



基于BP神经网络的长鳍金枪鱼渔获量与气候因子关系研究

丁鹏, 邹晓荣, 丁淑仪, 许回, 白思琦, 张子辉

Study on the Relationship between Catch of *Thunnus alalunga* and Climatic Factors Based on BP Neural Network

DING Peng, ZOU Xiaorong, DING Shuyi, XU Hui, BAI Siqi, ZHANG Zi Hui

在线阅读 View online: <https://doi.org/10.12284/hyxb2024-03>

您可能感兴趣的其他文章

Articles you may be interested in

关注微信公众号, 获得更多资讯信息



丁鹏, 邹晓荣, 丁淑仪, 等. 基于 BP 神经网络的长鳍金枪鱼渔获量与气候因子关系研究[J]. 海洋学报, 2024, 46(x): 1-8, doi:10.12284/hyxb2024-03

DING Peng, ZOU Xiaorong, DING Shuyi, et al. Study on the Relationship between Catch of Thunnus alalunga and Climatic Factors Based on BP Neural Network[J]. Haiyang Xuebao, 2024, 46(x): 1-8, doi:10.12284/hyxb2024-03

基于 BP 神经网络的长鳍金枪鱼渔获量 与气候因子关系研究

丁鹏¹, 邹晓荣^{1,2,3*}, 丁淑仪⁴, 许回⁵, 白思琦¹, 张子辉⁶

(1. 上海海洋大学 海洋生物资源与管理学院, 上海 201306; 2. 远洋渔业创新中心, 上海 201306; 3. 大洋渔业资源可持续开发省部共建教育部重点实验室, 上海 201306; 4. 山东女子学院 教育学院, 山东 济南 250300; 5. 北海道大学 水产科学研究院, 日本 北海道; 6. 山东鲁抗医药股份有限公司, 山东 济宁 272100)

摘要: 为探讨气候变化对长鳍金枪鱼渔获量的影响, 利用中西太平洋渔业委员会统计的 1960-2021 年太平洋长鳍金枪鱼年度渔获量和对应的厄尔尼诺指标 (Niño1+2、Niño3、Niño4 以及 Niño3.4)、南方涛动指数 (SOI)、北大西洋涛动 (NAO)、太平洋年代际涛动 (PDO)、北太平洋指数 (NPI) 以及全球海气温度异常指标 (dT) 等月度数据, 采用 BP 神经网络和变量敏感性分析法探讨了低频气候因子与长鳍金枪鱼渔获量的关系; 构建了结构为 6-8-1 的最优 BP 神经网络模型, 对长鳍金枪鱼渔获量进行了预测。结果表明, Niño1+2、SOI、NAO、PDO、NPI、dT 为影响长鳍金枪鱼渔获量相对独立的气候因子, 其对应的最佳滞后阶数依次为 8 年、2 年、9 年、0 年、9 年、3 年。Niño1+2、SOI、NAO 为影响长鳍金枪鱼渔获量的关键气候因子。长鳍金枪鱼渔获量预测值和实际值差值与实际值的比值自 1971 年后基本维持在 15% 以内, 预测值与实际值变化趋势基本一致, 模型拟合效果良好。

关键词: 气候变化; 长鳍金枪鱼; 相关性分析; BP 神经网络

中图分类号: S931.9

文献标志码: A

文章编号: 0253-4193(2024)x-0001-08

长鳍金枪鱼 (*Thunnus alalunga*) 广泛分布于三大洋和地中海海域^[1], 是一种重要的经济鱼种, 太平洋是其最大的渔场, 但自 1993 年以来长鳍金枪鱼的渔获量却呈减少趋势^[2], 因此研究太平洋长鳍金枪鱼渔场空间分布特征及资源丰度对气候因子的响应在近年来逐步引起海内外学者关注^[3]。

国内外学者在研究长鳍金枪鱼资源分布与海洋环境或气候变化之间的关系时, 指出海洋与气候因子是影响长鳍金枪鱼资源分布的关键因子, 但在分析长鳍金枪鱼资源丰度受海洋环境和气候变化影响时, 主要以海洋环境因子和在气候发生模式转换时对长鳍

金枪鱼的影响为主, 缺乏气候变化对长鳍金枪鱼渔业的长期影响分析。例如 Kinura^[4] 等基于 1970~1988 年日本在北太平洋的延绳钓数据研究了长鳍金枪鱼的洄游与海洋气候的关系, 认为长鳍金枪鱼在厄尔尼诺期间的逆时针洄游路径比在拉尼娜期间宽, 但实际上影响太平洋长鳍金枪鱼的海洋气候因子除了厄尔尼诺还包含太平洋涛动等其他因素; 袁红春^[5] 等认为厄尔尼诺-拉尼娜现象会引起长鳍金枪鱼产卵、洄游路线、渔场分布等鱼类行为变化, 但未能分析气候变化对长鳍金枪鱼渔获量的内在影响机制; 许回^[6] 等基于广义加性模型研究影响长鳍金枪鱼单位捕捞努力

