

刘淑贤,张立生,刘扬,等,2024. 基于机器学习的热带气旋灾害等级评估模型构建及其活动特征分析[J]. 气象,50(3):331-343. Liu S X,Zhang L S,Liu Y,et al,2024. Construction of tropical cyclone disaster grade assessment model based on machine learning and analysis of its activity characteristics[J]. Meteor Mon,50(3):331-343(in Chinese).

基于机器学习的热带气旋灾害等级评估 模型构建及其活动特征分析^{*}

刘淑贤¹ 张立生¹ 刘 扬¹ 王维国¹ 杨 琨¹ 张源达^{2,3}

1 国家气象中心,北京 100081

2 中国气象科学研究院,北京 100081

3 南京信息工程大学,南京 210044

提 要: 在全球变暖的背景下,热带气旋(TC)作为影响我国最严重的自然灾害之一,其活动特征及灾害损失评估研究受到了广泛关注。采用组合赋权和 k -means 等方法,分析了 2000 年以来登陆我国的 TC 及灾害损失特征,并构建了基于机器学习的 TC 灾害等级评估模型。结果表明:从总体趋势来看,登陆我国的 TC 频数在逐年减少,但登陆风速的最大值却在缓慢增加;广东、浙江、福建、广西受灾较为严重,但整体上全国综合灾情指数呈下降趋势;与传统的随机森林、支持向量机、朴素贝叶斯算法相比,LightGBM(Light Gradient Boosting Machine)在 TC 灾害评估中效果最佳,准确率值为 0.91,其中致灾因子是模型中最关键的因素,其次是防灾减灾能力、暴露度和脆弱性指标。

关键词: 热带气旋,灾害等级评估,机器学习,LightGBM(Light Gradient Boosting Machine)

中图分类号: P49,P447

文献标志码: A

DOI: 10.7519/j.issn.1000-0526.2023.043001

Construction of Tropical Cyclone Disaster Grade Assessment Model Based on Machine Learning and Analysis of Its Activity Characteristics

LIU Shuxian¹ ZHANG Lisheng¹ LIU Yang¹ WANG Weiguo¹ YANG Kun¹ ZHANG Yuanda^{2,3}

1 National Meteorological Centre, Beijing 100081

2 Chinese Academy of Meteorological Sciences, Beijing 100081

3 Nanjing University of Information Science and Technology, Nanjing 210044

Abstract: Tropical cyclone (TC), one of the worst natural disasters in China, has garnered a lot of interests for both its activity characteristics and disaster loss assessment, especially in the context of global warming. In this paper, the combined weighting and k -means clustering methods are used to analyze the spatial and temporal characteristics of TC and its disaster loss in China since 2000. In addition, the disaster grade assessment model of TC based on machine learning algorithm is also constructed. The results show that the frequency of TC landing in China is in a trend of decreasing year by year, but the maximum landing wind speed has been slowly strengthening. Guangdong, Zhejiang, Fujian and Guangxi provinces are seriously affected by TC, but overall, the comprehensive disaster index shows a downward trend. Compared with the classic RF, SVM and NB algorithms, LightGBM (Light Gradient Boosting Machine) has

^{*} 国家气象中心青年基金项目(Q202212)、国家气象中心气象现代化建设专项(QXXDH202226)和国家重点研发计划(2019YFC1510204)共同资助

2022 年 11 月 28 日收稿; 2023 年 11 月 30 日收修定稿

作者简介:刘淑贤,主要从事气象灾害风险评估研究. E-mail:liushuxian@cma.gov.cn

通讯作者:刘扬,主要从事气象灾害风险评估研究. E-mail:liuyang@cma.gov.cn

the best performance in assessing the TC disaster loss, and the accuracy can reach 0.91. Moreover, the disaster-inducing factor is the most critical factor in the assessment model, followed by the disaster prevention and mitigation, exposure and vulnerability indicators.

Key words: tropical cyclone(TC), disaster grade assessment, machine learning, LightGBM(Light Gradient Boosting Machine)

引 言

热带气旋(tropical cyclone, TC)是世界上最严重的自然灾害之一,伴随 TC 产生的极端大风、暴雨、巨浪和风暴潮天气往往会对人类生命财产和沿海生态系统等造成严重破坏(Dube et al, 2009; 牛海燕等, 2011; 张娇艳等, 2011; Krapivin et al, 2012; 魏章进等, 2017)。平均而言,全球每年大约会形成 90 个 TC, 每年因 TC 造成的损失约为 260 亿美元(Mendelsohn et al, 2012; Bakkensen and Mendelsohn, 2019)。我国濒临世界上最大的 TC 发源地西北太平洋, 每年受 TC 侵扰频繁(刘彤和闫天池, 2011; 丑洁明等, 2022)。根据统计, 1994—2013 年因 TC 造成的灾害占我国气象灾害总数的 37%, 导致了 21% 的人口死亡和 17% 的直接经济损失, 其灾害强度和损失程度仅次于洪涝灾害(吴吉东等, 2014)。自 2010 年以来, TC 给我国带来的直接经济损失每年都高达数百亿甚至上千亿元(金蕊等, 2020)。在全球变暖的背景下, 相关研究表明 TC 的频率会保持不变或降低, 但其平均强度和造成的影响程度可能会大幅升级(Bender et al, 2010; Moon et al, 2019; Knutson et al, 2020)。因此, 对 TC 活动特征及灾害损失评估研究一直是我国防灾减灾工作的重点之一(殷洁等, 2013; 温姗姗等, 2017; 丑洁明等, 2018; 向纯怡等, 2022; 庄瑶等, 2022; 钱奇峰等, 2023)。

TC 灾害损失主要是由致灾因子的危险性、承灾体和孕灾环境的暴露度和脆弱性、防灾减灾能力等因素决定, 目前已经进行了大量研究来检验这些因素在 TC 灾害损失评估中所起的作用, 但相关结论仍存在较大的不确定性。一些研究认为社会经济发展对 TC 灾害损失的影响更大。Schmidt et al (2010) 使用非线性最小二乘算法 Levenberg-Marquardt 研究了社会经济和气候变化对美国 TC 损失的影响, 结果表明由社会经济因素导致的损失变化大约是气候因素的 3 倍。Yonson et al (2018) 使用

