

基于改进的神经网络方法的风暴潮灾害经济损失预测

赵领娣^{1,2}, 綦艳玲¹, 王小华³

(1. 中国海洋大学经济学院, 山东 青岛 266100; 2. 中国海洋大学 教育部人文社会科学重点研究基地中国海洋大学海洋发展研究院, 山东 青岛 266100; 3. 新南威尔士大学中澳海岸带管理研究中心, 澳大利亚 堪培拉 2600)

摘要: 风暴潮灾害一直以来对中国东南沿海地区的社会经济发展具有较为严重的负面影响, 是对中国造成危害最为严重的海洋灾害之一, 建立一个准确有效的损失评估模型进行风暴潮灾害损失预测, 对风暴潮灾害的预防具有重要的意义。本文在现有研究的基础上收集了 2000—2018 年中国东南沿海的琼、粤、闽、浙等省份记录较为完整的风暴潮灾害相关数据, 在综合考虑危险性、承灾体脆弱性、孕灾环境和防灾减灾能力的基础上, 建立起更为完整的风暴潮灾害损失的指标体系。相较于单一的 BP 神经网络, 本文在借鉴机器学习相关理论的基础上搭建了差分进化灰狼算法(DEGWO)优化的 BP 神经网络, 对样本进行训练和仿真测试。结果表明, 通过 DEGWO 算法优化后的模型误差更小, 数据的拟合程度更高, 对比而言, 提高了风暴潮灾害损失预测的精确性, 能够为风暴潮灾害损失预测的研究提供新的思路, 同时也为风暴潮灾害的防灾减灾管理提供了指导。

关键词: 风暴潮; 损失预测; 差分进化灰狼算法(DEGWO); BP 神经网络

中图分类号: X43 **文献标识码:** A **文章编号:** 1000-3096(2023)12-0010-11

DOI: 10.11759/hyxx20220525002

自 20 世纪 90 年代以来, 随着全球气温变暖现象的逐渐发展, 极端天气状况和灾害事件频发, 日益突出的海洋灾害风险对中国沿海地区社会经济的可持续发展产生了较为严重的负面影响, 其中影响范围最广、造成损失最大的就是风暴潮灾害。风暴潮是热带、温带气旋等风暴过境所伴随的强风和气压骤变而引起叠加在天文潮位之上的海面振荡或非周期性异常升高(降低)现象^[1]。中国领海宽阔, 海岸线绵长, 沿海城市分布广泛, 遭受风暴潮灾害尤为严重。据《中国海洋灾害公报》显示, 2011 至 2020 年中国海洋灾害造成的直接经济损失已累计达 876 亿元, 其中由风暴潮造成的损失所占比重超过 90%。因此, 做好风暴潮灾害的应对工作, 加强对风暴潮灾害损失的量化评估, 提高损失的预测水平, 对防灾减灾管理决策具有重要的意义。

国外对风暴潮灾害的研究起步较早, 美国国家飓风中心(National Hurricane Center, NHC)自十九世纪九十年代起就有对热带气旋发生路径进行追踪和预测的相关研究。随后美国又组建联邦应急管理局(Federal Emergency Management Agency, FEMA), 主要进行风暴潮灾害的预防、应急、减灾和恢复等工

作。西方国家对灾害损失评估模型的应用较成熟, 美国联邦应急管理局建立针对飓风灾害损失评估的 HAZUS—HM 模型(Hazus Hurricane Model)已被多个研究机构所采用^[2]; Powell 等提出了一种公开模型 FPHLM(Florida Public Hurricane Loss Model), 包括飓风灾害指标以及损失精算组件, 对飓风灾害损失进行预测^[3]。

近年来, 中国对风暴潮灾害损失评估的研究日益增多, 主要涵盖灾后损失和灾前损失。中国前期的损失评估研究主要集中于灾后损失和损失等级评估^[4-6]。灾后评估虽然结合了现场调查而使得数据更趋于真实, 但对于灾害发生后的处理决策具有滞后性。随着社会经济的发展与灾害防范意识的增强, 中国学者们越来越意识到预估灾害损失对防灾减灾工作的重要性, 提高了对相关研究的重视程度。灾害损失程度是危险性、脆弱性、孕灾环境和地区的防灾减灾能力^[7-8]

收稿日期: 2022-05-25; 修回日期: 2022-09-20

基金项目: 国家自然科学基金资助项目(71974176, 71473233)

[Foundation: National Natural Science Foundation of China, Nos. 71974176, 71473233]

作者简介: 赵领娣(1963—), 女, 河南武陟人, 教授, 博士生导师, 研究方向: 海洋灾害与可持续发展, E-mail: lingdizhao512@163.com

综合作用的结果,在灾前损失评估中,需要充分考虑这几个方面的指标,才能对风暴潮灾害损失有较为全面的预测。20世纪90年代以来,中国部分学者采用数理统计法、层次分析法、因子分析法、模糊数学^[9-12]等方法将危险性、孕灾环境、脆弱性相结合分析搭建评估模型,对风暴潮灾害损失进行预测。脆弱性与孕灾环境显著相关,基于它们的内在联系,学者们大都选取脆弱性来进行损失分析。浙江省水利工程院曾基于该省典型的台风风暴潮案例,针对具体地区的不同财产类型计算出风暴潮脆弱性损失矩阵^[13];同时也有学者通过脆弱性指数来划分风暴潮灾害脆弱性等级^[14]。在防灾减灾能力方面,较少有学者能同时将防灾减灾能力的定量分析也考虑到风暴潮灾害损失的预测中,而是更多集中在对泥石流、洪涝^[15-16]等灾害的防灾减灾综合指标评估的研究。综上所述,在考虑损失相关因子方面,更多的研究是将风暴潮灾害损失与单一的危险性或脆弱性联系起来,对孕灾环境和防灾减灾能力角度的分析有所忽视,这使得预测模型具有一定局限性,难以更加全面地呈现损失预测结果,从而可能与实际损失产生较大的误差。因此能够综合考虑危险性、脆弱性、孕灾环境和防灾减灾能力等与灾害损失的相关关系,建立损失评估较为全面的指标体系对风暴潮灾害损失的预测研究尤为重要。

在损失预测方法方面,传统的方法是依据已发生损失的历史资料,采用合理的统计模型来进行分析预测^[17];此外,还有学者建立起风暴潮灾害的致灾因子与经济损失之间的关系,利用灾害强度指数来建立与直接经济损失的拟合方程,主要包括线性回归法、多项式曲线法、对数法、指数法等^[4]。但是研究表明通过这些传统方法进行的损失评估所得到的结果往往误差较大。因此逐渐有学者开始将反向传播(Back Propagation, BP)、径向基函数(Radial basis function, RBF)等不同的机器学习算法应用到灾前损失预测的研究中^[18-21]。这些研究的结果一定程度上反映了机器学习方法在损失预测中的可行性,为风暴潮灾害的损失预测提供了新的思路和研究基础。而简单的BP神经网络模型自身仍存在缺陷,结构不够稳定,易陷入局部最优,也更易受到数据不完整的影响,因此在预测的精准性方面还有待提高。

