



基于深度学习的西北太平洋柔鱼渔场预测

解明阳¹, 柳 彬^{1,2,3}, 陈新军^{1,4,5,6*}

(1. 上海海洋大学海洋科学学院, 上海 201306;

2. 自然资源部海洋生态监测与修复技术重点实验室, 上海 200137;

3. 自然资源部第二海洋研究所, 卫星海洋环境动力学国家重点实验室, 浙江 杭州 310012;

4. 上海海洋大学, 农业农村部大洋渔业可持续利用重点实验室, 上海 201306;

5. 上海海洋大学, 国家远洋渔业工程技术研究中心, 上海 201306;

6. 上海海洋大学, 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)

摘要: 柔鱼为西北太平洋主要的经济头足类物种, 准确判别渔场空间分布能够更科学、有效地为渔业生产提供依据。在海洋渔业和海洋遥感的大数据时代下, 如何提高模型精度、稳定性、计算效率, 提取并挖掘有价值信息成为渔场学研究的挑战性问题。为此, 本研究基于深度学习和渔场学理论, 采用人工智能最前沿的 U-Net 模型, 以海表面温度 (SST) 为输入因子, 中心渔场分布为输出因子, 构建了 1998—2019 年每年 7—11 月中心渔场预测模型。结果显示, 验证集准确率为 86.7%, 训练集准确率为 89.7%, 测试集 (2020 年) 的准确率、精确率、召回率和 F1 分数分别为 87.2%、0.91、0.87 和 0.89, 实际作业的渔获量数据与预测的中心渔场范围基本匹配, 模型应用效果良好。在不同气候事件下, 模型性能具有较好的适应能力。模型分析显示, 厄尔尼诺事件下中心渔场纬度向南偏移, 拉尼娜事件则相反。研究表明, 本研究构建的 U-Net 模型可有效解决复杂数据下渔场预测的问题, 提高渔场预测模型精度。本研究可为人工智能技术实现中心渔场的预报提供基础, 具有很好的应用前景。

关键词: 柔鱼; 渔场; 深度学习; U-Net 模型; 西北太平洋

中图分类号: S 934; TP 181

文献标志码: A

柔鱼 (*Ommastrephes bartramii*) 为西北太平洋海域重要的经济头足类之一^[1], 自 1993 年我国开发和利用柔鱼资源以来, 年产量稳定在 6 万~10 万 t, 是我国远洋渔业重要的捕捞对象^[2]。柔鱼的中心渔场学分析是渔情预报中的重要研究内容, 其研究结果可为渔业生产提供指导性服务, 准确预报渔场出现的位置对提高渔业捕捞产量、节省燃油有重要意义^[3]。由于柔鱼是短生命周期的机会主义物种, 其渔场空间变动极易受海洋气候环

境的影响且变化较大^[4], 因此, 柔鱼渔场预测通常是结合海洋遥感数据, 分析海洋气候、环境因子与柔鱼空间分布之间的关系, 并建立线性或非线性模型对柔鱼渔场进行回归预测。目前, 国内外学者对柔鱼渔场的预测方法主要有朴素贝叶斯方法^[5]、人工神经网络^[6]、环境阈值法 (空间叠加法)^[7]、栖息地适宜性指数^[8]等。随着空间技术和传感器技术以及捕捞作业技术的不断发展, 海洋遥感及渔业已进入大数据时代, 面对大量复杂的

收稿日期: 2022-04-18 修回日期: 2022-07-05

资助项目: 国家自然科学基金 (NSFC42476086, NSFC42006159); 上海市科技创新行动计划 (19DZ1207502); 卫星海洋环境动力学国家重点实验室资助项目 (QNHX2238)

第一作者: 解明阳 (照片), 从事人工智能渔业学、渔业资源研究, E-mail: 772966694@qq.com

通信作者: 陈新军, 从事渔业资源与渔场学、远洋鱿钓渔业研究, E-mail: xjchen@shou.edu.cn



数据, 传统方法在柔鱼渔场预测问题上面临着一系列挑战, 挑战在于如何提升大数据的应用效能, 进一步提高模型精度与稳定性, 提高模型计算效率, 提取并挖掘有价稀疏信息, 以及解释影响渔场时空变化的机制等。