统计方法评估社会经济的脆弱性、暴露度和致灾因子对 TC 造成的死亡人数的影响, 并发现死亡人数似乎更多地受到贫困发生率的影响, 而不是 TC 过程中的降水量。还有一些则认为由气候变化引起的 TC 强度变化对灾害损失的影响更大。Ye et al (2020) 使用负二项式回归模型量化了由 TC 引起的直接经济损失与 TC 最大风速、资产价值和人均国内生产总值(gross domestic product, GDP)之间的关系, 发现 TC 最大风速对经济损失的影响要大于资产价值和人均 GDP。

虽然这些传统的统计回归模型在解决低维、弱非线性问题方面取得了一定成果, 但是由于 TC 灾害损失是一个复杂、高维和强非线性问题, 传统统计模型不能很好地预测。有效的自然灾害损失评估模型应包括较为全面的综合因素, 并反映因素与灾害损失之间复杂的非线性关系(Sun et al, 2021)。机器学习(machine learning, ML)算法在解决复杂的非线性问题上已经取得了显著的效果, 并具有较好的可控性和可扩展性, 已经被成功应用于灾害监测和影响评估研究中(冯倩和刘强, 2017; 刘扬和王维国, 2020; 周康辉等, 2021; 杨绚等, 2022)。

机器学习模型可以分为单模型和集成模型。单模型基于一种模型独立进行训练和验证, 主要包括支持向量机(support vector machine, SVM)、神经网络(neural network, NN)、决策树(decision tree, DT)、朴素贝叶斯(naive Bayes, NB)等。叶小岭等(2011)以浙江省为例, 选取台风致灾因子、区域差异等指标作为解释变量, 以台风造成的经济、人口、耕地、房屋损失作为预测变量, 建立了台风损失预测的反向传播神经网络(back propagation neural network, BPNN)模型。集成机器学习模型就是将多个单模型组合成一个强模型, 该强模型能取所有单模型之长, 达到相对的最优性能, 常用的集成模型包括随机森林(random forest, RF)、梯度提升决策树(gradient boosting decision tree, GBDT)、XGBoost(extreme gradient boosting)等。相比各基模型之

间独立训练,结果为简单投票或平均的 RF 算法,在基于 Boosting 的 GBDT 算法中,新决策树在每次迭代中学习所有先前树的错误残差,从而生成更强大的基础模型 (Friedman, 2001; Richardson et al, 2007; Chen and Guestrin, 2016)。Zhang et al (2019)采用 BPNN、一维卷积神经网络、DT、RF 和 XGBoost,拟合泥石流触发因素与灾害损失之间的关系,发现基于 GBDT 的改进模型 XGBoost 的精度要显著高于 RF 和其他单模型。2017 年,微软提出了 XGBoost 的改进算法 LightGBM(Light Gradient Boosting Machine),该算法更加快速和准确,是 GBDT 最成功和最先进的实现(Ke et al, 2017),其在灾害损失预测方面具有较大的潜力。

随着研究的深入,虽然高拟合模型的数量逐渐增加,但选择合适的模型仍然具有挑战性,因此,TC 灾害损失评估模型的构建和优化仍需要不断地被验证和评估,从而选择出最优模型。此外,单一灾害损失指标不足以评估 TC 对社会经济等方面的综合影响,需要构建较为客观的综合灾害指标以反映 TC 造成的综合影响。本文旨在对 TC 及其灾害损失特征进行统计分析,并将 TC 综合灾害损失与 TC 物理特征、社会经济等因素联系起来,建立基于集成机器学习算法的 TC 灾害等级评估模型,为 TC 的灾

害防御提供重要参考依据。

1 数据和方法

1.1 数据样本和指标体系建立

本文选取了 2000—2021 年 TC 影响我国不同省(自治区、直辖市)的 492 个个例作为样本,考虑的 TC 灾害损失指标主要包括直接经济损失、死亡人口、受灾面积和倒塌房屋,并从致灾因子(H)、暴露度和脆弱性(V)、防灾减灾能力(R)3 个方面,构建 TC 灾害的影响因素指标体系(表 1)。其中,致灾因子主要考虑了 TC 过程中最大日降水量、暴雨站点比例、极大风速、大风站点比例 4 个指标。关于承灾体的暴露度和脆弱性,主要从农业、交通、经济、房屋建筑等方面考虑了农作物播种面积、公共汽电车运营线路总长度、地区生产总值、房屋施工面积等 7 个指标。此外,从抗台工程能力、监测预警能力、医疗救护能力、社会应对台风能力 4 个方面分别选取了防护林造林面积、电话和互联网、每万人医疗机构床位数、人均 GDP 等 5 个具有代表性的指标衡量应对 TC 的防灾减灾能力(张颖超等, 2015)。

表 1 数据类别及来源
Table 1 Categories and sources of samples

类别	指标	简称	数据来源
致灾因子(H)	最大日降水量(单位:mm)	H_1	中国地面气象站基本气象要素日值数据集 (http://idata.cma/)
	暴雨站点比例(单位:%)	H_2	
	极大风速(单位: $m \cdot s^{-1}$)	H_3	
	大风站点比例(单位:%)	H_4	
暴露度和脆弱性(V)	地区生产总值(单位:亿元)	V_1	国家统计局 (http://www.stats.gov.cn/)
	人口数量(单位:万人)	V_2	
	人口密度(单位: $人 \cdot km^{-2}$)	V_3	
	农作物播种面积(单位: hm^2)	V_4	
	房屋施工面积(单位: m^2)	V_5	
	房屋竣工面积(单位: m^2)	V_6	
	公共汽电车运营线路总长度(单位:km)	V_7	
防灾减灾能力(R)	每万人医疗机构床位数(单位:张)	R_1	国家统计局 (http://www.stats.gov.cn/)
	电话(单位:部/百人)	R_2	
	互联网(单位:万户)	R_3	
	人均 GDP(单位:万元/人)	R_4	
	防护林造林面积(单位: hm^2)	R_5	
TC 灾害损失	直接经济损失(单位:亿元)	—	《中国气象灾害年鉴》 (中国气象局, 2000—2020)
	死亡人口(单位:人)	—	
	受灾面积(单位: hm^2)	—	
	倒塌房屋(单位:万间)	—	