鉴于此,本文综合考虑危险性、承灾体脆弱性、孕灾环境和防灾减灾能力与灾害损失的相关关系,建立起较为完整科学的损失评估指标体系,同时借鉴机器学习的理论搭建差分进化灰狼算法改进的BP

神经网络模型,通过差分进化灰狼算法优化BP网络的权、阈值,使网络结构更加稳定,并提高了全局搜索能力,进一步增强了损失预测的精准性,为风暴潮灾害损失的预测提供了新的研究思路。

1 资料来源与处理

1.1 数据来源

中国东南沿海地区台风登陆频繁,受到风暴潮的侵袭严重,而该地区又是人口密集且经济较为发达的地区,因此往往在历次风暴潮灾害中遭受较大的损失。本文系统收集了东南沿海地区历年来风暴潮灾害较为严重的浙江、福建、广东、海南四个省份的2000—2018年发生的台风风暴潮灾害数据,整理发现虽然此期间风暴潮过程发生次数较多,但有部分风暴潮过程并未造成灾害,还有较多风暴潮灾害过程造成损失较小,发生年份较早等原因,对其损失统计较为笼统,大部分仅涉及直接经济损失值,而如农田受灾面积、水产养殖受灾面积、房屋与船只损毁等并没有具体统计。除此之外各省份海洋灾害公报中的损失统计选取的指标也并不完全一致。基于此,本文从其中选取了44组各损失指标记录较为完整的台风风暴潮灾害数据作为样本进行分析。数据资料主要来源于《中国海洋灾害公报》^[22]、各省份历年海洋灾害公报以及各省份历年统计年鉴^[23-29]、《中国风暴潮灾害史料集》^[30]。

1.2 指标体系的建立

中国的风暴潮灾害损失评估指标体系还没有形成较为统一的确立标准。有学者主要针对统计的承灾体灾情指标对风暴潮灾害的直接或间接经济损失进行评估,核心指标主要选取死亡及失踪人口数、农田受灾面积、海水养殖受灾面积、房屋与船只损毁、海岸工程损毁等,指标体系层次较为单一^[11]。随着该问题研究的不断深入,学者们开始将致灾因子与灾情联系起来,在指标体系的搭建中综合分析风暴潮灾害的成灾机制,将最大风速与中心最低气压等危险性指标考虑在内^[31]。但风暴潮灾害的损失程度是各方面因素综合作用的结果,除了危险性与承灾体的脆弱性直接关系到风暴灾害的损失,孕灾环境与地区的防灾减灾能力也是影响损失的重要因素^[8]。综合考虑危险性、承灾体脆弱性、孕灾环境、防灾减灾能力与风暴潮灾害的相关关系,建立起较为合理、完整的指标体系更有利于风暴潮灾害损失的预测评估。基于此,本文依据自然灾害损失评估的相关理论^[32]及指标选取原则,

从危险性、承灾体的脆弱性、孕灾环境、防灾减灾能力等4个角度选取相应指标因子来建立风暴潮灾害损失评估的指标体系(图1)。

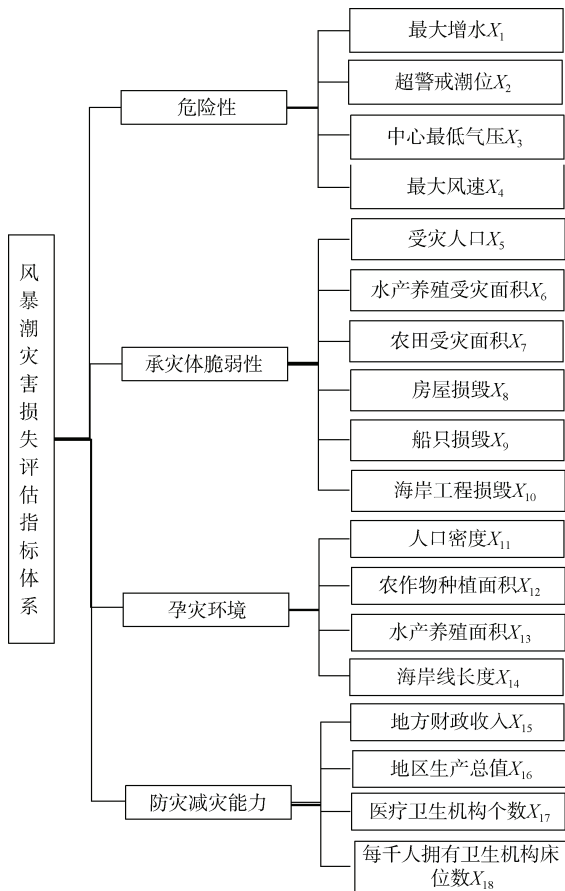


图1 风暴潮灾害损失评估指标体系

Fig. 1 Storm surge disaster loss assessment index system

(1)危险性。风暴潮的危险性主要在于风暴潮的变化过程,可能造成人员伤亡,或造成财产损失、环境破坏,包括天文潮、风暴增(减)水、近岸海浪及漫滩淹没等要素的危险性大小及其综合^[33]。在此选取最大风暴潮增水、超警戒潮位、中心最低气压、台风登陆的最大风速4个指标。

(2)承灾体脆弱性。风暴潮灾害的承灾体包括受到其影响和损害的人、物以及其他各种社会资源,例如人的生命安全、房屋、船只、码头、堤坝、种植作物及养殖产品等^[34]。随着国家灾害预报能力和救援能力的增强及社会安全意识的提高,由风暴潮灾害所导致的死亡与失踪人数已连续多年为0,因此该指标在此不考虑。根据数据的可获得性,本文选取受灾人口、水产养殖受灾面积、农田受灾面积、房屋损毁、船只损毁、海岸工程损毁共6个指标。

(3)孕灾环境。孕灾环境主要包括人文与自然环 境,人文环境方面主要体现的是中国东南沿海地区人口密集程度、农田的种植以及水产养殖的发展,选取人口密度、农田种植面积、水产养殖面积三个指标。在自然环境方面主要是指地形地貌等因素,选取海岸线长度指标。

(4)防灾减灾能力。防灾减灾能力包括灾前的防灾工程建设以及灾害后的恢复,这在很大程度上受到当地的社会经济发展以及公共设施建设的影响。综合考虑与防灾减灾能力的联系以及数据的完整性,本文选取地方财政收入、地区生产总值、医疗卫生机构个数以及每千人拥有卫生机构床位数等指标。