传统方法在柔鱼渔场预测的精度方面维持在 70%~80%^[4, 9-10], 时空分辨率较低, 数量较少, 验证数据不充分, 结果存在一定的不稳定性。同时, 柔鱼渔场的环境场又是一个复杂、动态、综合的变化过程, 且具有很强的时间和空间相关性, 利用传统的渔场预测方法已经很难高效率、高精度地完成, 并且从大量复杂的数据中挖掘有价值信息。深度学习作为近年来人工智能领域新兴的一项强大技术, 在许多工业领域的应用中取得了较好的成果, 与传统的基于物理或统计的信息提取算法相比, 其优势更加明显, 并开始在海面遥感及渔业中展开应用^[11-12]。U-Net 模型作为深度学习中的语义分割中经典的网络模型, 更善于处理图像空间特征, 其结构简单, 参数量少, 利用全卷积的卷积神经网络层可以将图像的浅层特征与深层特征进行融合, 能够更好地进行像素点识别, 提取局部有效特征^[13]。目前, 此方法已在海岸洪水预测^[14]、降水预测^[15]、海表面风反演^[16]等方面取得了较好的效果。

在柔鱼渔场学分析中, 海表面温度 (sea surface temperature, SST) 是影响渔场变化的主要因素之一^[17], 无论是 SST 还是柔鱼渔场的空间变化都可以看作图像上像素点的变化, 且具有很强的空间相关性与时间关联性。为此, 本研究采用 1998—2020 年渔业生产统计数据作为输出数据, SST 分布数据作为输入数据, 利用 U-Net 模型对柔鱼的中心渔场进行实时预测, 为实现未来时刻的柔鱼渔场预测奠定基础, 在大数据背景下提高对柔鱼渔场变动的认识, 为实现高效、高精度、智能化的柔鱼渔情预报提供技术支撑。

1 材料与方法

1.1 数据来源

数据来源包括渔业数据和环境数据。渔业生产统计数据来自上海海洋大学中国远洋渔业数据中心, 研究区域选取传统的柔鱼作业渔场 (图 1), 时间范围为 1998—2020 年每年的 7—11 月, 地理范围为西北太平洋的 36°~48°N、145°~165°E 公海

区域, 统计内容包括日期、经纬度、日产量和作业渔船, 时间分辨率为旬, 空间分辨率为 0.05°×0.05°。




图 1 西北太平洋柔鱼渔场分布示意图

Fig. 1 Distribution of *O. bartramii* fishing ground in the Northwest Pacific

环境数据为 SST, 来源于美国国家海洋和大气管理局 (NOAA) 的 Oceanwatch 网站 (<http://oceanwatch.pifsc.noaa.gov/erddap/index.html>), 时间、空间分辨率与渔业数据一致, 并将环境数据与渔业数据进行栅格化处理, 完成匹配对应。

1.2 数据预处理

渔场的定义与等级划分 已有研究表明^[17], 柔鱼中心渔场受环境因子尤其是 SST 的影响。柔鱼作为短生命周期的机会主义物种, 其资源丰度变化具有明显的季节性差异, 因此, 本研究将每年每月每旬的资源丰度指数对应的 SST 范围作为表征渔场的环境指标。渔业数据是“仅包含发现”数据 (presence-only), 即有记录站点表示有渔获量, 但无记录站点并不能代表没有渔获量^[18], 因此各旬渔场的 SST 范围取最大值和最小值。

由于潜在渔场具有资源丰度离散程度大, 高资源丰度值较为集中的特点, 同时能更好地适应模型的需要, 将渔场等级按照各旬的资源丰度指数进行四分位数划分, 大于上四分位数的渔场定义为中心渔场 (标签用 1 表示), 其余为非中心渔场 (标签用 0 表示)。

在渔业生产中, 通常用渔获量 (Catch)、捕捞努力量 (Effort)、单位捕捞努力量渔获量 (Catch per unit effort, CPUE) 作为资源丰度指数^[19]。因为 Catch 指数相比于其他指数量级差异显著, 能更好