1.2 数据处理方法

1.2.1 直接经济损失的去通货膨胀调整

考虑到通货膨胀的影响,直接比较不同年份的直接经济损失是不可取的。因此,有必要消除通货膨胀的影响得到实际直接经济损失,其计算方式为:

实际直接经济损失 =

$$\text{直接经济损失} / \text{GDP 平减指数} \quad (1)$$

式中 GDP 平减指数来源于世界银行 (<http://data.worldbank.org/datacatalog/world-development-indicators>) (图 1)。




图 1 2000—2021 年中国 GDP 平减指数变化趋势

Fig. 1 Trend of China's GDP deflator from 2000 to 2021

表 2 综合灾情指数中各灾情指标的组合权重

Table 2 Combined weight of each disaster index for the calculation of comprehensive disaster index

指标	死亡人口	实际直接经济损失	倒塌房屋	受灾面积
权重	0.33	0.27	0.21	0.19

1.2.3 TC 灾害损失等级分类

k -means 算法作为聚类算法中的典型代表之一,其聚类效果已经被各领域广泛应用和认可,其中 k 为类别数,means 为均值。 k -means 算法通过预先设定的 k 值及每个类别的初始质心对相似数据点进行划分归类,并通过划分后的均值不断迭代优化以获得最优的聚类结果。在王国复(2021)提出的台风灾害调查与风险评估方法(以下简称台风灾害普查)中,根据台风灾害指数(R)的分布特征,将台风灾害分为高($R \geq \text{ave} + s$)、较高($\text{ave} + 0.5s \leq R < \text{ave} + s$)、中($\text{ave} - 0.5s \leq R < \text{ave} + 0.5s$)、较低($\text{ave} - s \leq R < \text{ave} - 0.5s$)和低($R < \text{ave} - s$)5 个等级,其中 ave 和 s 分别表示均值和标准差。

对 1.2.2 小节得到的综合灾情指数进行等级分

1.2.2 综合灾情指数构建

由于不同指标变量的单位和量级不同,对数据进行归一化处理:

$$X_{ij}^* = (X_{ij} - X_{\min}) / (X_{\max} - X_{\min}) \quad (2)$$

式中: X_{ij} 、 X_{ij}^* 分别为归一化处理前、后第 i 个样本中灾情指标 j 的值, $X_{\min}$ 和 $X_{\max}$ 分别代表最小值和最大值。

为了对死亡人口、实际直接经济损失、受灾面积、倒塌房屋这 4 项灾情指标进行综合定量评价,本研究利用主、客观相结合的组合赋权法确定各指标相应权重。具体而言,本文采用的主观赋权法为专家打分法(王秀荣等, 2018),客观赋权法为熵值法,两种方法的组合权重为:

$$w_j = \frac{\sqrt{\alpha_j \beta_j}}{\sum_{j=1}^4 \sqrt{\alpha_j \beta_j}} \quad (3)$$

式中: w_j 为指标 j 的组合权重, α_j 为专家打分法所得权重, β_j 为熵值法计算所得权重。

如表 2 所示,最终确定死亡人口、实际直接经济损失、倒塌房屋、受灾面积这 4 项损失指标的权重值 $w_j = (0.33, 0.27, 0.21, 0.19)$ ($j = 1, 2, 3, 4$)。综合灾情指数 D_i 计算公式如下:

$$D_i = \lg \left(\sum_{j=1}^4 w_j \times X_{ij}^* \times 100 \right) \quad (4)$$

类,分别按照 k -means 聚类方法和台风灾害普查中的分类方法进行对比分析。为了便于对两种方法进行比较,在 k -means 方法中将 k 值设为 5,根据综合灾情指数划分为低[0~0.28)、较低[0.28~0.49)、中[0.49~0.63)、较高[0.63~0.77)、高[0.77~1] 5 类。从 k -means 和台风灾害普查两种方法的分类结果可以看出(表 3), k -means 较台风灾害普查方法增加了 21 个高、35 个较高、43 个较低等级的分类个数,减少了 50 个中和 49 个低等级的分类个数,即 k -means 方法增加了灾害等级强度大的分类个数,而减少了位于中间强度的分类个数。进一步对典型 TC 个例的分类结果进行分析,例如,0102 号台风飞燕造成浙江 22 人死亡,实际直接经济损失达 1.31 亿元,在 k -means 方法中其灾害等级被认定为较高,

但在台风灾害普查方法中仅为中;0119 号台风利奇马造成浙江 1 人死亡,受灾面积为 0.07 万 hm^2 ,在 k -means 方法中其灾害等级被认定为较低,但在台风灾害普查方法中却为低;1409 号台风威马逊造成云南 37 人死亡,实际直接经济损失达 34.1 亿元,在 k -means 方法中其灾害等级被认定为高,但在台风灾害普查方法中仅为较高,可以发现 k -means 方法的灾害等级分类结果更加符合实际灾害损失情况。

因此,基于以人为本的防灾减灾理念,本文选择 k -means 方法进行 TC 灾害等级分类。同时为了保证每一类的样本数量足够多,以便在机器学习模型中取得较好的训练效果,在构建 TC 灾害损失评估模型时将 k 值设为 3 类,并利用 k -means 算法将样本的综合灾情指数分为低 $[0\sim0.46)$ 、中 $[0.46\sim0.69)$ 、高 $[0.69\sim1]$ 3 个等级(图 2)。

表 3 k -means 和台风灾害普查方法的各等级分类结果对比
Table 3 Comparison of the classification results between k -means and typhoon disaster census