基金项目: 渔业生产数据收集 (D-8002-12-0127-2)。

作者简介: 丁鹏 (1994—), 男, 山东省淄博市人, 研究方向为渔业资源学。E-mail: 282207687@qq.com

* **通信作者:** 邹晓荣 (1971—), 男, 硕士, 副教授, 从事捕捞学研究。E-mail: xrzou@shou.edu.cn

量渔获量 (Catch Per Unit Effort, CPUE) 与海洋环境的关系, 结果显示海表面温度是影响长鳍金枪鱼 CPUE 的最显著因子, 但未考虑气候因子及其滞后性对渔场的影响; Lu^[7] 等研究南太平洋长鳍金枪鱼与厄尔尼诺/南方涛动的关系时, 分析了气候滞后年限对 CPUE 分布的影响, 但未明确厄尔尼诺的相关指标。本文基于 BP 神经网络模型, 综合考虑了影响太平洋长鳍金枪鱼渔获量的气候因素及其滞后效应, 构建了长鳍金枪鱼渔情预测模型, 探讨气候变化对长鳍金枪鱼渔获量的长期影响, 为长鳍金枪鱼渔场与气候因子的相关研究提供参考, 同时为太平洋长鳍金枪鱼渔业管理提供依据。

1 材料与方 法

1.1 数据来源

渔业数据来自中西太平洋渔业委员会 (Western & Central Pacific Fisheries Commission, WCPFC) 所提供的太平洋长鳍金枪鱼年度渔获量 (catch) 数据, 时间跨度为 1960-2021 年。

气候变化表征因子数据来源于美国国家海洋和大气管理局 (<https://www.esrl.noaa.gov>) 发布的厄尔尼诺相关指标 (Niño1+2、Niño3、Niño4 以及 Niño3.4)、南方涛动指数 (Southern Oscillation Index, SOI)、北大西洋涛动 (North Atlantic Oscillation, NAO)、太平洋年代际涛动 (Pacific Decadal Oscillation, PDO)、北太平洋指数 (North Pacific Index, NPI); 全球海气温度异常指标 (dT) 等 9 种气候因子的月度数据由英国气象局哈德利中心 (<https://www.metoffice.gov.uk>) 所提供的。时间跨度均为 1960-2021 年。

1.2 研究方法

1.2.1 数据归一化处理

直接选用原始数据建模, 不足以获得准确的预测模型^[8]。为有利于模型的建立, 需将原始数据进行归一化的处理。由于 Min-Max 归一化^[9] 具有不改变原始数据分布的优点, 本文选定该方法对原始数据做一次线性变换, 将原始数据映射到 [0,1] 之间。首先对气候因子数据依据计算公式 1^[10] 获得年度平均数据, 依据计算公式 2^[8] 对气候因子数据及长鳍金枪鱼渔获量数据进行归一化处理, 计算公式为:

$$g_i = \frac{1}{12} \sum_{j=1}^{12} g_{ij} \quad (1)$$

$$x_{new} = \frac{x - Min}{Max - Min} \quad (2)$$

式中, g_i 为气候表征因子 i 年的年平均数据, g_{ij} 为气候

因子第 i 年 j 月的月度数据, x_{new} 、 x 、 Min 、 Max 分别为年度气候因子数据和长鳍金枪鱼渔获量数据的归一化数据、原始数据、原始数据最小值、原始数据最大值。

1.2.2 气候因子相关性分析

Spearman 秩相关系数可衡量两个变量间相关度^[11], 不易受异常值干扰, 数据不需满足正态分布的特点, 不仅可度量变量间的简单线性关系, 也可度量复杂的单调关系的强弱, 因为长鳍金枪鱼渔获量与气候变化表征因子之间的关系往往非简单的线性关系^[12], 故本研究选用 Spearman 秩相关系数来度量长鳍金枪鱼渔获量与气候变化表征因子间的相关关系。计算公式^[11] 为

$$p = 1 - \frac{6 \sum d_i^2}{n(n^2 - 1)} \quad (3)$$

式中, p 为秩相关系数; d_i 为两个变量的等级之差; p 的取值范围为 [-1,1], 绝对值越大, 表示相关性越强; n 为样本容量。

1.2.3 长鳍金枪鱼滞后年限

互相关分析可以通过两列信号相似程度最大时, 得到两列信号的时间差^[13]。在渔业上, 互相关分析常用于判断鱼群的最大滞后年限^[14]。有研究表明^[12] 气候变化因子在渔业上的影响有 15 年的滞后性, 本文选取最大滞后年限为 15 年, 各个气候变化表征因子与长鳍金枪鱼渔获量的互相关系数绝对值最大时为气候变化表征因子的最佳滞后年限, 其表达式^[10] 为:

$$R(t) = E(X_{s+t} Y_s) \quad (4)$$

式中, $R(t)$ 为 $X(s+t)$ 与 $Y(s)$ 在滞后年限 t 年的互相关系数, $E(\cdot)$ 为期望值函数, t 为滞后年限, $X(\cdot)$ 与 $Y(\cdot)$ 为时间序列。

1.2.4 构建最优 BP 神经网络模型预测长鳍金枪鱼渔获量及验证

BP 神经网络相比支持向量机、随机森林算法等具备更好的兼容性和匹配性^[15], 并且其具有结构简单、较强的自学习性和适应性的优点^[16], 被广泛地应用于数据的预测。本研究使用 matlab(R2023a) 软件构建最优 BP 神经网络模型, 并对长鳍金枪鱼渔获量进行预测。以 1960-2012 年气候表征因子滞后数据和长鳍金枪鱼渔获量数据作为训练样本, 2013-2021 年气候表征因子滞后数据和长鳍金枪鱼渔获量数据作为测试样本, 建立一个三层 BP 神经网络模型^[17-18]; 训练样本: 测试样本=53:9。以气候表征因子的滞后数据作为输入变量, 长鳍金枪鱼渔获量数据作为输出变量。设置隐含层转换函数和输出层转换函数分别