1.3 数据预处理

由于风暴潮灾害损失所涉及的相关指标较多,并且这些指标因子与损失的联系程度各不相同。为了排除冗余信息,使数据信息更为有效,需要对指标因子进行进一步的筛选。在对指标体系的处理中有学者曾采用模糊数学^[35]、层次分析^[36]等方法来分配权重,但是隶属度函数的确定以及层次分析决策中用到的专家打分方法都在一定程度上依赖于决策者的经验判断,而具有较强的主观性。因此本文采用熵值法来对风暴潮灾害损失的各项指标进行赋权^[37]。熵值法借鉴了信息熵的思想,能够根据指标的相对变化程度对整体的影响算出不同指标的权重,权重值越大,贡献度越高,以此筛选出在风暴潮灾害损失中占比较重的指标因子,作为模型的输入变量。相较于层次分析等赋权方法,熵值法不涉及人为的因素,因此更为客观。分析步骤如下:

(1)数据标准化

由于统计的各类指标其计量单位有所不同,在进行模型计算前,需先要对各指标的原始数据作归一化处理:

$$z_{ij} = \frac{x_{ij} - \min(x_j)}{\max(x_j) - \min(x_j)}, (i=1, 2, \dots, m, j=1, 2, \dots, n). \quad (1)$$

式中: z_{ij} 为归一化后第 i 个样本的第 j 个指标的数值; x_{ij} 为原始值, $\max(x_j)$ 、 $\min(x_j)$ 分别为该指标的最大值和最小值。

(2)计算在第 j 项指标下第 i 个样本所占的比重:

$$p_{ij} = \frac{y_{ij}}{\sum_{i=1}^m y_{ij}}, (i=1, 2, \dots, m, j=1, 2, \dots, n). \quad (2)$$

(3)计算第 j 项指标的熵值 e_j :

$$e_j = -k \sum_{i=1}^m P_{ij} \ln(P_{ij}). \quad (3)$$

式中: $k = \frac{1}{\ln(m)} > 0$, 满足 $e_j \geq 0$;

(4) 计算 j 指标的信息熵冗余度 d_j :

$$d_j = 1 - e_j. \quad (4)$$

(5) 计算各指标的权重值 w_j :

$$w_j = \frac{d_j}{\sum_{j=1}^n d_j}. \quad (5)$$

通过上述过程, 对指标进行赋权, 结果如表 1 所示。

表 1 指标因子的熵值、信息熵冗余度以及权重值
Tab. 1 Entropy value, information entropy redundancy and weight value of each index factor

因子	熵值 e_j	信息冗余度 d_j	权重 w_j
X_1	0.954 2	0.045 8	0.015 1
X_2	0.890 2	0.109 8	0.036 2
X_3	0.977 1	0.022 9	0.007 5
X_4	0.968 1	0.031 9	0.010 5
X_5	0.875 3	0.124 7	0.041 1
X_6	0.853 6	0.146 4	0.048 3
X_7	0.789 8	0.210 2	0.069 3
X_8	0.193 7	0.806 3	0.265 9
X_9	0.842 4	0.157 6	0.052 0
X_{10}	0.764 0	0.236 0	0.077 8
X_{11}	0.926 0	0.074 0	0.024 4
X_{12}	0.354 5	0.645 5	0.212 9
X_{13}	0.956 4	0.043 6	0.014 4
X_{14}	0.982 6	0.017 4	0.005 7
X_{15}	0.885 3	0.114 7	0.037 8
X_{16}	0.904 1	0.095 9	0.031 6
X_{17}	0.914 3	0.085 7	0.028 3
X_{18}	0.935 9	0.064 1	0.021 1

由上述熵值法计算结果可知, 指标权重值由大到小排序前 10 的因子的贡献率已超过 87%, 由此, 最终选取房屋损毁 X_8 、农作物种植面积 X_{12} 、海洋工程损毁 X_{10} 、农田受灾面积 X_7 、船只损毁 X_9 、水产养殖受灾面积 X_{13} 、受灾人口 X_5 、超警戒潮位 X_2 、地方财政收入 X_{15} 、地区生产总值 X_{16} 等 10 个指标作为模型的输入变量。

2 研究方法

2.1 BP 神经网络原理

上世纪八十年代中期, David Runelhart 等人^[38]提

出了以反向误差算法来进行误差校正的一种多层前馈网络, 其计算过程包括正向计算过程和反向计算过程两个部分, 通过这两个过程的交替反复训练学习, 使得最终获取结果满足一定的误差要求^[39]。BP 网络模型通常由三部分结构组成, 即输入层、隐含层和输出层(图 2), 隐含层可以为单或多层, 每一层有若干节点, 其层数和神经元个数可以视具体情况设定。BP 神经网络从输入层到输出层是正向传递, 输入的特征值经过隐含层的计算后输出为预测值, 若输出的预测值并不能达到预先设定的精度, 则会将预测值与对应数据进行比较并计算出相应的误差。误差计算完成后原路返回不断向前一层传播, 将此信号分散给各层节点, 以此为依据调整权值和阈值, 形成反向传播过程, 通过这样的过程反复训练, 直到实现期望结果。

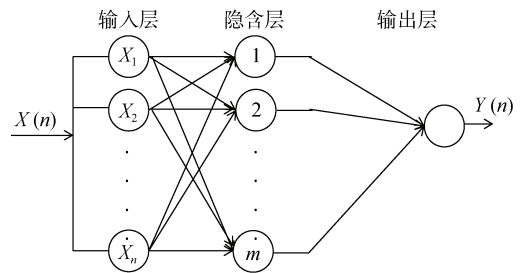


图 2 BP 神经网络单隐含层结构图

Fig. 2 Structure of BP neural network with single implicit layer

假设 n_l 表示第 l 层神经元的个数, $f(\cdot)$ 表示激活函数, $W^{(l)}$ 为权重矩阵, $W_{ij}^{(l)}$ 表示 $l-1$ 层 j 个神经元到 l 层 i 个神经元的权重, $b^{(l)}$ 为 $l-1$ 到 l 层的偏置, $z^{(l)}$ 表示神经元状态, $a^{(l)}$ 为 l 层神经元的输出值, 则

$$z^{(l)} = W^{(l)} a^{(l-1)} + b^{(l)}, \quad (6)$$

$$a^{(l)} = f(z^{(l)}). \quad (7)$$

以均方误差作为损失函数:

$$E = \frac{1}{2} \|a^{(l)} - y\|^2. \quad (8)$$

$a^{(l)}$ 为训练样本实际输出, y 为期望输出。

输出层梯度计算:

$$\delta^{(l)} = (a^{(l)} - y) \odot f'(z^{(l)}), \quad (9)$$

$$\frac{\partial E}{\partial w_{ij}^{(l)}} = \delta_i^{(l)} a_j^{(l-1)}, \quad (10)$$