灾害等级	k -means/个	台风灾害普查/个
低	22	71
较低	114	71
中	134	184
较高	119	84
高	103	82

1.3 TC 灾害等级评估模型建立


在单模型机器学习算法中,NB 仅适应于样本

独立且均匀分布的情况,而 SVM 则在解决非线性问题时效果较差。相比之下,包含多模型的集成机器学习算法具有避免过拟合、计算快速和准确等优势,已成为解决大量机器学习问题的最先进方法。

集成机器学习模型基本可以分为两类:Bagging 和 Boosting,RF 为基于 Bagging 的经典模型,而 GBDT 则为基于 Boosting 的典型代表。Boosting 与 Bagging 之间最大的区别在于:①对于样本选择, Bagging 算法为有放回的均匀取样,且各轮训练集之间相互独立,而 Boosting 算法中训练集不变,但会根据上一轮的分类结果对样本权重进行调整;②关于预测函数, Bagging 算法中所有预测函数权重相等,其预测结果为所有弱分类器结果的投票或平均,而 Boosting 中每个弱分类器具有不同的权重,分类误差小的分类器将会有较大的权重。

作为目前 GBDT 算法最成功和最先进的实现,在 LightGBM 算法中,新决策树在每次迭代中学习所有先前树的错误残差,从而生成更强大的基础模型。因此,与各基模型之间独立训练、结果为简单投票或平均的 RF 算法相比,LightGBM 往往表现出更加优越的性能(Wang et al,2017;2022)。

本文将 TC 灾害损失的影响因素指标如致灾因子(H)、暴露度和脆弱性(V)、防灾减灾能力(R)作为特征变量,反映综合灾害损失的等级分类作为预测变量分别输入到 4 种机器学习模型(LightGBM、RF、SVM、NB)中进行训练和检验(图 3)。具体实现步骤如下。



注:数字 1、2、3 分别代表 TC 灾害损失的低、中、高等级。

图 2 基于 k -means 的 TC 灾情等级分类

Fig. 2 Comprehensive disaster grade based on k -means




图 3 基于机器学习的 TC 综合灾害等级评估模型流程图

Fig. 3 Flow chart of comprehensive grade assessment of TC disaster based on machine learning

(1)数据集。从总样本中随机选择 80% 作为训练集(交叉验证集),剩下的 20% 作为测试集(不参与训练)。为了增强模型的鲁棒性、确保泛化误差的稳定性,本文采用了 5 倍交叉验证法对模型进行训练和调参以得到最优模型。具体而言,将训练集等分为 5 份,不重复地每次选择其中 1 份作为验证集,其他 4 份作为训练集来进行模型的调参。

(2)模型评估。采用查准率(Precision)、准确率(Accuracy)、召回率(Recall)、 F_1 -score 指标对模型结果进行定量评估和比较。

2 结果与讨论

2.1 登陆我国 TC 的时空特征分析

我国海岸线长、海洋疆域辽阔,沿海城市和岛屿众多,且沿海地区人口密集、经济发达。在全球变暖的背景下,TC 频繁发生且登陆我国沿海,对我国沿海地区的经济发展和居民安全造成了较大的威胁。因此,了解登陆我国 TC 的年际和年代际变化等活动特征是十分必要的。图 4 给出了 2000—2021 年 TC 登陆我国沿海地区的空间分布。从图中可以看出,2000 年以来 TC 登陆我国的沿海地区包括广东、广西、海南、台湾、福建、浙江、上海、江苏、山东、

辽宁等,且南方沿海地区的登陆频数要远高于北方沿海地区。其中,TC 登陆频数最多为广东(64 个),其次是台湾(44 个)、福建(40 个)、海南(35 个)和浙江(21 个)。

登陆频数和登陆风速是评估 TC 活动特征的重要指标。图 5 给出了登陆我国的 TC 频数的月际和年际变化。结果表明,登陆我国沿海地区的 TC 主要集中在出现在 6—10 月,其中 7 月、8 月、9 月最为频繁,登陆频数分别为 59、52、44 个(图 5a)。2000 年以来共有 162 个 TC 登陆我国,平均每年登陆频数为 7 个。整体而言,自 2000 年以来登陆我国的 TC




图 4 2000—2021 年登陆我国的 TC 频数分布

Fig. 4 Distribution of total frequency of TC landing in China from 2000 to 2021




图5 2000—2021年登陆我国的TC频数随(a)月份和(b)年份的变化

Fig. 5 Variation of the frequency of TC landing in China with (a) month and (b) year from 2000 to 2021

频数呈现波动下降趋势(图5b)。

根据TC的6个等级划分:热带低压(风力6~7级,TD)、热带风暴(风力8~9级,TS)、强热带风暴(风力10~11级,STS)、台风(风力12~13级,TY)、强台风(风力14~15级,STY)和超强台风(风力 ≥ 16 级,SuperTY),本研究对2001—2021年登陆我国的TC等级进行年代际变化分析。从3年TC强度频数分布(图6)中可以看出,登陆我国的TC中,TD、TS、STS的登陆频数整体上随时间呈现出缓慢增加趋势(图6中棕色虚线);而TY、STY、SuperTY登陆频数呈现较为明显的下降趋势(图6中蓝色虚线)。

为了进一步评估TC登陆强度,分析2000—2021年我国TC登陆风速箱线图,如图7所示。就登陆风速的平均值而言,2005年、2012年、2015年





图6 2001—2021年登陆我国TC等级的3年平均频数分布

Fig. 6 3-year average frequency of the grade of TC landing in China from 2001 to 2021



注:箱体红色短横线、菱形分别代表中位数、平均值,箱体上、下两端分别代表上、下四分位数,沿虚线上、下两端分别代表最大值和最小值。

图7 2000—2021年我国TC登陆风速箱线图

Fig. 7 Box plot of the wind speed of TC landing in China from 2000 to 2021

的登陆风速值较大,均超过了 $36 \text{ m} \cdot \text{s}^{-1}$,其中 2015 年的登陆风速值最大,为 $38.4 \text{ m} \cdot \text{s}^{-1}$ 。对于登陆风速的最大值而言,在 2014 年达到了 $70 \text{ m} \cdot \text{s}^{-1}$ 。整体来看,登陆风速的平均值呈下降趋势,而最大值呈上升趋势,且伴随较大异常值的出现,说明在全球变暖的背景下,近年来登陆我国的 TC 强度的极端性有所加强。