为单极性 Sigmoid 函数 (tansig) 和线性函数 (purelin)。LM 算法具有非常快速的收敛性^[12], 是一种二阶非线性优化算法, 故本文选择 LM 算法进行样本训练。设置网络最大训练次数为 1 000 次。利用隐含层节点数经验公式^[7] 计算得到隐含层的节点数:

$$m = \sqrt{k+l} + \alpha \quad (5)$$

式中, k 为输入层节点数; l 为输出层节点数; α 为 1-10 之间的常数; m 为隐含层节点数。

由经验公式 5 计算得到不同的隐含层节点数, 每个节点构建一套 BP 神经网络模型, 每套模型训练 100 次, 计算模型每次训练的效率系数^[19](coefficient of efficiency, E), 用每套模型的最优效率系数指代该模型的性能指标。效率系数越接近 1 表示预测值与实际值越接近, 模型越优良^[20]。计算公式为^[19]:

$$E = 1 - \frac{\sum_{i=1}^s (O_i - P_i)^2}{\sum_{i=1}^s (O_i - \theta)^2} \quad (6)$$

式中 O_i 为渔获量实际值; P_i 为渔获量预测值; O 为渔获量实际值的平均值; s 为样本总数; E 为效率系数。

最后将气候变化表征因子滞后数据以及长鳍金枪鱼渔获量数据输入长鳍金枪鱼渔获量预测最优 BP 神经网络模型, 得到渔获量的预测值, 比较预测值与实际值的变化趋势。计算预测值和实际值差值与实际值的比值^[17-18], 验证预测的准确性。

1.2.5 气候变化表征因子敏感性分析

敏感性分析法是在最优 BP 神经网络模型的基础上, 用来解释变量与因变量之间的关系^[21], 该方法能描述各个气候变化表征因子对长鳍金枪鱼渔获量重要性程度^[22], 本文采用敏感性分析法中的 Garson 算法的改进算法^[22] 来判断各个气候变化表征因子对长鳍

金枪鱼渔获量的影响程度。计算公式^[22] 为:

$$Q_i = \frac{\sum_{j=1}^m (|w_{ij}f_j| / \sum_{r=1}^n |w_{ij}|)}{\sum_{i=1}^n \sum_{j=1}^m (|w_{ij}f_j| / \sum_{r=1}^n |w_{ij}|)} \quad (7)$$

式中, w_{ij} 是输入层第 i 个变量对隐含层第 j 个神经元的权重, f_j 是隐含层第 j ($i=1,2,\dots,n, j=1,2,\dots,m$) 个神经元对输出层的权重。由公式 7 可知, 可以依据敏感系数数值大小来判断不同气候因子对长鳍金枪鱼渔获量的影响程度大小。

2 结果与分析

2.1 气候变化表征因子相关性分析

由图 1 Spearman 秩相关系数表可见, 气候变化表征因子 Niño1+2 与 Niño3、Niño4、Niño3.4、SOI、NAO、PDO、NPI、dT 间的相关系数分别为 0.912、0.603、0.783、-0.678、0.179、0.405、-0.297、0.185; Niño3 与 Niño4、Niño3.4、SOI、NAO、PDO、NPI、dT 间的相关系数分别为 0.81、0.948、-0.837、0.132、0.467、-0.312、0.22; Niño4 与 Niño3.4、SOI、NAO、PDO、NPI、dT 间的相关系数分别为 0.912、-0.868、0.135、0.547、-0.307、0.368; Niño3.4 与 SOI、NAO、PDO、NPI、dT 间的相关系数分别为 -0.928、0.124、0.492、-0.3、0.158; SOI 与 NAO、PDO、NPI、dT 间的相关系数分别为 -0.145、-0.586、0.408、-0.099; NAO 与 PDO、NPI、dT 间的相关系数分别为 0.139、0.067、0.026; PDO 与 NPI、dT 间的相关系数分别为 -0.674、0.236; NPI 与 dT 间的相关系数为 -0.102。为避免高度相关的气候变化表征因子在 BP 神经网络预测模型中对预测结果赋予过度的权值, 选取相关系数绝对值在 0.7 以下的气候因子集, 得到 Niño1+2、SOI、NAO、PDO、NPI、dT 这 6 个

dt	1.000								
NPI	-0.102	1.000							
PDO	0.236	-0.674	1.000						
NAO	0.026	0.067	0.139	1.000					
SOI	-0.099	0.408	-0.586	-0.145	1.000				
Niño3.4	0.158	-0.300	0.492	0.124	-0.928	1.000			
Niño4	0.368	-0.307	0.547	0.135	-0.868	0.912	1.000		
Niño3	0.220	-0.312	0.467	0.132	-0.837	0.948	0.810	1.000	
Niño1+2	0.185	-0.297	0.405	0.179	-0.678	0.783	0.603	0.912	1.000
dt	NPI	PDO	NAO	SOI	Niño3.4	Niño4	Niño3	Niño1+2	

图 1 Spearman 秩相关系数表

Fig. 1 Spearman Rank Correlation Coefficient Table

相对独立的气候变化表征因子集。

2.2 气候变化表征因子的滞后年限

由图2气候表征因子与长鳍金枪鱼互相关关系图可知, Niño1+2、SOI、NAO、PDO、NPI、dT与长鳍金枪鱼渔获量的互相关系数绝对值分别在8年、2年、9年、0年、9年、3年时达到峰值。其滞后年限各不相同,最大时为NAO的NPI的9年,最小时为PDO的0年。最佳滞后年限的相关系数与0年的相关系数比值分别为1.7、1.2、2.6、1、2、1.1,代表两者之间的差别最大的为NAO的2.6倍,最小的为PDO的1倍。