地根据四分位数划分出中心渔场, 故选择 Catch 指数作为资源丰度指数 (表 1)。

标准化与无效值处理 为了统一数据的量纲, 提高模型运转效率, 将 SST 数据归一化到 0~1, 计算公式^[20]:

$$x = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$

式中, x 表示样本归一化后的值, x_i 表示样本原始值, x_{\max} 和 x_{\min} 分别表示样本中的最大值和最小值。对于无效值, 全部用-1 替代。

1.3 U-Net 模型架构

U-Net 模型采用全卷积层的架构, 主要分为两个部分: 前半部分为卷积 (下采样) 特征提取, 后半部分为反卷积 (上采样, upsample) 预测 (图 2)。在前半部分, 一共进行 4 次下采样处理, 每次下

采样都有 2 个卷积层 (conv)、激活函数层和 1 个最大池化层 (max pool), 卷积层中卷积核的大小为 3×3, 步数为 1, 第 1 次卷积的卷积核数量设置为 32, 经过第 1 次卷积后, 样本的特征通道数从 1 变为 32; 激活函数为 ReLU 函数, 主要目的是

表 1 不同资源丰度指数特征对比

Tab. 1 Comparison of characteristics of different abundance indexes

资源丰度指数 abundance index	渔获量/t Catch	捕捞努力量/船 Effort	单位捕捞努力 量渔获量/(t/船) CPUE
最小值 minimum value	0.001	1	0.001
最大值 maximum value	1047	203	5.158
量级差 magnitude difference	10 ⁶	10 ²	10 ³