2.2 TC 灾害损失特征分析

如 2.1 节所述,近年来在全球变暖的背景下气候表现异常,登陆我国的 TC 频数虽然整体上逐年减少,但其登陆风速的最大值却呈缓慢上升趋势,并伴有较大异常值的出现,具有一定的突发性和极端性。因此,分析我国 TC 灾害损失的时空分布特征,对科学认识 TC 灾害,提高风险防范能力具有重要的指导意义。

图 8 给出了 2000—2019 年 TC 主要影响地区的灾情分布情况,包括受灾面积、倒塌房屋、实际直接经济损失以及死亡人口。由图可见,整体而言,各省份之间灾害损失的总体强度和受灾种类都存在分布不均匀的特征,除受灾较为严重的广东、浙江、福建、广西外,其他地区的受灾情况差异较小,且广东、浙江、福建、广西的受灾面积、倒塌房屋、实际直接经济损失基本都远大于其他地区。

图 9 给出了死亡人口、倒塌房屋、受灾面积、直接经济损失以及综合灾情指数的年际变化趋势,其中图中虚线代表各指标的线性拟合。由图可见,直接经济损失呈现明显上升趋势,而在去除通货膨胀因素后,实际直接经济损失则呈缓慢上升趋势。除直接经济损失外,TC 灾害造成的死亡人口、倒塌房屋、受灾面积、综合灾情指数均为下降趋势。具体而言,死亡人口、倒塌房屋和综合灾情指数均在 2006 年达到最大值,且其数值明显高于其他年份,是其他年份数值的 2~3 倍,其中死亡人数为 1522 人,倒塌房屋数为 72.3 万间。这是因为在 2006 年,出现了几次灾害较为严重的 TC 个例,如 0604 号台风碧利斯造成了 843 人死亡,以及 384 亿元的直接经济损失;0608 号台风桑美造成了 483 人死亡和 196.6 亿元的直接经济损失。综上所述,虽然近年来 TC 强度和频率都在增加,但是除直接经济损失外,死亡人口、倒塌房屋、受灾面积和综合灾情指数都在降低,这可能与我国对 TC 的预测体系和防御措施在不断加强,以及居民的防灾减灾意识逐渐提升有关。




图 8 2000—2019 年 TC 主要

影响地区的灾情分布

Fig. 8 Distribution of disaster loss in major region affected by TC from 2000 to 2019

2.3 基于机器学习的 TC 灾害等级评估

通过上文分析可以得到,气候异常背景下,登陆我国的 TC 强度具有一定的极端性,且其造成的灾害损失具有时空分布不均匀的特征,不同省份之间存在较大的差异。因此,构建综合考虑 TC 物理特征和社会经济因素的灾害损失评估模型是十分必要的。如 1.3 节所述,本文采用 4 种机器学习算法对 TC 灾害等级评估进行对比分析。为了使模型的表现性能最佳,选择 7 个参数对 LightGBM 模型进行调整,其中参数调整范围如表 4 所示。然后,使用网格搜索来找到最佳参数组合,这意味着模型需要被迭代调整 37 500 ($5 \times 5 \times 5 \times 5 \times 3 \times 4 \times 5$) 次。本文选用 Log loss 达到最小值时的参数模型作为最优模型,最佳参数组合见表 4。此外,将 LightGBM 的参数“is_unbalance”设定为“true”,用于处理数据集中类别标签存在不平衡的情况,从而使得模型的泛化性能更强。其他 3 种机器学习模型的最优参数组合已省略。

在经过参数调整得到最优模型后,对 4 种机器学习算法的 TC 灾害等级预测结果进行了评估和比较(表 5)。结果表明,单模型算法 SVM 和 NB 中各项结果评估指标均远小于集成模型算法 RF 和 LightGBM。且与基于 Bagging 思想的 RF 相比,基于 Boosting 的 LightGBM 表现最佳,除查准率之外,其余 3 个指标值均在 0.90 及以上,准确率达到 0.91,召回率为 0.93, F_1 -score 为 0.90。由此说明,LightGBM 算法非常适于 TC 灾害损失预测,在灾害评估方面具有广泛应用前景。




图9 2000—2019年我国由TC造成的(a)死亡人口,(b)倒塌房屋,
(c)受灾面积,(d)直接经济损失及(e)综合灾情指数的年际变化趋势

Fig. 9 Interannual trend of (a) death population, (b) collapsed houses, (c) affected area, (d) direct economic loss and (e) comprehensive disaster index caused by TC in China from 2000 to 2019

表 4 LightGBM 的参数调整范围及最优模型参数组合

Table 4 Range and optimal combination of parameters in LightGBM		
参数	含义及调整范围	最优模型取值
num_leaves	决策树上最大的叶子树[10,20,30,40,50]	20
max_depth	决策树的最大深度[5,6,7,8,9]	7
max_bin	最大分档树[5,10,15,20,25]	10
min_leaf	叶子上最小的数据量[10,15,20,25,30]	20
fea_frac	在每棵树上随机选择的特征比例[0.6,0.8,1.0]	0.8
learn_rate	收缩率[0.01,0.03,0.05,0.10]	0.03
n_estimators	提升迭代次数[50,100,150,200,250]	200

表 5 基于 4 种机器学习算法的 TC 灾害
损失预测结果评估

Table 5 Prediction assessment of TC disaster based on
four machine learning algorithms

算法	查准率	召回率	F ₁ -score	准确率
LightGBM	0.88	0.93	0.90	0.91
RF	0.69	0.76	0.70	0.73
SVM	0.57	0.64	0.60	0.65
NB	0.56	0.60	0.57	0.58