$$\frac{\partial E}{\partial b_i^{(l)}} = \delta_i^{(l)}. \quad (11)$$

隐含层梯度计算:

$$\delta^{(l)} = \left[\left(W^{(l+1)} \right)^T \delta^{(l+1)} \right] \odot f' \left(z^{(l)} \right), \quad (12)$$

$$\frac{\partial E}{\partial w_{ij}^{(l)}} = \delta_i^{(l)} a_j^{(l-1)}, \quad (13)$$

$$\frac{\partial E}{\partial b_i^{(l)}} = \delta_i^{(l)}. \quad (14)$$

2.2 DEGWO 算法原理

灰狼算法(Grey Wolf Optimizer, GWO)是在 2014 年提出的一种元启发式算法,主要模拟了灰狼群体的捕食活动,该算法的优化过程包含了灰狼的社会等级分层、跟踪、包围和攻击猎物等步骤^[40]。GWO 算法收敛性能更强,调整参数较少,但是在解决复杂问题时却容易出现陷入局部极值的问题。差分进化算法(Differential Evolution, DE)作为一种模拟生物进化的算法,能够通过变异、交叉和选择使种群不断进化,借鉴此思想,将 DE 算法与 GWO 算法相结合,形成差分进化灰狼算法(DEGWO),从而弥补 GWO 算法的缺陷,增强全局搜索能力。其过程主要通过 DE 算法的交叉、选择操作维持种群的多样性,并将其作为 GWO 算法的初始种群计算目标函数值,选出最优的三个个体 α 、 β 、 δ , 据此更新其他灰狼个体的位置,然后利用 DE 的交叉和选择操作更新所有灰狼位置,反复迭代直至选出最优目标值^[41]。




图 3 灰狼社会等级分层
Fig. 3 Social hierarchy of GWO

算法的具体实施步骤及流程:

(1)设置差分进化算法各项参数,种群规模 N , 最大迭代次数 t_{\max} , 搜索范围 ub 、 lb , 交叉概率 CR , 缩放因子 F 范围, 搜索维数 D 。

(2)初始化参数 a , A 和 C , 通过变异、选择操作初始化灰狼种群。

(3)计算灰狼个体的目标函数值,并选出最优个体: α 、 β 、 δ 。

(4)计算其他灰狼与 α 、 β 、 δ 距离并更新位置。

(5)更新参数 a , A 和 C 的值,对个体位置进行交叉操作,选择产生新个体并计算目标函数值。

(6)更新 α 、 β 、 δ 的位置。

(7)判断是否达到最大迭代次数 t_{\max} , 若是,即结束算法并输出最优解 α 值, 否则, 回到(3)继续执行。

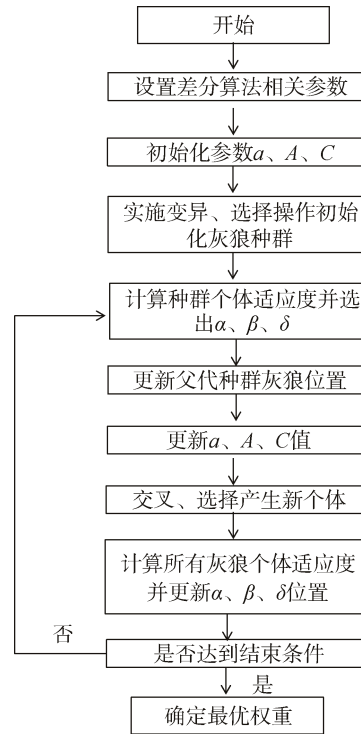


图 4 DEGWO 算法流程
Fig. 4 Flowchart of the DEGWO

2.3 DEGWO-BP 神经网络模型

BP 网络的结构较为简单,训练过程是依靠对权值和阈值的不断调整,无需另设参数。虽然这种结构操作简单,但是也增加了初始权值阈值对模型性能的影响,如果仍以随机化的方式来获取初始权值、阈值,训练结果将难以避免地产生易陷入局部最优等缺陷。基于此,本文利用 DEGWO 算法进行寻优,将该算法输出的值作为 BP 神经网络的初始权、阈值,形成 DEGWO-BP 训练模型,以进一步提升网络性能,克服标准 BP 神经网络通过随机化初始权值和阈值所形成的稳定性差、易陷入局部最优等问题。

模型搭建过程如下:

(1)利用熵值法对数据进行预处理后,筛选出输入层的特征值,并将样本数据划分训练集与测试集。

(2)设置 BP 网络结构隐含层数、神经元个数、最大迭代次数、目标误差值、学习率等相关参数。

(3)搭建 DEGWO 算法,确定最优初始权值和阈值并进行赋值。

- (4)将训练集作为输入层导入网络中进行训练,以直接经济损失为唯一输出值。
- (5)测试集进行性能测试。

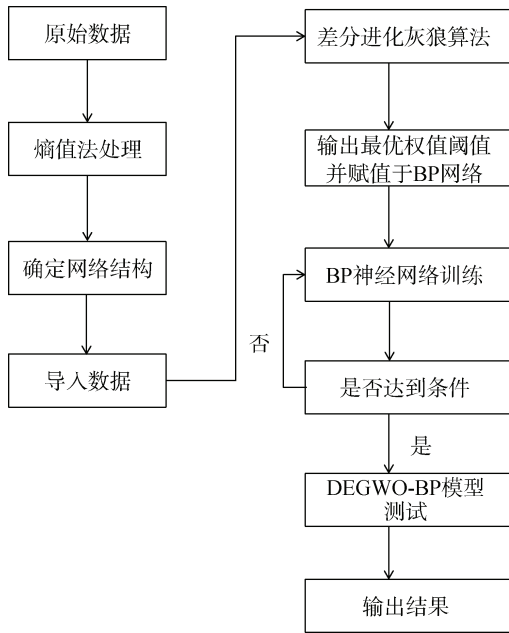


图5 DEGWO-BP模型
Fig.5 DEGWO-BP model

3 结果分析

本文总样本为数据集内 44 个记录较为完整风暴潮灾害,由于样本量较小,在此将其划分为两个互斥的集合即训练集(4 个样本)和测试集(40 个样本),使用训练集的数据来对模型进行训练,以测试集来验证模型效果,将测试集计算的误差近似作为现实场景中的泛化误差。同时,本文以相对误差 E_i 和决定系数 R^2 作为性能评估指标,其计算公式如下:

$$E_i = \frac{|y'_i - y_i|}{y_i}, (i=1, 2, \dots, n). \quad (15)$$

$$R^2 = \frac{\left(n \sum_{i=1}^n y'_i y_i - \sum_{i=1}^n y'_i \sum_{i=1}^n y_i \right)^2}{\left[n \sum_{i=1}^n y_i'^2 - \left(\sum_{i=1}^n y'_i \right)^2 \right] \left[n \sum_{i=1}^n y_i^2 - \left(\sum_{i=1}^n y_i \right)^2 \right]}. \quad (16)$$