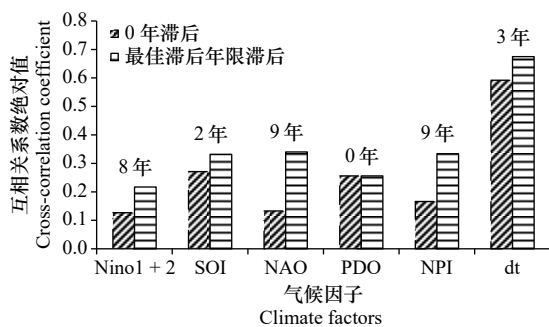


图2 气候表征因子与长鳍金枪鱼互相关关系
Fig. 2 Cross-correlation between Climate Characterization Factors and Thunnus alalunga Catch

2.3 长鳍金枪鱼渔获量的预测及验证

由经验公式5计算可知,隐含层的节点数为3-13个,即有11套BP神经网络模型运算方案。由图3可见隐含层节点数3-13个的最优效率系数,依次为0.3253、0.2939、0.3742、0.3873、0.5635、0.6602、0.6091、0.5692、0.4125、0.4431、0.3123。在隐含层节点数为8时值最大,隐含层节点数为4时值最小,因此隐含层节点数为8时定义为预测长鳍金枪鱼渔获量的最优BP神经网络预测模型,构建6-8-1结构的最优BP神经网络模型。

由图4长鳍金枪鱼渔获量预测值与实际值对比

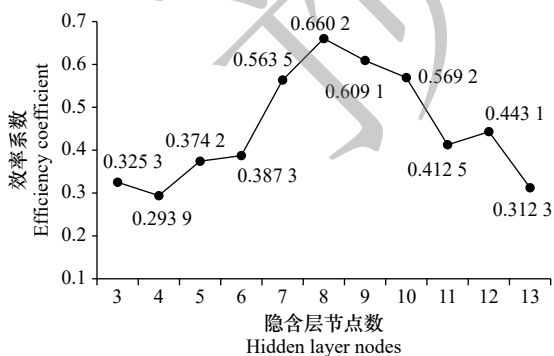


图3 BP神经网络模型的最优效率系数
Fig. 3 Efficiency coefficient of BP neural network model

图可见,1960-2021年长鳍金枪鱼渔获量实际值与预测值的变化趋势基本相同,整体均呈现先递增后递减再递增最后递减的趋势。1980年前渔获量预测值与实际值差异明显,1980年后渔获量预测值与实际值差异减弱。长鳍金枪鱼渔获量预测值与实际值均在1990年左右达到低谷后逐步提高至2003年左右的峰值,2003年后长鳍金枪鱼渔获量预测值与实际值均呈现先上升后下降趋势。

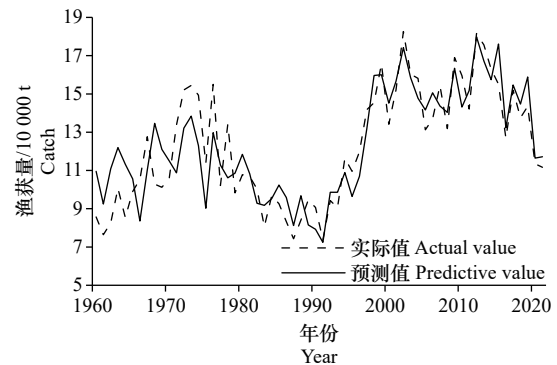


图4 长鳍金枪鱼渔获量预测值与实际值对比
Fig. 4 Comparison between the observed catch and the fitted value of Thunnus alalunga

由图5显示,长鳍金枪鱼渔获量预测值和实际值的差值与实际值的比值,在1962年达到峰值35%左右,后逐步降低至1971年的20%左右,1971年后长鳍金枪鱼渔获量预测值和实际值的差值占实际值的比值基本稳定在15%以内,且10%以内占比较10%-15%以内占比高。

2.4 气候变化表征因子敏感性分析

最优BP神经网络模型预测的输入层对隐含层的权值,隐含层对输出层的权值,由公式7计算可得,气候变化表征因子Niño1+2、SOI、NAO、PDO、NPI、dT对长鳍金枪鱼渔获量的敏感系数分别为0.2261、0.2095、0.1939、0.1049、0.1385、0.1372(图4)。Niño1+2为影响长鳍金枪鱼渔获量最显著的气候变化表征因子,其次为SOI与NAO,以上3个气候因子对长鳍金枪鱼渔获量的敏感系数均在0.2左右。NPI与dT的敏感系数均在0.14以下, PDO对长鳍金枪鱼渔获量的敏感系数在6个气候因子中最低在0.1左右。因此Niño1+2、SOI、NAO可作为影响长鳍金枪鱼渔获量的关键气候变化表征因子。

3 讨论

3.1 筛选气候因子及气候因子滞后性

本文依据Spearman秩相关分析方法从气候变化表征因子Niño1+2、Niño3、Niño4、Niño3.4、SOI、




图 5 长鳍金枪鱼渔获量实际值和预测值差值与实际值比值

Fig. 5 the ratio of the difference between the predicted and actual bigeye tuna catch to the actual catch

