(降幅 100%), BP 可降低约 70%; 稳定性则为多项式插值 $>$ 神经网络算法(RBF、BP)。本研究已完成对 RBF、BP 神经网络海啸检测算法的




图8 算法预测残差及 RMSE 比较

Fig.8 Comparison of algorithm prediction residuals and the RMSE

C 语言编程,可将算法部署至底层硬件设备中,或将神经网络参数直接写入海啸浮标底层数据算法程序;预测残差的减小可进一步提升海啸波高度反演与预测精度。

参考文献:

- [1] 任鲁川, 赵联大, 刘哲. 地震海啸危险性分析导论[M]. 北京: 科学出版社, 2022.
Ren Luchuan, Zhao Lianda, Liu Zhe. Introduction to seismic tsunami hazard analysis[M]. Beijing: Science Press, 2022.
- [2] 于福江, 原野, 王培涛. 现代地震海啸预警技术[M]. 北京: 科学出版社, 2020.
Yu Fujiang, Yuan Ye, Wang Peitao. Modern technologies in earthquake-generated tsunami Early warning[M]. Beijing: Science Press, 2020.
- [3] 阿尔弗雷德·魏格纳. 海陆的起源[M]. 王春雨, 李辰莹, 译. 西安: 陕西师范大学出版总社, 2023.
Wegener A. The origin of continents and oceans[M]. Wang Chunyu, Li Chenying, trans. Xi'an: Shaanxi Normal University General Publishing House, 2023.
- [4] 海洋地质国家重点实验室. 海底科学观测的国际进展[M]. 上海: 同济大学出版社, 2017.
State Key Laboratory of Marine Geology. International progress in seafloor observation science[M]. Shanghai: Tongji University Press, 2017.
- [5] 冯士筌, 李凤歧, 李少菁. 海洋科学导论[M]. 北京: 高等教育出版社, 1999.
Feng Shizuo, Li Fengqi, Li Shaojing. An introduction to marine science[M]. Beijing: Higher Education Press, 1999.
- [6] 王树青, 梁丙臣. 海洋工程波浪力学[M]. 青岛: 中国海洋大学出版社, 2013.
Wang Shuqing, Liang Bingchen. Wave mechanics for ocean

- engineering[M]. Qingdao: China Ocean University Press, 2013.
- [7] 蔡华阳, 欧素英, 罗向欣, 等. 海岸动力学实验[M]. 广州: 中山大学出版社, 2021.
- Cai Huayang, Ou Suying, Luo Xiangxin, et al. Coastal dynamics experiment[M]. Guangzhou: Sun Yat-sen University Press, 2021.
- [8] 国家海洋信息中心. 潮汐表[M]. 天津: 天津科学技术出版社, 2023.
- National Marine Data and Information Service. Tide table[M]. Tianjin: Tianjin Science and Technology Press, 2023.
- [9] 贾立双, 任伟, 李家军, 等. 基于海底压力测量的海啸预警方法研究[J]. 海洋技术学报, 2017, 36(3): 108-111.
- Jia Lishuang, Renwei, Li Jiajun, et al. Research on the method of tsunami pre-warning based on deep-sea pressure measurement[J]. Journal of Ocean Technology, 2017, 36(3): 108-111.
- [10] Beltrami G M. An ANN algorithm for automatic, real-time tsunami detection in deep-sea level measurements[J]. Ocean Engineering, 2008, 35(5/6): 572-587.
- [11] Chierici F, Embriaco D, Pignagnoli L. A new real-time tsunami detection algorithm[J]. Journal of Geophysical Research: Oceans, 2017, 122(1): 636-652, doi: 10.1002/2016JC012170.
- [12] Kumar T S, Manneela S. A review of the progress, challenges and future trends in tsunami Early warning systems[J]. Journal of the Geological Society of India, 2021, 97(12): 1533-1544, doi: 10.1007/s1294-021-1910-0.
- [13] Beltrami G M, Di Risio M. Algorithms for automatic, real-time tsunami detection in wind-wave measurements part I: implementation strategies and basic tests[J]. Coastal Engineering, 2011, 58(11): 1062-1071, doi: 10.1016/j.coastaleng.2011.06.004.
- [14] Martin T H, Howard B D, Mark H B. 神经网络设计[M]. 章毅, 译. 北京: 机械工业出版社, 2017.
- Martin T H, Howard B D, Mark H B. Neural network design[M]. Zhang Yi, trans. Beijing: China Machine Press, 2017.
- [15] 毕晓君. 计算智能[M]. 北京: 人民邮电出版社, 2020.
- Bi Xiaojun. Computational intelligence[M]. Beijing: Posts & Telecom Press, 2020.
- [16] 韩力群, 施彦. 人工神经网络理论及应用[M]. 北京: 机械工业出版社, 2017.
- Han Liqun, Shi Yan. Artificial neural network theory and application[M]. Beijing: China Machine Press, 2017.
- [17] 江永红. 深入浅出人工神经网络[M]. 北京: 人民邮电出版社, 2019.
- Jiang Yonghong. Artificial neural networks: from basics to applications[M]. Beijing: Posts & Telecom Press, 2019.
- [18] 魏海坤. 神经网络结构设计的理论与方法[M]. 北京: 国防工业出版社, 2005.
- Wei Haikun. Theoretical method for neural network structure design[M]. Beijing: National Defense Industry Press, 2005.
- [19] 张树京, 齐立心. 时间序列分析简明教程[M]. 北京: 清华大学出版社, 北方交通大学出版社, 2003.
- Zhang Shujing, Qi Lixin. Time series analysis[M]. Beijing: Tsinghua University Publishing House, Beijing Jiaotong University Press, 2003.
- [20] 沈培. 基于神经网络的非线性慢时变系统的数值预测研究[D]. 南京: 东南大学, 2016.
- Shen Yu. Research on numerical prediction of nonlinear slow time-varying systems based on neural network[D]. Nanjing: Southeast University, 2016.
- [21] 门爱东, 苏菲, 王雷, 等. 数字信号处理[M]. 2版. 北京: 科学出版社, 2009.
- Men Aidong, Su Fei, Wang Lei, et al. Digital signal processing [M]. 2nd ed. Beijing: Scientific Press, 2009.
- [22] 江渝, 李幸, 卓金武. MATLAB时间序列方法与实践[M]. 北京: 电子工业出版社, 2019.
- Jiang Yu, Li Xing, Zhuo Jinwu. MATLAB time series methods and practice[M]. Beijing: Publishing House of Electronics Industry, 2019.

Comparison of two neural network tsunami wave detection algorithms

ZHANG Xiaojuan, LI Guofu, LIU Jie, ZHANG Shuang, SHANG Hongmei, LIANG Jie

(National Ocean Technology Center, Tianjin 300112, China)

Abstract: This study briefly introduces the current status of tsunami detection methods; Back Propagation (BP) and Radial Basis Function (RBF) neural network detection algorithms is designed and compared, and the effectiveness of the algorithms are proved using DART data, and these prediction residuals are compared with the traditional polynomial interpolation detection algorithm, the root mean square error is used to measure the residual between predicted values and observed values. Simulation results prove that the new algorithms can reduce the root mean square error, especially reducing the number of residuals with an absolute value greater than 10 mm 90%~100%.

Key words: tsunami detection; Back Propagation neural network, Radial Basis Function neural network; time series model