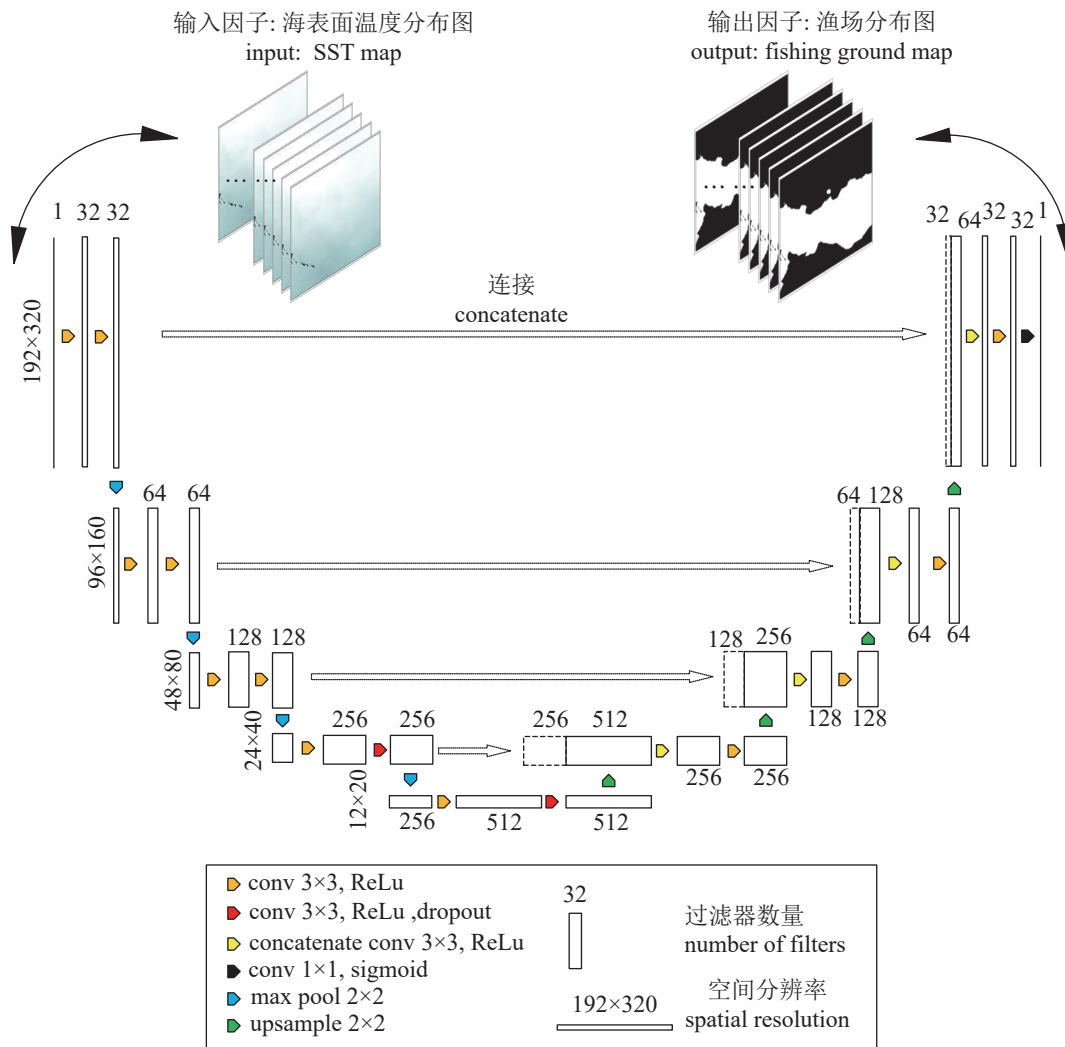


图 2 U-Net 网络架构图

Fig. 2 Architecture of U-Net model

为卷积层输出增加非线性, 增强学习非线性的特征; 最大池化层的过滤器大小为 2×2 , 步数为 2, 经过池化后, 样本的大小缩小了 1 倍, 但样本的特征通道数增大了 1 倍, 主要目的是对特征进行压缩、简化网络复杂度、减小参数和计算量, 保持检测特征的尺度不变, 并提高网络对噪声和杂波的鲁棒性。由于模型的过拟合较严重, 本研究在模型的第 3、4 次采样的最后一个卷积层分别加入了 Spatial Dropout 2D 层, 这里是整个 U-Net 模型参数最多、结构最复杂的地方, 所以在此加入 Spatial Dropout 2D 层效果更好, dropout 参数为 0.75。在后半部分, 同样进行对称的 4 次上采样处理, 因为最后一层卷积层的输入为二分类问题, 所以激活函数为 sigmoid。

经过卷积和反卷积, 从编码到解码的过程, 在样本大小保持一致的基础上有效地提取了图片特征, 确保了不同层上的特征之间的语义连通性, 实现了网络的端对端, 达到预测西北太平洋柔鱼渔场的效果。

1.4 模型评价与检验

通常用准确率 (accuracy) 评价模型的好坏。准确率指所有样本中预测结果正确的比例。检验模型预测的结果好坏, 除了用准确率之外, 通常计算预测结果的精确率 (precision)、召回率 (recall) 和 F1 分数 (F1-score)。精确率指在预测为中心渔场的结果中预测正确的比例, 召回率指中心渔场被预测出来的比例, F1 分数指精确率和召回率的调和平均, 由于准确率和召回率之间存在此消彼长的关系, 所以计算 F1 得分来综合考虑模型的稳定性。计算公式^[13]:

$$\text{准确率} = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (2)$$

$$\text{精确率} = \frac{TP}{TP + FP} \quad (3)$$

$$\text{召回率} = \frac{TP}{TP + FN} \quad (4)$$

$$\text{F1 分数} = \frac{2 \times TP}{2 \times TP + FP + FN} \quad (5)$$

式中, TP (true positive) 表示真实中心渔场被预测为中心渔场的数量, TN (true negative) 表示真实非中心渔场被预测为非中心渔场的数量, FP (false positive) 表示真实非中心渔场被预测为中心渔场的数量, FN (false negative) 表示真实中心渔场被

预测为非中心渔场的数量。

1.5 实验设计

本研究所使用的图片处理器 (GPU) 型号为 GeForce RTX 2080 Ti, 操作系统为 Linux, 搭建了基于 Python 3.7 的 Tensorflow 2.4.1 框架实现 U-Net 模型。

实验数据集为 1998—2019 年 7—11 月西北太平洋 $36^\circ \sim 48^\circ \text{N}$ 、 $145^\circ \sim 165^\circ \text{E}$ 区域的 SST 分布图与中心渔场分布图, 将 1998—2019 年的 660 张图片 (输入和输出各 330 张) 按照 80% 和 20% 划分为训练集和验证集, 将 2020 年的 15 张图片作为测试集。