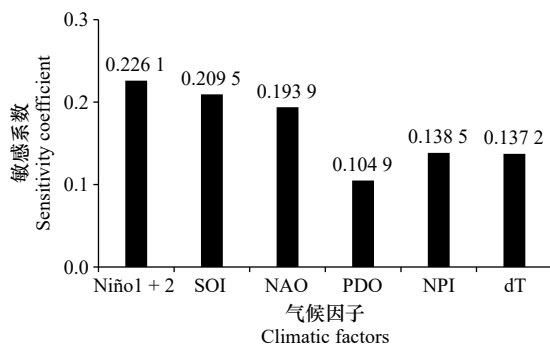


图 6 气候变化表征因子敏感性分析

Fig. 6 Sensitivity analysis of climate change characterization factors

NAO、PDO、NPI、dT 间筛选出了 Niño1+2、SOI、NAO、PDO、NPI、dT 这 6 个相互独立的气候因子。分析认为可能与 Niño1+2、Niño3、Niño4、Niño3.4 为描述不同区域的厄尔尼诺有关。王靓^[23]等认为当气候发生变化时,由于海洋自身的热惯性,特定区域的海洋生态系统响应规模较气候系统小且表现出时空异步性,鱼类资源丰度可能存在滞后的响应。本文利用互相关分析方法分析认为气候变化表征因子 Niño1+2、SOI、NAO、PDO、NPI、dT 对长鳍金枪鱼渔获量的影响的最佳滞后年限分别为 8 年、2 年、9 年、0 年、9 年、3 年。Lu^[7]等研究认为在 10°S-30°S 海域中的长鳍金枪鱼 CPUE 在厄尔尼诺-拉尼娜现象发生 8 年后会下降的现象也侧面印证了本文的结论。分析认为,这可能由于大尺度的气候不仅与鱼类资源变化有直接的相关关系,而且通过改变其它其他生物及非生物因素对鱼类产生间接影响,从而产生滞后效应^[23]。

3.2 BP 神经网络模型

本文由经验公式计算得到不同的隐含层节点数,从而构建了 11 套 BP 神经网络预测模型,以效率系数为模型的评价指标,构建了 6-8-1 的最优 BP 神经网络模型结构。依据最优 BP 神经网络预测模型预测出的长鳍金枪鱼渔获量预测值与实际值基本呈现一致的

变化趋势。长鳍金枪鱼渔获量预测值与实际值整体均呈现先递增后递减再递增最后递减的趋势。长鳍金枪鱼渔获量预测值与实际值的差值和实际值的比值也呈现由高向低的变化趋势,自 1971 年后基本维持在 15% 以内,这表明最优 BP 神经网络模型预测效果显著。分析认为 1971 年以前的预测效果相较 1971 年以后的预测效果差,这可能与早年间渔业数据收集不完整有关,与官文江^[24]等研究认为的部分渔业数据缺失,从而导致模型预测精度下降相呼应。

3.3 气候因子对长鳍金枪鱼渔获量的影响

对于本文敏感性分析提出的 Niño1+2、SOI、NAO 为影响长鳍金枪鱼渔获量的 3 个主要气候变化表征因子,已有众多研究表明它们对渔业的影响。在厄尔尼诺-南方涛动方面;王靓^[23]、肖启华^[25]、LEHODEY P^[26]认为,由于气候变化引起的海水温度等海洋环境的变化会引起长鳍金枪鱼渔获量及其分布的变化^[23, 25-26],其中海表温度影响显著。程懿麒^[21]等认为,海表温度与长鳍金枪鱼幼鱼的生长息息相关,成鱼也需要在适宜的海表温度下产卵。滞后现象可能由于厄尔尼诺-拉尼娜现象发生时对海洋环境因子等的影响有滞后效应,后通过海洋环境因子的变化影响了长鳍金枪鱼产卵和补充量^[27],进而影响长鳍金枪鱼的渔获量。此外,有研究发现,鱼类种群的分布^[28-29]、繁殖^[30]、渔获量^[31-32]、渔场空间分布^[33]等方面均与之密切相关。在 NAO 方面;主要通过调节海水温度、上层洋流、海洋密度层结等过程,影响海水 pH 值,营养盐分等的变化,从而对长鳍金枪鱼的渔获量产生影响^[34-35]。Wu^[36]等发现北太平洋的海气耦合作用通过 NAO 等气候因子调节全球的气候变化。肖启华^[12]等认为,NAO 调节着 40°N-60°N 之间西风的强弱,正 NAO 时西风增强且北移,温度升高,负 NAO 时则相反。本文所探讨的 Niño1+2、SOI、dT、NAO、PDO、NPI 等气候因子对长鳍金枪鱼的影响机理尚未完全清晰,后续需要进一步研究。

本文将气候变化表征因子作为影响长鳍金枪鱼渔获量的唯一影响因素进行研究,探讨长鳍金枪鱼渔获量受气候变化的长期影响,这有别于将气候变化变量作为影响因素之一或海洋环境变量作为影响因素的诸多短期研究^[37-38],短期研究多选择海面温度等周期较短的海洋环境变量或在某个低频气候出现模式

转换的时间区间进行研究。采用周期较长的低频气候因子研究可以从全球角度来分析长鳍金枪鱼渔业资源受气候变化的长期影响。同时,本文以气候因子作为唯一的影响因素对长鳍金枪鱼渔获量进行研究,凸显了影响长鳍金枪鱼资源的气候原因,研究结果可为长鳍金枪鱼渔业管理提供基础资料。

参考文献:

- [1] 官文江,于永恒,贺伟伟,等.长鳍金枪鱼全生命史动态能量收支预测模型[J/OL].水产学报,2023:1-15. <http://kns.cnki.net/kcms/detail/31.1283.S.20230329.1408.002.html>, 2023-09-23.
Guan Wenjiang, Yu Yongheng, He Weiwei, et al. A full lifecycle dynamic energy budget model for albacore tuna[J/OL]. Journal of Fisheries of China, 2023: 1-15. <http://kns.cnki.net/kcms/detail/31.1283.S.20230329.1408.002.html>, 2023-09-23.
- [2] Williams P, Ruaia T. Overview of tuna fisheries in the western and central Pacific Ocean, including economic conditions-2021[C]//Proceedings of the 18th Regular Session of the WCPFC Scientific Commission. 2022. (查阅网上资料,未找到本条文献出版信息,请确认)
- [3] 许回.不同空间分辨率对 LSTM 渔场预报精度的影响及在最佳空间分辨率下其预报结果与 QRM 结果的比较——以库克群岛海域长鳍金枪鱼为例[D].上海:上海海洋大学,2022.
Xu Hui. The impacts of different spatial resolutions on the fishing ground prediction accuracy of LSTM and the comparison between its prediction accuracy and that of the quantile regression model under the optimal spatial resolution—a case study on the Albacore tuna in the waters near cook islands[D]. Shanghai: Shanghai Ocean University, 2022.
- [4] Kimura S, Nakai M, Sugimoto T. Migration of albacore, *Thunnus alalunga*, in the North Pacific Ocean in relation to large oceanic phenomena[J]. *Fisheries Oceanography*, 1997, 6(2): 51–57.
- [5] 袁红春,陈冠奇,张天蛟,等.基于全卷积网络的南太平洋长鳍金枪鱼渔场预报模型[J].*江苏农业学报*, 2020, 36(2): 423–429.
Yuan Hongchun, Chen Guanqi, Zhang Tianjiao, et al. Fishing ground forecast model of albacore tuna based on fully convolutional networks in the South Pacific[J]. *Jiangsu Journal of Agricultural Sciences*, 2020, 36(2): 423–429.
- [6] 许回,宋利明,沈介然,等.基于 GAM 的库克群岛海域长鳍金枪鱼 CPUE 时空分布与海洋环境的关系[J].*海洋通报*, 2023, 42(4): 444–455.
Xu Hui, Song Liming, Shen Jieran, et al. The relationship between the spatial-temporal distribution of albacore tuna CPUE and the marine environment variables in waters near the Cook Islands based on GAM[J]. *Marine Science Bulletin*, 2023, 42(4): 444–455.
- [7] Lu H J, Lee K T, Liao C H. On the relationship between El Niño/Southern oscillation and South Pacific albacore[J]. *Fisheries Research*, 1998, 39(1): 1–7.
- [8] 杨寒雨,赵晓永,王磊.数据归一化方法综述[J].*计算机工程与应用*, 2023, 59(3): 13–22.
Yang Hanyu, Zhao Xiaoyong, Wang Lei. Review of data normalization methods[J]. *Computer Engineering and Applications*, 2023, 59(3): 13–22.
- [9] Panda S K, Nag S, Jana P K. A smoothing based task scheduling algorithm for heterogeneous multi-cloud environment[C]//Proceedings of 2014 International Conference on Parallel, Distributed and Grid Computing. Solan, India: IEEE, 2014: 62–67.
- [10] 肖启华,黄硕琳.气候变化对东南太平洋智利竹筴鱼渔获量的影响[J].*中国水产科学*, 2021, 28(8): 1020–1029.
Xiao Qihua, Huang Shuolin. Impact of climate change on Chilean jack mackerel catch in the Southeast Pacific[J]. *Journal of Fishery Sciences of China*, 2021, 28(8): 1020–1029.
- [11] 余鹏明,管孝艳,陈俊英,等.基于 Spearman 秩相关的再生水利用量影响因素研究[J].*节水灌溉*, 2019(10): 78–82,88.
Yu Pengming, Guan Xiaoyan, Chen Junying, et al. Study on factors affecting reclaimed water utilization based on spearman rank correlation[J]. *Water Saving Irrigation*, 2019(10): 78–82,88.
- [12] 肖启华.气候变化背景下东南太平洋智利竹筴鱼资源评估模型研究[D].上海:上海海洋大学,2020.
Xiao Qihua. Study on the assessment model of Chilean jack mackerel resources in the Southeast Pacific Ocean under the background of climate change[D]. Shanghai: Shanghai Ocean University, 2020.
- [13] 甘雨,马小川,阎军.空间互相关方法在分析海底沙波迁移规律中的应用[J].*海洋学报*, 2019, 41(4): 42–52.
Gan Yu, Ma Xiaochuan, Yan Jun. The application of spatial cross correlation in analyzing the migration of submarine sand waves[J]. *Haiyang Xuebao*, 2019, 41(4): 42–52.
- [14] Lu H J, Lee K T, Lin H L, et al. Spatio-temporal distribution of yellowfin tuna *Thunnus albacares* and bigeye tuna *Thunnus obesus* in the tropical Pacific Ocean in relation to large-scale temperature fluctuation during ENSO episodes[J]. *Fisheries Science*, 2001, 67(6): 1046–1052.
- [15] 陈国强,申正义,孙利,等.基于 BP 神经网络优化遗传算法的智能座舱感性意象预测[J].*汽车工程*, 2023, 45(8): 1479–1488.
Chen Guoqiang, Shen Zhengyi, Sun Li, et al. Intelligent cockpit perceptual image prediction based on BP neural network optimization genetic algorithm[J]. *Automotive Engineering*, 2023, 45(8): 1479–1488.