为了增强模型的解释能力,理解指标在预测 TC 灾害等级中的相对重要性,基于 LightGBM 模型的“feature_importances”工具包给出了每项指标的分裂次数(图 10),可用来衡量各指标的相对重要性,结果表明:

(1)整体来看,就重要性指标的平均值而言,致灾因子(24)> 防灾减灾能力(14)>暴露度和脆弱性(10);就最大值而言,致灾因子、防灾减灾能力、暴露度和脆弱性指标分别排在了第一、第二、第五位。

这说明致灾因子在 TC 灾害等级评估中具有非常重要的指示意义,对灾害损失等级分类的识别能力要明显高于暴露度和脆弱性以及防灾减灾能力。

(2)致灾因子的 4 个指标均排在了前八位中,关于大风的 2 个指标(极大风速 H_3 、大风站点比例 H_4)的平均值(28)要高于降水的 2 个指标(最大日降水量 H_1 、暴雨站点比例 H_2)的平均值(21),说明 TC 过程中大风对灾害损失的影响要大于暴雨的影响。其中,极大风速(H_3)和暴雨站点比例(H_2)分别位于第一、第三位,其重要性指标显著高于其他特征变量,充分代表了致灾因子的危险性和在 TC 灾害等级评估中的重要性。

(3)防灾减灾能力指标的重要性排序相对比较分散,除互联网 R_3 和人均 GDP R_4 排在了后三位外,防护林造林面积 R_5 排在了第九位,电话 R_2 和每万人医疗机构床位数 R_1 则排在了前四位,说明我国近年来在医疗、通信等方面的发展进步已经为



注:指标名称见表 1。

图 10 不同指标在模型中的分裂次数

Fig. 10 Split numbers of different indexes in model

灾害防御和灾后恢复提供了重要保障。

(4)相比之下,承灾体和孕灾环境的暴露度和脆弱性指标表现不佳,其中最重要的2个指标为农作物播种面积 V_4 和房屋竣工面积 V_6 。虽然TC主要影响的是我国经济快速发展而农作物播种面积相对较小的华南、华东等地区(上海、江苏、浙江、福建、广东等),但通过本文得到的特征重要性排序结果可以看出,农作物播种面积 V_4 的重要程度要大于地区生产总值 V_1 ,对于该结论有两点解释:①近20年来我国中东部地区主要省份农作物播种面积的标准差(0.29)要高于地区生产总值(0.256)(图略),也就是说,相比地区生产总值,农作物播种面积的差异更能体现不同省份之间的差异;②经济发展一方面会使承灾体的暴露度增加,另一方面却可以提升所在地区的防灾减灾能力,降低了承灾体的易损性,而农作物播种面积的增大只能使得承灾体的暴露度增加,因此农作物播种面积在进行TC灾害等级评估时所起到的作用相对较大。

将本研究中基于LightGBM的TC灾害等级评估模型(以下简称方法一)与王秀荣等(2018)提出的台风灾害等级评判模型(以下简称方法二)进行结果对比,并选取一些典型TC个例进行分析。例如,0313号台风杜鹃造成广东44人死亡,实际直接经济损失达40.7亿元,受灾面积为26万 hm^2 ,在方法一中,其灾害损失等级被评估为高,而在方法二中被认定为中;0707号台风帕布造成广东4人死亡,实际直接经济损失达30亿元,倒塌房屋为1.56万间,0917号台风芭玛造成海南4人死亡,实际直接经济损失达2.9亿元,受灾面积2.96万 hm^2 ,在方法一中分别将2次个例评估为高和中灾,但在方法二中2次个例均为小灾,并未体现出2次个例在直接经济损失等方面的差异。由此可见,基于LightGBM的评估模型(方法一)具有较高的灾害等级分辨率,且其评估结果更加符合实际灾害损失情况。

3 结论与展望

通过分析2000年以来登陆我国的热带气旋(TC)及其灾害损失的时空分布特征,建立了基于机器学习算法的TC灾害等级评估模型,主要得到以下结论:

(1)登陆我国的TC频数呈现缓慢下降趋势,且低强度TC的数量逐年增多,高强度TC的数量显

著减少。进一步分析得到,虽然TC登陆风速的平均值整体呈下降趋势,但登陆风速的最大值却在缓慢增加,并伴有较大异常值的出现,说明在全球变暖的背景下,登陆我国TC的突发性和极端性在增强。

(2)结合熵值法和专家打分法对死亡人口、倒塌房屋、实际直接经济损失、受灾面积赋予权重并得到综合灾情指数,其指标权重大小排序为死亡人口(0.33)>倒塌房屋(0.27)>实际直接经济损失(0.21)>受灾面积(0.19)。通过分析我国TC灾害损失的时空分布特征得到,受灾较为严重的主要为广东、浙江、福建、广西等地,且除实际直接经济损失外,倒塌房屋、死亡人口、受灾面积及综合灾情指数都呈下降趋势。

(3)基于机器学习算法LightGBM、RF、SVM、NB,将致灾因子、暴露度和脆弱性、防灾减灾能力作为特征变量,TC灾害等级作为预测变量进行模型训练和评估。结果表明,在4种机器学习算法中,LightGBM的预测结果准确性远远高于其他算法,其准确率(Accuracy)、查准率(Precision)、召回率(Recall)、 F_1 -score分别达到了0.91、0.88、0.93、0.90,在灾害评估方面具有广泛应用前景。

(4)通过对各特征变量的相对重要性指标进行排序分析,发现致灾因子是TC灾害损失评估中最关键的因素,且TC过程中大风对灾害损失的影响要大于暴雨的影响;其次是防灾减灾能力指标,由此可以看出近年来我国在医疗、通信等方面的发展进步已经为灾害防御和灾后恢复提供了重要保障;相比之下,暴露度和脆弱性指标的重要性较低,说明在全球变暖导致的TC灾害极端性增强和我国日益增长的防灾减灾能力背景下,来自社会经济因素影响下的暴露度和脆弱性指标的重要性已有所减弱。