2 结果

2.1 渔场 SST 分布情况

从西北太平洋柔鱼每旬中心渔场的 SST 分布状况来看, 8—10 月 SST 样本数量多且聚集, 7、11 月 SST 样本点数量少且分散 (图 3), 表明 8—10 月的渔船产量均匀分布且作业环境的 SST 较为连续, 而 7、11 月的渔船高产量分布集中, 整体上各旬 SST 分布呈现明显的季节性变化。从每旬中心渔场的 SST 范围变化来看 (图 4), SST 最大值在 9 月下旬之前基本变化不大, 在 10 月上旬后




图 3 西北太平洋柔鱼每旬中心渔场的海表面温度分布状况

1. 7 月上旬, 2. 7 月中旬, 3. 7 月下旬, 4. 8 月上旬, 5. 8 月中旬, 6. 8 月下旬, 7. 9 月上旬, 8. 9 月中旬, 9. 9 月下旬, 10. 10 月上旬, 11. 10 月中旬, 12. 10 月下旬, 13. 11 月上旬, 14. 11 月中旬, 15. 11 月下旬; 图 4 和图 8 同。

Fig. 3 SST distribution of fishing ground of *O. bartramii* in each ten days in the Northwest Pacific

1. Jul_1st, 2. Jul_2nd, 3. Jul_3rd, 4. Aug_1st, 5. Aug_2nd, 6. Aug_3rd, 7. Sep_1st, 8. Sep_2nd, 9. Sep_3rd, 10. Oct_1st, 11. Oct_2nd, 12. Oct_3rd, 13. Nov_1st, 14. Nov_2nd, 15. Nov_3rd; the same as Fig. 4 and Fig. 8.

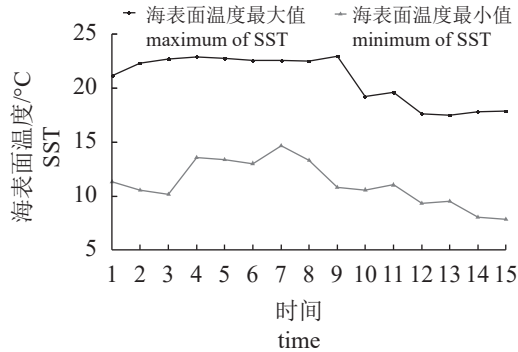


图4 西北太平洋柔鱼每旬中心渔场的海表面温度范围变化

Fig. 4 Variation of SST range in fishing ground of *O. bartramii* in each ten days in the Northwest Pacific

骤降且持续到10月结束, 11月保持稳定; SST最小值大致呈现先上升后下降的趋势, 在9月上旬的SST最小值最高。因此, 7月SST范围面积最大, 10月SST范围面积最小, 所对应的中心渔场面积大小随SST范围变化而变化。

2.2 中心渔场判别

从U-Net模型的损失函数变化来看, 训练集的损失值持续稳定下降, 验证集的损失值在迭代次数50次之前快速下降, 之后处于波动状态, 在第190次迭代后出现过拟合, 训练集的损失值为0.227, 验证集的损失值为0.291(图5)。从准确率变化来看, 训练集的准确率持续稳定上升, 验证集的准确率同样在迭代次数50次之前快速上升, 之后在84%上下波动, 在验证集的损失值最小时, 验证集准确率最大为86.7%, 训练集准确率89.7%(图6)。整体上, 模型的准确率虽然有一定的波动, 但结果较好。