- [16] 李帅, 杨赫然, 孙兴伟, 等. 基于改进神经网络算法的数控钻攻中心进给轴热误差预测 [J]. 电子测量与仪器学报, 2023, 37(9): 234–242.
Li Shuai, Yang Heran, Sun Xingwei, et al. Prediction of thermal error of CNC drilling center feed axis based on improved neural network algorithm[J]. *Journal of Electronic Measurement and Instrumentation*, 2023, 37(9): 234–242.
- [17] 丁鹏, 邹晓荣, 白思琦, 等. 东南太平洋智利竹筴鱼渔场时空分析与资源丰度的预测 [J]. 大连海洋大学学报, 2021, 36(4): 629–636.
Ding Peng, Zou Xiaorong R, Bai Siqi, et al. Spatial and temporal analysis and stock abundance prediction of Chilean jack mackerel *Trachurus murphyi* in fishing ground in Southeast Pacific[J]. *Journal of Dalian Ocean University*, 2021, 36(4): 629–636.
- [18] 丁鹏, 邹晓荣, 冯超, 等. 东南太平洋智利竹筴鱼的洄游路线 [J]. 大连海洋大学学报, 2021, 36(6): 1027–1034.
Ding Peng, Zou Xiaorong, Feng Chao, et al. Migratory route of Chilean jack mackerel *Trachurus murphyi* in Southeast Pacific[J]. *Journal of Dalian Ocean University*, 2021, 36(6): 1027–1034.
- [19] 王蕾, 王鹏新, 田苗, 等. 效率系数和一致性指数及其在干旱预测精度评价中的应用 [J]. 干旱地区农业研究, 2016, 34(1): 229–235, 251.
Wang Lei, Wang Pengxin, Tian Miao, et al. Application of the coefficient of efficiency and index of agreement on accuracy assessment of drought forecasting models[J]. *Agricultural Research in the Arid Areas*, 2016, 34(1): 229–235, 251.
- [20] 陈皓锐, 黄介生, 伍靖伟, 等. 灌溉用水效率尺度效应研究评述 [J]. 水科学进展, 2011, 22(6): 872–880.
Chen Haorui, Huang Jiesheng, Wu Jingwei, et al. Review of scale effect on the irrigation water use efficiency[J]. *Advances in Water Science*, 2011, 22(6): 872–880.
- [21] 程懿麒, 张俊波, 汪金涛, 等. 基于神经网络的印度洋长鳍金枪鱼 (*Thunnus alalunga*) 时空分布与海洋环境关系研究 [J]. 海洋与湖沼, 2021, 52(4): 960–970.
Cheng Yiqi, Zhang Junbo, Wang Jintao, et al. Study on the relationship between temporal-spatial distribution of Indian ocean albacore (*Thunnus alalunga*) and marine environment based on neural network[J]. *Oceanologia et Limnologia Sinica*, 2021, 52(4): 960–970.
- [22] 蔡毅, 邢岩, 胡丹. 敏感性分析综述 [J]. 北京师范大学学报 (自然科学版), 2008, 44(1): 9–16.
Cai Yi, Xing Yan, Hu Dan. On sensitivity analysis[J]. *Journal of Beijing Normal University (Natural Science)*, 2008, 44(1): 9–16.
- [23] 王靓, 花传祥, 朱清澄, 等. 北太平洋小型中上层鱼类资源对气候-海洋变化的响应研究进展 [J]. 中国水产科学, 2020, 27(11): 1379–1392.
Wang Liang, Hua Chuanxiang, Zhu Qingcheng, et al. Review on the response of small pelagic fishery resources in the North Pacific to climate-ocean changes[J]. *Journal of Fishery Sciences of China*, 2020, 27(11): 1379–1392.
- [24] 官文江, 朱江峰, 高峰. 印度洋长鳍金枪鱼资源评估的影响因素分析 [J]. 中国水产科学, 2018, 25(5): 1102–1114.
Guan Wenjiang, Zhu Jiangfeng, Gao Feng. Analysis of influencing factors on stock assessment of the Indian Ocean albacore tuna (*Thunnus alalunga*)[J]. *Journal of Fishery Sciences of China*, 2018, 25(5): 1102–1114.
- [25] 肖启华, 黄硕琳. 气候变化对海洋渔业资源的影响 [J]. 水产学报, 2016, 40(7): 1089–1098.
Xiao Qihua, Huang Shuolin. Climate change implications for marine fishery resources[J]. *Journal of Fisheries of China*, 2016, 40(7): 1089–1098.
- [26] Lehodey P, Alheit J, Barange M, et al. Climate variability, fish, and fisheries[J]. *Journal of Climate*, 2006, 19(20): 5009–5030.
- [27] 方海, 张衡, 刘峰, 等. 气候变化对世界主要渔业资源波动影响的研究进展 [J]. 海洋渔业, 2008, 30(4): 363–370.
Fang Hai, Zhang Heng, Liu Feng, et al. A summary of research progress related with the fluctuation of the worldwide main marine fishery resources influenced by climate changes[J]. *Marine Fisheries*, 2008, 30(4): 363–370.
- [28] Hampton J, Lewis A, Williams P. The western and central Pacific tuna fishery: overview and status of stocks[M]//SPC. Oceanic Fisheries Programme. New Caledonia: Secretariat of the Pacific Community, 1999. (查阅网上资料, 未找到本条文献信息, 请确认)
- [29] Hampton J. Estimates of tag-reporting and tag-shedding rates in a large-scale tuna tagging experiment in the western tropical Pacific Ocean[J]. *Oceanographic Literature Review*, 1997, 95(1): 68–79.
- [30] Bakun A, Parrish R H. Comparative studies of coastal pelagic fish reproductive habitats: the Brazilian sardine (*Sardinella aurita*)[J]. *ICES Journal of Marine Science*, 1990, 46(3): 269–283.
- [31] Deary A L, Moret-Ferguson S, Engels M, et al. Influence of Central Pacific oceanographic conditions on the potential vertical habitat of four tropical tuna species[J]. *Pacific Science*, 2015, 69(4): 461–475.
- [32] Ernesto T O, Arturo M M, Armando T, et al. Variation in yellowfin tuna (*Thunnus albacares*) catches related to El Niño-Southern Oscillation events at the entrance to the Gulf of California[J]. *Fishery Bulletin*, 2006, 104(2): 197–203.
- [33] Williams P, Ruaia T. Overview of tuna fisheries in the western and central Pacific Ocean, including economic conditions –2019[C]//Proceedings of the 16th WCPFC Scientific Committee Meeting (SC16). Pohnpei State, Federated States of Micronesia: WCPFC, 2020: 7. (查阅网上资料, 未找到本条文献出版信息, 请确认)
- [34] 丁鹏, 邹晓荣, 丁淑仪, 等. 基于 CNN-BiLSTM 模型的黄鳍金枪鱼渔获量与气候因子关系研究 [J]. 南方水产科学, 2024, 20(2): 19–26.
Ding Peng, Zou Xiaorong, Ding Shuyi, et al. Study on relationship between *Thunnus albacares* catches and climatic factors based on CNN-BiLSTM model[J]. *South China Fisheries Science*, 2024, 20(2): 19–26.
- [35] 徐策, 张力, 余静, 等. 气候变化对中国近海捕捞渔业的影响——以太平洋年代际涛动为例 [J]. 资源科学, 2022, 44(2): 386–400.