其中: y'_i 与 y_i 分别代表第 i 个样本的预测值和真实值; n 为总样本量; 在这两项指标中, E_i 越小、 R^2 在其范围内越趋于 1, 模型性能越好; 反之, 模型性能越差。

本文以 MATLAB 2019a 为平台, 搭建模型中的 BP 神经网络部分, 函数定义为 `net=newff(inputn, outputn, hiddennum, {'tansig', 'purelin'}, 'trainlm')`, 其

中参数分别为输入值、输出值、隐含层神经元个数、输入层与输出层传递函数、训练函数。损失函数(MSE, 记为 E_{MS}):

$$E_{MS} = \frac{\sum_{i=1}^n (y_i - y'_i)^2}{n}. \quad (17)$$

y'_i 为第 i 个样本的预测值; y_i 为第 i 个样本的真实值; n 为总样本量。训练次数 epochs=1 000, 学习速率为 0.1, 训练目标最小误差 0.000 01。输入层节点数依据前文由熵值法确定的输入变量数目 $m=10$, 输出层节点数 $n=1$, 隐含层为 1。隐含层神经元个数根据公式 $h = \sqrt{(m+n)} + a, a \in [1, 10]$ 计算为 [4, 14]。为提高预测的准确性, 在实验过程中将取值范围扩大到 [3, 20], 通过模型多次运行, 依次计算每个神经元数目下的 MSE 值, 选取该值最小的节点即为最优的节点值。通过寻优设置隐含层神经元个数为 12, 寻优结果如图 6。文中搭建的差分进化灰狼算法, 其搜索维度由 $D = m \cdot h + n \cdot h + h + n$ 计算得 $D=145$, 本文的搜索结构并不复杂, 初始种群数量为设置为 10, 最大迭代次数 $t_{max}=50$, 通过图 7 的适应度变化曲线可以看出, DEGWO 算法优化的 BP 模型收敛速度较快。




图6 隐含层节点数寻优结果
Fig.6 Hidden layer node number optimization

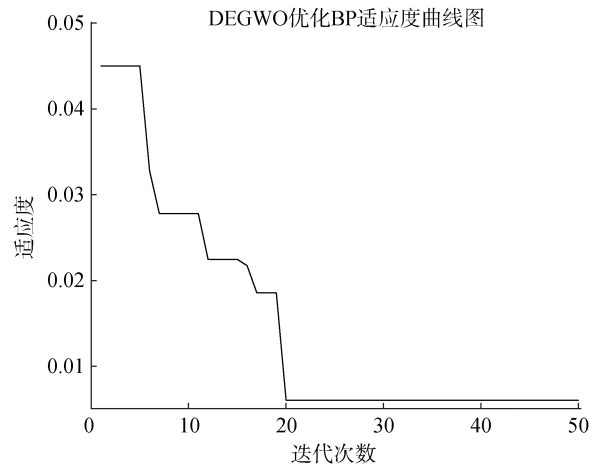


图7 DEGWO-BP神经网络适应度
Fig.7 Fitness of a DEGWO-BP neural network

图 8、图 9、图 10 分别为 BP 模型、DEGWO-BP 模型训练集与测试集的拟合结果。从图中可以发现,在拟合效果上无论是训练集还是测试集,相较于优化前的 BP 神经网络,经过差分进化灰狼算法优化的模型预测曲线更趋近于真实值,并且测试集中 DEGWO-BP 模型优于 BP 模型更为明显。由 DEGWO 算法优化过的 BP 神经网络中训练集的预测除了个别值外,大多数都能够贴和真实值,拟合程度整体较高。

为了更具体地对比改进后的 DEGWO-BP 回归预测模型是否在风暴潮灾害损失预测方面更具有优越性,本文将其与未改进前的 BP 神经网络模型,分别从训练集与测试集的相对均值误差以及决定系数 R^2 两个角度进行比较,结果如表 2 所示。




图 8 基于 BPNN 的风暴潮灾害损失训练集预测

Fig. 8 Prediction results of storm surge disaster loss training set based on the BP neural network

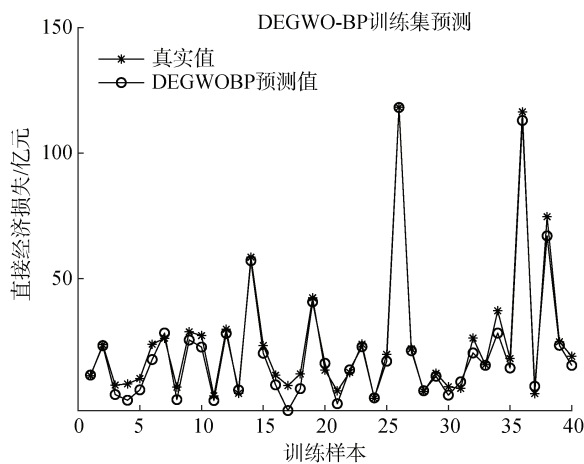


图 9 基于 DEGWO-BP 的风暴潮灾害损失训练集预测

Fig. 9 Prediction results of storm surge disaster loss training set based on the DEGWO-BP neural network




图 10 测试集预测结果对比

Fig. 8 Test set prediction results comparison

表 2 改进前后结果比较

Tab. 2 Result comparison before and after improvement

算法	相对误差均值		决定系数 R^2	
	测试集	训练集	测试集	训练集
DEGWO-BP	0.181	0.269	0.933 65	0.985 78
BP	0.398	0.350	0.759 38	0.954 08

表 2 结果显示,未改进的 BP 模型相对误差均值较大,而经过 DEGWO 算法优化的 BP 神经网络其测试集和训练集的相对误差均值分别为 0.181 和 0.269,均明显优于简单的 BP 神经网络。比较决定系数发现,仍是 DEGWO-BP 神经网络的训练效果最好,其测试集和预测集的决定系数分别为 0.933 65 和 0.985 78,拟合程度较高,相较而言对原始数据的拟合效果最好。

表 3 不同算法结果比较

Tab. 3 Comparison of the results from different algorithms

算法	相对误差均值		决定系数 R^2	
	测试集	训练集	测试集	训练集
DEGWO-BP	0.181	0.269	0.933 65	0.985 78
RBF	0.564	0.786	0.624 53	0.716 25
GA-BP	0.432	0.756	0.738 70	0.727 67