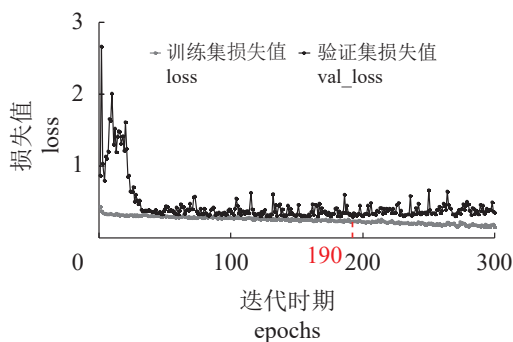


图5 模型损失值曲线图

Fig. 5 Curve of loss value of U-Net model

从测试集的结果来看(表2), 2020年的平均准确率为87.2%, 平均精确率为0.91, 平均召回




图6 模型准确率曲线图

Fig. 6 Curve of accuracy value of U-Net model

表2 2020年7—11月模型检验结果

Tab. 2 Results of the model from July to November in 2020

旬 ten-days	准确度/% accuracy	精确度 precision	召回率 recall	F1得分 F1-score
7月上旬 Jul-1st	86.6	0.87	0.87	0.87
7月中旬 Jul-2nd	88.3	0.98	0.85	0.91
7月下旬 Jul-3rd	77.9	0.99	0.73	0.85
8月上旬 Aug-1st	89.4	0.89	0.93	0.91
8月中旬 Aug-2nd	92.9	0.89	0.97	0.93
8月下旬 Aug-3rd	95.8	0.99	0.92	0.96
9月上旬 Sep-1st	94.4	0.91	0.99	0.95
9月中旬 Sep-2nd	94.7	0.98	0.92	0.95
9月下旬 Sep-3rd	83.2	1.00	0.78	0.87
10月上旬 Oct-1st	78.0	0.75	0.88	0.81
10月中旬 Oct-2nd	88.8	0.87	0.93	0.90
10月下旬 Oct-3rd	78.6	0.79	0.79	0.79
11月上旬 Nov-1st	89.4	0.87	0.90	0.89
11月中旬 Nov-2nd	84.7	0.95	0.78	0.85
11月下旬 Nov-3rd	85.6	0.95	0.79	0.86
平均值 average	87.2	0.91	0.87	0.89

率为0.87, 平均F1得分为0.89, 模型的测试结果较好, 证明模型的精度与泛化能力良好。

3 讨论

3.1 SST对渔场空间变化的影响

西北太平洋柔鱼是短生命周期物种, 其生命周期大致为1年, 所以其生活史过程对气候和海洋环境变化非常敏感, 尤其是SST。当气候和海洋环境变化导致SST变化时, 柔鱼种群会立刻转移至适宜的SST范围^[21]。有研究认为, 柔鱼在各月的适宜SST范围有明显差异。如Chen等^[22]认为, 柔鱼5—11月的适宜SST范围分别为12~14、15~16、14~16℃、18~19℃、16~17℃、15~16℃

和 12~13℃, 明显成季节性变化。余为等^[23]研究发现, 柔鱼渔场范围内适宜的水温面积增加, 对应的柔鱼资源丰度上升。而适宜的水温面积较小时, 柔鱼资源丰度将会降低。本研究结果的中心渔场 SST 范围相比于前人结果来说, 范围更大, 变化更为明显, 原因在于选取数据的时间长度更长, 为 1998—2019 年, 包含了 20 多年不同气候事件和海洋环境因子变化对柔鱼中心渔场的影响; 时间尺度也更为精细, 相比于各月的最适 SST 范围, 各旬的最适 SST 范围变化更为明显, 尤其在高产量月份 9 月, 中心渔场 SST 最小值下降趋势显著 (图 3, 图 4), 表明较长的时间序列和较精细的时空尺度利于预测柔鱼的中心渔场, 从而为后续模型训练的精度提供质量更好的数据集。