本文利用熵值法、专家打分法和 k -means聚类法等,采用主、客观相结合的方法确定指标权重并进行灾害等级分类,并采用LightGBM集成机器学习模型,克服了单模型中过拟合、泛化能力差等局限性。同时,本研究综合考虑了TC物理特征和社会经济等方面因素,从致灾因子、暴露度和脆弱性、防灾减灾能力3个方面构建特征变量,对TC造成的综合灾害损失进行评估,有别于单一的TC特征分析及单一的灾害损失模型构建,所得结果具有实际参考价值。但还存在样本数量不够、研究区域空间分辨率较低等问题,在后续的研究中,将进一步增加

样本数量以及提高样本空间分辨率,并根据社会经济的发展对模型加以改进和完善。

参考文献

- 丑洁明,班靖晗,董文杰,等,2018. 影响广东省的热带气旋特征分析及灾害损失研究[J]. 大气科学,42(2):357-366. Chou J M, Ban J H, Dong W J, et al, 2018. Characteristics analysis and assessment of economic damages caused by tropical cyclones in Guangdong Province[J]. Chin J Atmos Sci, 42(2):357-366 (in Chinese).
- 丑洁明,董文杰,徐洪,等,2022. 影响中国沿海区域的热带气旋及其经济损失评估[J]. 气象与环境科学,45(3):1-10. Chou J M, Dong W J, Xu H, et al, 2022. Assessment on economic losses of tropical cyclone disasters affecting China's coastal areas[J]. Meteor Environ Sci, 45(3):1-10 (in Chinese).
- 冯倩,刘强,2017. 基于 SVM-BP 神经网络的风暴潮灾害损失预评估[J]. 海洋环境科学,36(4):615-621. Feng Q, Liu Q, 2017. Pre-assessment for the loss caused by storm surge based on the SVM-BP neural network[J]. Mar Environ Sci, 36(4):615-621 (in Chinese).
- 金蕊,余晖,吴志伟,等,2020. 次季节-季节尺度热带气旋活动研究和预测技术进展[J]. 大气科学学报,43(1):238-254. Jin R, Yu H, Wu Z W, et al, 2020. Sub-seasonal to seasonal prediction of tropical cyclone activity in the Western North Pacific: a review[J]. Trans Atmos Sci, 43(1):238-254 (in Chinese).
- 刘彤,闫天池,2011. 我国的主要气象灾害及其经济损失[J]. 自然灾害学报,20(2):90-95. Liu T, Yan T C, 2011. Main meteorological disasters in China and their economic losses[J]. J Nat Dis, 20(2):90-95 (in Chinese).
- 刘扬,王维国,2020. 基于随机森林的暴雨灾害人口损失预估模型及应用[J]. 气象,46(3):393-402. Liu Y, Wang W G, 2020. Assessing model of casualty loss in rainstorms based on random forest and its application[J]. Meteor Mon, 46(3):393-402 (in Chinese).
- 牛海燕,刘敏,陆敏,等,2011. 中国沿海地区近 20 年台风灾害风险评估[J]. 地理科学,31(6):764-768. Niu H Y, Liu M, Lu M, et al, 2011. Risk assessment of typhoon disasters in China coastal area during last 20 years[J]. Sci Geogr Sin, 31(6):764-768 (in Chinese).
- 钱奇峰,董林,许映龙,等,2023. 2022 年西北太平洋和南海台风活动特征和预报难点分析[J]. 气象,49(10):1254-1266. Qian Q F, Dong L, Xu Y L, et al, 2023. Analysis on the characteristics and forecast difficulties of the typhoons over the Northwest Pacific and the South China Sea in 2022[J]. Meteor Mon, 49(10):1254-1266 (in Chinese).
- 王国复,2021. 气象灾害调查与风险评估[J]. 城市与减灾, (2):5-9. Wang G F, 2021. Meteorological disaster investigation and risk assessment[J]. City Disas Reduc, (2):5-9 (in Chinese).
- 王秀荣,张立生,李维邦,2018. 台风灾害综合等级评判模型改进及应用分析[J]. 气象,44(2):304-312. Wang X R, Zhang L S, Li W B, 2018. Improvement and application analysis of the comprehensive grade evaluation model of typhoon disaster[J]. Meteor Mon, 44(2):304-312 (in Chinese).
- 魏章进,马华铃,唐丹玲,2017. 基于改进熵值法的台风灾害风险趋势评估[J]. 灾害学,32(3):7-11. Wei Z J, Ma H L, Tang D L, 2017. Trend assessment of typhoon disasters based on the improved entropy method[J]. J Catastrophol, 32(3):7-11 (in Chinese).
- 温姗姗,翟建青,Thomas F,等,2017. 1984—2014 年影响中国热带气旋的经济损失标准化及其变化特征[J]. 热带气象学报,33(4):478-487. Wen S S, Zhai J Q, Thomas F, et al, 2017. Variation of normalized economic losses from influential tropical cyclones in China for 1984—2014[J]. J Trop Meteor, 33(4):478-487 (in Chinese).
- 吴吉东,傅宇,张洁,等,2014. 1949—2013 年中国气象灾害灾情变化趋势分析[J]. 自然资源学报,29(9):1520-1530. Wu J D, Fu Y, Zhang J, et al, 2014. Meteorological disaster trend analysis in China: 1949—2013[J]. J Nat Resour, 29(9):1520-1530 (in Chinese).
- 向纯怡,许映龙,高拴柱,等,2022. 2021 年西北太平洋台风活动特征和预报难点分析[J]. 气象,48(9):1195-1208. Xiang C Y, Xu Y L, Gao S Z, et al, 2022. Analysis of the characteristics and forecast difficulties of typhoon over the Western North Pacific in 2021[J]. Meteor Mon, 48(9):1195-1208 (in Chinese).
- 杨绚,张立生,王铸,2022. 基于机器学习算法的县城台风灾害经济损失风险评估[J]. 热带气象学报,38(5):651-661. Yang X, Zhang L S, Wang Z, 2022. Risk assessment for typhoon economic losses in county-based units using machine learning[J]. J Trop Meteor, 38(5):651-661 (in Chinese).
- 叶小岭,刘程波,张颖超,等,2011. 基于 BP 神经网络的浙江台风损失预测[J]. 信息技术, (10):59-61. Ye X L, Liu C B, Zhang Y C, et al, 2011. Damage forecasting of typhoon in Zhejiang Province based on BP ANN[J]. Inform Technol, (10):59-61 (in Chinese).
- 殷洁,戴尔阜,吴绍洪,等,2013. 中国台风强度等级与可能灾害损失标准研究[J]. 地理研究,32(2):266-274. Yin J, Dai E F, Wu S H, et al, 2013. A study on the relationship between typhoon intensity grade and disaster loss in China[J]. Geogr Res, 32(2):266-274 (in Chinese).
- 张娇艳,吴立广,张强,2011. 全球变暖背景下我国热带气旋灾害趋势分析[J]. 热带气象学报,27(4):442-454. Zhang J Y, Wu L G, Zhang Q, 2011. Tropical cyclone damages in China under the background of global warming[J]. J Trop Meteor, 27(4):442-454 (in Chinese).
- 张颖超,王璐,熊雄,等,2015. 基于 SPA 的福建省抗台风减灾能力评估[J]. 灾害学,30(2):85-88. Zhang Y C, Wang L, Xiong X, et al, 2015. Evaluation of typhoon disaster prevention and mitigation ability in Fujian Province based on set pair analysis[J]. J Catastrophol, 30(2):85-88 (in Chinese).
- 中国气象局,2000—2020. 中国气象灾害[M]. 北京:气象出版社. China Meteorological Administration, 2000—2020. Yearbook of