近年来有学者将神经网络方法应用到灾害损失的预测中,为了进一步说明 DEGWO-BP 神经网络在风暴潮灾害损失预测上的有效性,本文选择将其与部分学者在相关研究中应用过的 RBF 神经网络模型和遗传算法(Genetic Algorithm, GA)优化的 BP 模型(GA-BP)进行比较。RBF 神经网络是包含单隐藏层的三层前馈神经网络,其基本思想是利用其隐藏层空间,对低维输入矢量通过投影将数据转化到

高维空间,使其在高维空间线性可分,其激活函数设置为:

$$R(x_p, c_i) = \exp\left(-\frac{1}{2\sigma^2} \|x_p - c_i\|^2\right), i=1, 2, \dots, m. \quad (18)$$

x_p 为第 p 个输入样本, c_i 为第 i 个中心点, σ 表示围绕中心点的宽度, m 为隐含层节点数^[19]。实验过程中使用 MATLAB 平台的 nwerb 函数建立 RBF 神经网络, 设定误差目标为 0.001, 最大隐含节点个数 40, 扩展速度为 1, 两次显示之间添加神经元个数为 1。遗传算法(GA)是模拟自然选择和遗传学机理的生物进化过程的计算模型, 其根据问题的目标函数构造一个适值函数, 对一个由多个解构成的种群进行评估、遗传运算、选择, 经过多代繁殖, 获得适应值最好的个体作为问题最优解^[42]。通过实验确定 GA 算法的初始种群规模为 10, 最大迭代次数 100, 交叉概率 0.8, 遗传概率 0.1, BP 网络部分网络结构设置为 10-13-1, 其余参数与前述 BP 模型设置一致。

通过将 DEGWO-BP 模型预测性能与不同的神经网络模型(RBF)及不同的优化算法(GA-BP)进行比较, 从表 3 可以看出, 不仅在相对误差均值方面 DEGWO-BP 模型(0.181)的表现优于 RBF 模型(0.564)和 GA-BP 模型(0.432), 在决定系数的对比中, DEGWO-BP 模型(0.933 65)的拟合程度也更高于 RBF 模型(0.624 53)和 GA-BP 模型(0.738 70)。

根据上述结果, DEGWO-BP 神经网络模型在风暴潮灾害损失预测方面更为适用, 能够克服简单的 BP 神经网络常见的稳定性差、易陷入局部最优等问题, 对风暴潮灾害损失预测的精确度也有了进一步提高。

4 结论

风暴潮灾害一直是对中国危害最为严重的海洋灾害之一, 对风暴潮灾害的防灾减灾管理密切关系到中国沿海地区的社会经济的可持续发展。本文通过搭建 DEGWO-BP 神经网络模型来致力于提高风暴潮灾害损失的预测能力。通过研究, 得出以下结论:

(1)差分进化灰狼算法(DEGWO)优化的 BP 神经网络预测模型对风暴潮灾害损失的预测精度较高。本文首先搭建了较为完整的风暴潮灾害损失评估指标体系, 根据指标收集相应数据并进行预处理, 最终根据权重确定了对风暴潮灾害损失影响较大的 10 个因子作为输入变量。随后利用 DEGWO 算法获取 BP 神经网络的最优初始权、阈值, 搭建起 DEGWO-

BP 神经网络模型进行训练。优化后的 DEGWO-BP 模型克服了 BP 算法极易陷入局部最优的缺陷, 在风暴潮灾害直接经济损失预评估方面, 对比其他模型精度明显提高。

(2)本研究为风暴潮灾害损失的评估提供了新的思路但尚存在不足。本文搭建的 DEGWO-BP 模型能够进一步提高损失评估的可靠性, 为风暴潮等相关灾害损失预测提供了一定参考。但是, 由于目前在海洋灾害损失方面可收集的完整数据仍然较少, 用来进行样本训练和测试的样本有限, 灾害损失的预测精准度仍有提高空间, 今后将进一步加强对相关数据的收集和处理。

参考文献:

- [1] 冯士筌. 风暴潮导论[M]. 北京: 科学出版社, 1982.
LIN W H, CHEN L Q, YU W, et al. Radioactivity impacts of the Fukushima Nuclear Accident on the atmosphere[J]. Atmospheric Environment, 2015, 102: 311-322.
- [2] POWELL M, SOUKUP G, COCKE S, et al. State of Florida hurricane loss projection model: Atmospheric science component[J]. Journal of Wind Engineering and Industrial Aerodynamics, 2005, 93(8): 651-674.
- [3] 许启望, 谭树东. 风暴潮灾害经济损失评估方法研究[J]. 海洋通报, 1998, 17(1): 1-12.
XU Qiwang, TAN Shudong. Research on the method of evaluating the economic loss caused by storm, surge disaster[J]. Marine Science Bulletin, 1998, 17(1): 1-12.
- [4] 石先武, 刘钦政, 王宇星. 风暴潮灾害等级划分标准及适用性分析[J]. 自然灾害学报, 2015, 24(3): 161-168.
SHI Xianwu, LIU Qinzeng, WANG Yuxing. Gradation criteria of storm surge disaster and their applicability analysis[J]. Journal of Natural Disaster, 2005, 24(3): 161-168.
- [5] 肖茹水, 郭佩芳, 解晓茹. 风暴潮灾害损失评估研究综述[J]. 海洋湖沼通报, 2021, 43(2): 67-73.
XIAO Rushui, GUO Peifang, XIE Xiaoru. Theoretical research of storm surge loss assessment[J]. Transactions of Oceanology and Limnology, 2021, 43(2): 67-73.
- [6] 袁艺. 自然灾害灾情评估研究与实践进展[J]. 地球科学进展, 2010, 25(1): 22-32.
YUAN Yi. Advances in the assessment of natural disaster situation[J]. Advances in Earth Science, 2010, 25(1): 22-32.
- [7] 郭腾蛟, 李国胜. 基于验证性因素分析的台风风暴潮灾害经济损失影响因子优化分析[J]. 自然灾害学报, 2020, 29(1): 123-130.
GUO Tengjiao, LI Guosheng. The optimal analysis of the impact factors of economic losses due to typhoon