3.2 厄尔尼诺和拉尼娜事件对中心渔场的影响

厄尔尼诺和拉尼娜事件源于赤道太平洋中东部海域出现的一股异常暖或冷的水团, 为气候系统中最强的年际气候信号, 对太平洋渔业有极大的影响^[24]。有研究表明, 西北太平洋柔鱼同样受到厄尔尼诺和拉尼娜事件的调控, 如 Chen 等^[25]认为厄尔尼诺事件发生时产卵场温度环境有利于增加柔鱼资源量且其渔场会向南偏移, 而拉尼娜事件相反。Yu 等^[26]认为, 与厄尔尼诺事件相比, 拉尼娜事件和正常年份扩大了柔鱼的适宜栖息地, 纬度重心进一步向北移动。Alabia 等^[27]认为拉尼娜事件有利于形成柔鱼的产卵场和育肥场的环境, 从而使适宜栖息地范围增加, 但短暂和较弱的厄尔尼诺事件也会增加栖息地面积。因此, 不同气候事件对柔鱼的影响有显著差异, 且需要考虑到不同强度及模态的情况。根据美国 NOAA 对厄尔尼诺和拉尼娜事件强度的定义, 将 1998—2019 年按照定义进行划分, 来分析各强度事件下的中心渔场情况, 从结果可见 (图 7), 各年渔场范围的 SST 平均值的变化与厄尔尼诺-拉尼娜事件 (ENSO) 转换相吻合, 拉尼娜事件下 SST 平均值较高, 厄尔尼诺事件相反, SST 平均值与 Niño 3.4 区的 ONI 指数呈负相关。不同强度气候事件下的中心渔场 SST 平均值差别显著, 高强度拉尼娜事件下的 SST 平均值最高, 中等强度厄尔尼诺事件下的 SST 平均值最低, 且综合来看, 相比于厄尔尼诺事件, 拉尼娜事件下中心渔场的 SST 平均值较高, 此现象反映在中心渔场面积比例上, 厄尔尼诺事件的中心渔场面积要比拉尼娜事件的稍大, 最高

比例为弱厄尔尼诺事件, 最低比例为强拉尼娜事件, 这与 Chen 等^[25]的研究结果大致吻合, 从而也证明了不同强度的气候事件对柔鱼的中心渔场情况影响不同, 需要根据具体的气候事件类型以及特定年份来分析。

由于柔鱼中心渔场分布受不同强度气候事件调控, 且各年的调控作用不同, 本研究取平均渔获量最高的 8 月下旬 (图 8) 进行各年模型预测结果的对比分析, 从结果来看 (图 9), 模型的预测效果较好, 能够准确地预测中心渔场的空间分布, 提取空间分布特征, 并适应不同气候事件下的年际变化。中心渔场空间范围的定义是根据 SST 特征划分的, 所以中心渔场的空间分布特征大致为带状分布, 经过 U-Net 模型的训练, 机器学习很好地学到了渔场分布特征的知识, 在拉尼娜和厄尔尼诺事件相互转换的年份, 中心渔场的纬度由北向南偏移, 这与 Yu 等^[26]研究的结果一致, 尤其在 2004—2010 年和 2015—2018 年气候事件类型转换频繁, 纬度的南北偏移幅度更为明显, 模型更能较好地响应不同模态的变化。

3.3 模型的应用效果

从测试集的结果来看, 2020 年 7—11 月各旬的平均准确率、精确率、召回率和 F1 得分分别为 87.2%、0.91、0.87 和 0.89 (表 2), 说明模型的精度和稳健性均较高, 且应用效果较好, 为了检验渔业实际生产数据与预测的中心渔场拟合效果, 将二者进行对比, 结果显示, 除了 7 月上旬和 7 月中旬没有实际生产数据之外, 其他各旬的实际产量数据站点均几乎落在预测的中心渔场范围内 (图 10), 高产量数据站点全部落在渔场范围内, 应用效果较好。模型应用效果较好主要有以下几点原因: ①大数据的情况下保证了机器学习到了各种渔场类型出现的可能性, 尤其是在年际变化的厄尔尼诺-拉尼娜事件下, 训练和验证样本至少包括了 9 次气候事件的转变情况, 使得测试集得到了更好的效果。②利用上四分位数划分渔场等级得到的中心渔场范围也能较好地囊括低渔获量的实际生产作业渔场, 针对渔场的数据特征来定义中心渔场的方法可行且较为可靠, 能够更好地将深度学习应用在渔场的预测上。③卷积神经网络 (CNN) 能够更好地处理图像像素点的分类, 作为输入因子和输出因子的 SST 分布图和中心渔场图都具有很强的空间相关性, 在提取特征图时,