- Xu Ce, Zhang Li, Yu Jing, et al. Impact of climate change on China's offshore fishing: taking the Pacific Decadal Oscillation as an example[J]. *Resources Science*, 2022, 44(2): 386–400.
- [36] Wu Lixin, Liu Zhengyu, Liu Yun, et al. Potential global climatic impacts of the North Pacific Ocean[J]. *Geophysical Research Letters*, 2005, 32(24): L24710.
- [37] 张嘉容, 杨晓明, 戴小杰, 等. 南太平洋长鳍金枪鱼延绳钓渔获率与环境因子的关系研究 [J]. *南方水产科学*, 2020, 16(1): 69–77.
Zhang Jiarong, Yang Xiaoming, Dai Xiaojie, et al. Relationship between catch rate of longline albacore (*Thunnus alalunga*) and environmental factors in South Pacific[J]. *South China Fisheries Science*, 2020, 16(1): 69–77.
- [38] 闫敏, 张衡, 樊伟, 等. 南太平洋长鳍金枪鱼渔场 CPUE 时空分布及其与关键海洋环境因子的关系 [J]. *生态学杂志*, 2015, 34(11): 3191–3197.
Yan Min, Zhang Heng, Fan Wei, et al. Spatial-temporal CPUE profiles of the albacore tuna (*Thunnus alalunga*) and their relations to marine environmental factors in the South Pacific Ocean[J]. *Chinese Journal of Ecology*, 2015, 34(11): 3191–3197.

Study on the Relationship between Catch of *Thunnus alalunga* and Climatic Factors Based on BP Neural Network

DING Peng¹, ZOU Xiaorong^{1,2,3}, DING Shuyi⁴, XU Hui⁵, BAI Siqu¹, ZHANG Zi Hui⁶

(1. College of Marine Living Resource Sciences and Management, Shanghai Ocean University, Shanghai 201306, China; 2. Collaborative Innovation Center for National Distant-water Fisheries, Shanghai 201306, China; 3. Key Laboratory of Sustainable Exploitation of Oceanic Fisheries Resources, Ministry of Education, Shanghai 201306, China; 4. School of Education, Shandong Women's University, Jinan 250300, China; 5. Hokkaido University, Graduate School of Fisheries Science, Japan Hokkaido; 6. Shandong Lukang Pharmaceutical Co, JiNing 277100, China)

Abstract: In order to investigate the impact of climate change on the catch of bigeye tuna, we utilized the annual Pacific bigeye tuna catch data from 1960 to 2021, which was statistically compiled by the Western and Central Pacific Fisheries Commission. We also employed corresponding monthly climate indices, including Niño1+2, Niño3, Niño4, Niño3.4, Southern Oscillation Index (SOI), North Atlantic Oscillation (NAO), Pacific Decadal Oscillation (PDO), North Pacific Index (NPI), and global sea-air temperature anomaly (dT). By using a BP neural network and variable sensitivity analysis, we examined the relationship between these low-frequency climate factors and bigeye tuna catch. Our findings revealed that Niño1+2, SOI, NAO, PDO, NPI, and dT are relatively independent climate factors that have an impact on bigeye tuna catch. The optimal lag orders for these climate factors were determined to be 8 years for Niño1+2, 2 years for SOI, 9 years for NAO, 0 years for PDO, 9 years for NPI, and 3 years for dT. Among these factors, Niño1+2, SOI, and NAO were identified as the key climate factors influencing bigeye tuna catch. We constructed an optimal BP neural network model with a structure of 6-8-1, and the ratio of the difference between the predicted and actual bigeye tuna catch to the actual catch has been maintained within 15% since 1971. Additionally, the trend of the predicted and actual catch was found to be basically consistent, indicating a satisfactory level of model fit.

Key words: climate change; *Thunnus alalunga*; correlation analysis; BP neural network model