- storm surge based on confirmatory factor analysis[J]. *Journal of Natural Disasters*, 2020, 29(1): 123-130.
- [8] 郑慧, 赵昕. 海洋灾害经济损失的模糊测定——以风暴潮为例[J]. *中国渔业经济*, 2009, 27(4): 105-109.
ZHENG Hui, ZHAO Xin. Fuzzy assessment of economic loss by marine disaster——a case study of storm tide disaster[J]. *Chinese Fisheries Economics*, 2009, 27(4): 105-109.
- [9] 孙瑞杰, 赵昕. 基于因子分析的沿海地区海洋灾害损失评价——以风暴潮为例[J]. *海洋通报*, 2010, 29(6): 697-701.
SUN Ruijie, ZHAO Xin. Appraisal of ocean disaster losses of coastal area based on the factor analysis——a case study of storm surge disaster[J]. *Marine Science Bulletin*, 2010, 29(6): 697-701.
- [10] 殷克东, 韦茜, 李兴东. 风暴潮灾害社会经济损失评估研究[J]. *海洋环境科学*, 2012, 31(6): 835-837, 842.
YIN Kedong, WEI Qian, LI Xingdong. The evaluation techniques of the socio-economic loss caused by storm surge disaster[J]. *Marine Environmental Science*, 2012, 31(6): 835-837, 842.
- [11] 王志强, 陈思宇, 吕雪峰, 等. 风暴潮灾害受灾人口与直接经济损失评估方法研究进展[J]. *北京师范大学学报(自然科学版)*, 2015, 51(3): 58-63.
WANG Zhiqiang, CHEN Siyu, LV Xuefeng, et al. A review on evaluating hazard-affected population and direct economic losses by storm surge[J]. *Journal of Beijing Normal University (Natural Science)*, 2015, 51(3): 58-63.
- [12] 浙江省水利河口研究院. 浙江省水利工程防洪减灾能力评估[R]. 杭州: 浙江省水利河口研究院, 2007.
Zhejiang Institute of Hydraulics & Estuary. Zhejiang hydraulic engineering flood control and disaster mitigation capacity assessment[R]. Hangzhou: Zhejiang Institute of Hydraulics & Estuary, 2007.
- [13] 石先武, 谭骏, 国志兴, 等. 风暴潮灾害风险评估研究综述[J]. *地球科学进展*, 2013, 28(8): 866-874.
SHI Xianwu, TAN Jun, GUO Zhixing, et al. A review of risk assessment of storm surge disaster[J]. *Advances in Earth Science*, 2013, 28(8): 866-874.
- [14] 舒和平, 齐识, 宁娜, 等. 甘肃省南部武都区泥石流灾害风险评价研究[J]. *自然灾害学报*, 2016, 25(6): 34-41.
SHU Heping, QI Zhi, NING Na, et al. Risk assessment of debris flow disaster: a case study of Wudu District in the south of Gansu Province, China[J]. *Journal of Natural Disasters*, 2016, 25(6): 34-41.
- [15] 龚艳冰, 向林, 刘高峰. 基于高斯过程回归模型的洪涝灾害损失预测研究——以重庆市为例[J]. *长江流域资源与环境*, 2019, 28(6): 1502-1510.
GONG Yanbing, XIANG Lin, LIU Gaofeng. Study on flood disaster loss prediction based on gaussian process regression model: a case study of Chongqing city[J]. *Resources and Environment in the Yangtze Basin*, 2019, 28(6): 1502-1510.
- [16] 孙绍聘. 灾害评估研究内容与方法探讨[J]. *地理科学进展*, 2001, 20(2): 122-130.
SUN Shaocheng. A study on the contents and methods of disaster assessment[J]. *Progress in Geography*, 2001, 20(2): 122-130.
- [17] 叶小岭, 梁伟, 邓华. 基于主成分分析及RBF神经网络的浙江省台风灾害损失预测[J]. *科技通报*, 2014, 30(9): 13-19.
YE Xiaoling, LIANG Wei, DENG Hua. Forecasting of typhoon disaster loss of Zhejiang Province based on principal component analysis and RBF neural network model[J]. *Bulletin of Science and Technology*, 2014, 30(9): 13-19.
- [18] 杨雪雪, 刘强. 基于KPCA-RBF模型的风暴潮灾害经济损失预测[J]. *海洋科学*, 2021, 45(10): 32-39.
YANG Xuexue, LIU Qiang. Economic loss assessment of storm-surge disasters based on the KPCA-RBF model[J]. *Marine Sciences*, 2021, 45(10): 32-39.
- [19] 林江豪, 阳爱民. 基于BP神经网络和VSM的台风灾害经济损失评估[J]. *灾害学*, 2019, 34(1): 22-26.
LIN Jianghao, YANG Aimin. Economic loss assessment of typhoon based on BP neural network and VSM[J]. *Journal of Catastrophology*, 2019, 34(1): 22-26.
- [20] 郝婧, 刘强. 基于SSA-ELM模型的台风风暴潮灾害损失预评估[J]. *海洋科学*, 2022, 46(2): 55-63.
HAO Jing, LIU Qiang. Pre-assessment of typhoon storm surge disaster loss based on SSA-ELM model[J]. *Marine Sciences*, 2022, 46(2): 55-63.
- [21] 中华人民共和国自然资源部. 2000—2018年中国海洋灾害公报[EB/OL][2021-04-27]. <http://www.mnr.gov.cn/sj/sjfw/hy/gbfg/zghyzhgb/>.
Ministry of Natural Resources of the People's Republic of China. 2000-2018 China marine disaster bulletin [EB/OL] [2021-04-27]. <http://www.mnr.gov.cn/sj/sjfw/hy/gbfg/zghyzhgb/>.
- [22] 广东省自然资源厅. 2013—2018年广东省海洋灾害公报[EB/OL][2021-04-27]. http://nr.gd.gov.cn/gdlr_notice/2/content/post_2644380.html.
Department of Natural Resources of Guangdong Province. 2013-2018 Guangdong marine disaster bulletin [EB/OL] [2021-04-27]. http://nr.gd.gov.cn/gdlr_notice/2/content/post_2644380.html.
- [23] 广东省统计局. 广东统计年鉴[EB/OL][2021-04-27]. <http://stats.gd.gov.cn/gdtjnj/>.
Guangdong Provincial Bureau of Statistics. Guangdong statistical yearbook[EB/OL] [2021-04-27]. <http://stats.gd.gov.cn/gdtjnj/>.
- [24] 福建省海洋与渔业局. 2011—2018年福建省海洋灾