- Meteorological Disasters in China[M]. Beijing: China Meteorological Press(in Chinese).
- 周康辉,郑永光,韩雷,等,2021. 机器学习在强对流监测预报中的应用进展[J]. 气象,47(3):274-289. Zhou K H, Zheng Y G, Han L, et al, 2021. Advances in application of machine learning to severe convective weather monitoring and forecasting[J]. Meteor Mon, 47(3):274-289(in Chinese).
- 庄瑶,鲍瑞娟,张容焱,等,2022. 福建热带气旋灾害精细化危险性评估[J]. 应用气象学报,33(3):319-328. Zhuang Y, Bao R J, Zhang R Y, et al, 2022. Refined risk assessment of tropical cyclone disasters in Fujian[J]. J Appl Meteor Sci, 33(3):319-328 (in Chinese).
- Bakkensen L A, Mendelsohn R O, 2019. Global tropical cyclone damages and fatalities under climate change; an updated assessment [C] // Collins J M, Walsh K. Hurricane Risk. Switzerland: Springer; 179-197.
- Bender M A, Knutson T R, Tuleya R E, et al, 2010. Modeled impact of anthropogenic warming on the frequency of intense Atlantic hurricanes[J]. Science, 327(5964):454-458.
- Chen T Q, Guestrin C, 2016. XGBoost: A scalable tree boosting system[C]//Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. San Francisco: ACM; 785-794.
- Dube S K, Jain I, Rao A D, et al, 2009. Storm surge modelling for the Bay of Bengal and Arabian Sea[J]. Nat Hazards, 51(1):3-27.
- Friedman J H, 2001. Greedy function approximation; a gradient boosting machine[J]. Ann Statist, 29(5):1189-1232.
- Ke G L, Meng Q, Finley T, et al, 2017. LightGBM: A highly efficient gradient boosting decision tree[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach: Curran Associates Inc. ; 3149-3157.
- Knutson T, Camargo S J, Chan J C L, et al, 2020. Tropical cyclones and climate change assessment: Part II: projected response to anthropogenic warming[J]. Bull Amer Meteor Soc, 101(3): E303-E322.
- Krapivin V F, Soldatov V Y, Varotsos C A, et al, 2012. An adaptive information technology for the operative diagnostics of the tropical cyclones; solar-terrestrial coupling mechanisms[J]. J Atmos Sol-Terr Phys, 89:83-89.
- Mendelsohn R, Emanuel K, Chonabayashi S, et al, 2012. The impact of climate change on global tropical cyclone damage[J]. Nat Clim Change, 2(3):205-209.
- Moon I J, Kim S H, Chan J C L, 2019. Climate change and tropical cyclone trend[J]. Nature, 570(7759):E3-E5.
- Richardson M, Dominowska E, Robert R, 2007. Predicting clicks: estimating the click-through rate for new ADS[C]//Proceedings of the 16th International Conference on World Wide Web. Banff: ACM; 521-530.
- Schmidt S, Kemfert C, Höppe P, 2010. The impact of socio-economics and climate change on tropical cyclone losses in the USA[J]. Reg Environ Chang, 10(1):13-26.
- Sun H, Wang J, Ye W T, 2021. A data augmentation-based evaluation system for regional direct economic losses of storm surge disasters[J]. Int J Environ Res Public Health, 18(6):2918.
- Wang D H, Zhang Y, Zhao Y, 2017. LightGBM: an effective miRNA classification method in breast cancer patients[C]//Proceedings of the 2017 International Conference on Computational Biology and Bioinformatics. Newark: ACM; 7-11.
- Wang D N, Li L, Zhao D, 2022. Corporate finance risk prediction based on LightGBM[J]. Inform Sci, 602:259-268.
- Ye M Q, Wu J D, Liu W H, et al, 2020. Dependence of tropical cyclone damage on maximum wind speed and socioeconomic factors[J]. Environ Res Lett, 15(9):094061.
- Yonson R, Noy I, Gaillard J C, 2018. The measurement of disaster risk; an example from tropical cyclones in the Philippines[J]. Rev Dev Econ, 22(2):736-765.
- Zhang Y H, Ge T T, Tian W, et al, 2019. Debris flow susceptibility mapping using machine-learning techniques in Shigatse Area, China[J]. Remote Sens, 11(23):2801.

(本文责编:何晓欢)