- 害公报[EB/OL] [2021-04-27]. <https://hyyyj.fujian.gov.cn/xxgk/tzgg/>.
Fujian Provincial Bureau of Oceanography and Fisheries. 2011-2018 Fujian marine disaster bulletin [EB/OL] [2021-04-27]. <https://hyyyj.fujian.gov.cn/xxgk/tzgg/>.
- [25] 福建省统计局. 福建统计年鉴[EB/OL] [2021-04-27]. <https://tjj.fujian.gov.cn/xxgk/ndsjs/>.
Fujian Provincial Bureau of Statistics. Fujian statistical yearbook[EB/OL] [2021-04-27]. <https://tjj.fujian.gov.cn/xxgk/ndsjs/>.
- [26] 浙江省自然资源厅. 2011—2018 年浙江省海洋灾害公报 [EB/OL] [2021-04-27]. <https://zjoccean.org.cn/oceanswindow/bulletin>.
Department of Natural Resources of Zhejiang Province. 2011-2018 Zhejiang marine disaster bulletin[EB/OL] [2021-04-27]. <https://zjoccean.org.cn/oceanswindow/bulletin>.
- [27] 浙江省统计局. 浙江统计年鉴[EB/OL] [2021-04-27]. <http://tjj.zj.gov.cn/col/col1525563/index.html>.
Zhejiang Provincial Bureau of Statistics. Zhejiang statistical yearbook[EB/OL] [2021-04-27]. <http://tjj.zj.gov.cn/col/col1525563/index.html>.
- [28] 海南省人民政府. 海南统计年鉴[EB/OL] [2021-04-27]. <http://www.hainan.gov.cn/hainan/tjnj/list3.shtml>.
People's Government of Hainan Province. Hainan statistical yearbook[EB/OL] [2021-04-27]. <http://www.hainan.gov.cn/hainan/tjnj/list3.shtml>.
- [29] 于福江, 董剑希, 叶琳, 等. 中国风暴潮灾害史料集 (1949—2009)[M]. 北京: 海洋出版社, 2015.
YU Fujiang, DONG Jianxi, YE Lin, et al. Collection of storm surge disasters historical data in China 1949-2009[M]. Beijing: China Ocean Press, 2015.
- [30] 卢文芳. 上海地区热带气旋灾情的评估和灾年预测[J]. 自然灾害学报, 1995, 4(3): 40-45.
LU Wenfang. Assessment and year prediction of tropical cyclone disaster in Shanghai[J]. Journal of Natural Disasters, 1995, 4(3): 40-45.
- [31] 许闲, 张彧. 自然灾害损失评估: 联合国框架、评价与案例[J]. 数量经济技术经济研究, 2017, 34(8): 137-149.
XU Xian, ZHANG Yu. Natural disasters' loss assessment: framework by the United Nations, Remarks and case application[J]. Journal of Quantitative & Technological Economics, 2017, 34(8): 137-149.
- [32] 国家海洋局. 风暴潮风险评估和区划技术导则[S]. 北京: 国家海洋局, 2012.
State Oceanic Administration of China. Guideline for risk assessment and zoning of storm surge disaster[S]. Beijing: State Oceanic Administration of China, 2012.
- [33] 谭丽荣, 陈珂, 王军, 等. 近 20 年来沿海地区风暴潮灾害脆弱性评价[J]. 地理科学, 2011, 31(9): 111-117.
TAN Lirong, CHEN Ke, WANG Jun, et al. Assessment on storm surge vulnerability of coastal regions during the past twenty years[J]. Scientia Geographica Sinica, 2011, 31(9): 111-117.
- [34] 樊琦, 梁必骥. 热带气旋灾害经济损失的模糊数学预测[J]. 气象科学, 2000, 20(3): 360-366.
FAN Qi, LIANG Biqi. A fuzzy mathematics evaluation of disastrous economic losses caused by tropical cyclone[J]. Journal of the Meteorological Sciences, 2000, 20(3): 360-366.
- [35] 高松, 钟山, 李亚汝, 等. 山东省海洋自然灾害综合危险性评估研究[J]. 海洋科学, 2018, 42(9): 55-63.
GAO Song, ZHONG Shan, LI Yaru, et al. A comprehensive study on the hazard assessment of marine disasters in Shandong Province[J]. Marine Sciences, 2018, 42(9): 55-63.
- [36] 魏章进, 马华铃, 唐丹玲. 基于改进熵值法的台风灾害风险趋势评估[J]. 灾害学, 2017, 32(3): 7-11.
WEI Jinzhang, MA Hualing, TANG Danling. Trend assessment of typhoon disaster based on the improved entropy method[J]. Journal of Catastrophology, 2017, 32(3): 7-11.
- [37] RUMELHART D E, HINTON G E, WILLIAMS R J. Learning representations by back-propagating errors[J]. Nature, 1986, 323(6088): 533-536.
- [38] OSOWSKI S. Signal flow graphs and neural networks[J]. Biological Cybernetics, 1994, 70(4): 387-395.
- [39] MIRJALILI S, MIRJALILI S M, LEWIS A. Grey wolf optimizer[J]. Advances in Engineering Software, 2014, 69(7): 46-61.
- [40] 张新明, 涂强, 康强, 等. 灰狼优化与差分进化的混合算法及函数优化[J]. 计算机科学, 2017, 44(9): 93-98, 124.
ZHANG Xinming, TU Qiang, KANG Qiang, et al. Hybrid optimization algorithm based on grey wolf optimization and differential evolution for function optimization[J]. Computer Science, 2017, 44(9): 93-98, 124.
- [41] 李海涛, 袁森. 基于遗传算法和 BP 神经网络的海洋工程材料腐蚀预测研究[J]. 海洋科学, 2020, 44(10): 33-38.
LI Haitao, YUAN Sen. Corrosion prediction of marine engineering materials based on genetic algorithm and BP neural network[J]. Marine Sciences, 2020, 44(10): 33-38.

Improved neural network-based economic loss prediction of storm surge disaster

ZHAO Ling-di^{1,2}, QI Yan-ling¹, WANG Xiao-hua³

(1. College of Economics, Ocean University of China, Qingdao 266100, China; 2. Ocean Research Institute of Ocean Development, Ocean University of China, Key Research Base of Humanities and Social Sciences, Ministry of Education, Qingdao 266100, China; 3. Australia-China Centre for Coastal Zone Management, University of New South Wales, Canberra2600, Australia)

Received: May 25, 2022

Key words: storm surge disaster; economic loss assessment; differential evolution grey wolf optimization; BP neural network

Abstract: Storm surge disasters have serious negative impact on the social and economic development of China's southeast coastal areas and are one of the most serious marine disasters in China. Therefore, it is highly important to establish an accurate and effective loss assessment model for storm surge disaster loss prediction, which is crucial for the prevention and management of storm surge disasters. Based on existing research, this study collects relatively complete storm surge disaster-related data of Hainan, Guangdong, Fujian, and Zhejiang provinces on the southeast coast of China from 2000 to 2018. It establishes a complete indicator system for storm surge disaster losses based on comprehensive consideration of risk, the vulnerability of disaster bearers, pregnant environment, and disaster prevention and mitigation capabilities. Compared with a single back propagation (BP) neural network, this study constructs a BP neural network optimized by the differential evolutionary gray wolf algorithm (DEGWO) based on machine learning-related theories and trains and simulates the samples. The results show that the proposed network model demonstrates a smaller error and a higher fit of the data than single BP neural network model, thus improving the accuracy of storm surge disaster loss prediction. These results can provide new insights for the study of storm surge disaster loss prediction and guidance for storm surge disaster prevention and mitigation management.

(本文编辑: 丛培秀)