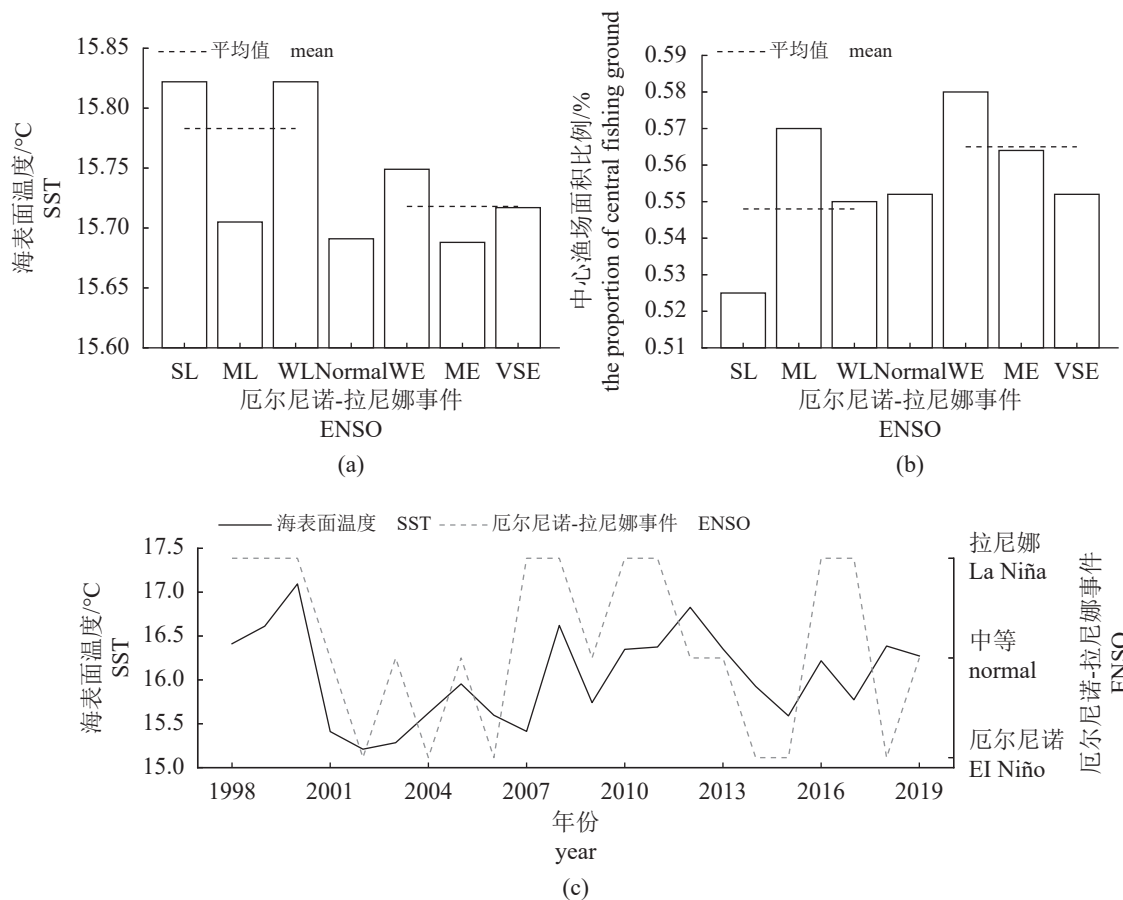


图 7 1998—2019 年不同气候事件下中心渔场相关参数

(a) SST 分布, (b) 中心渔场面积比例, (c) SST 变化; SL. 高强度拉尼娜事件, ML. 中等强度拉尼娜事件, WL. 弱拉尼娜事件, Normal. 正常气候事件, WE. 弱厄尔尼诺事件, ME. 中等强度厄尔尼诺事件, VSE. 超高强度厄尔尼诺事件。

Fig. 7 Relevant parameters of center fishing ground under different climate events

(a) SST distribution, (b) the proportion of center fishing ground, (c) SST variation. SL. strong La Niña event, ML. moderate La Niña event, WL. weak La Niña event, Normal. normal climate event, WE. weak El Niño event, ME. moderate El Niño event, VSE. very strong El Niño event.




图 8 1998—2020 年 7—11 月各旬中心渔场的平均产量

Fig. 8 Average catch of fishing ground during July to November over 1998 to 2020

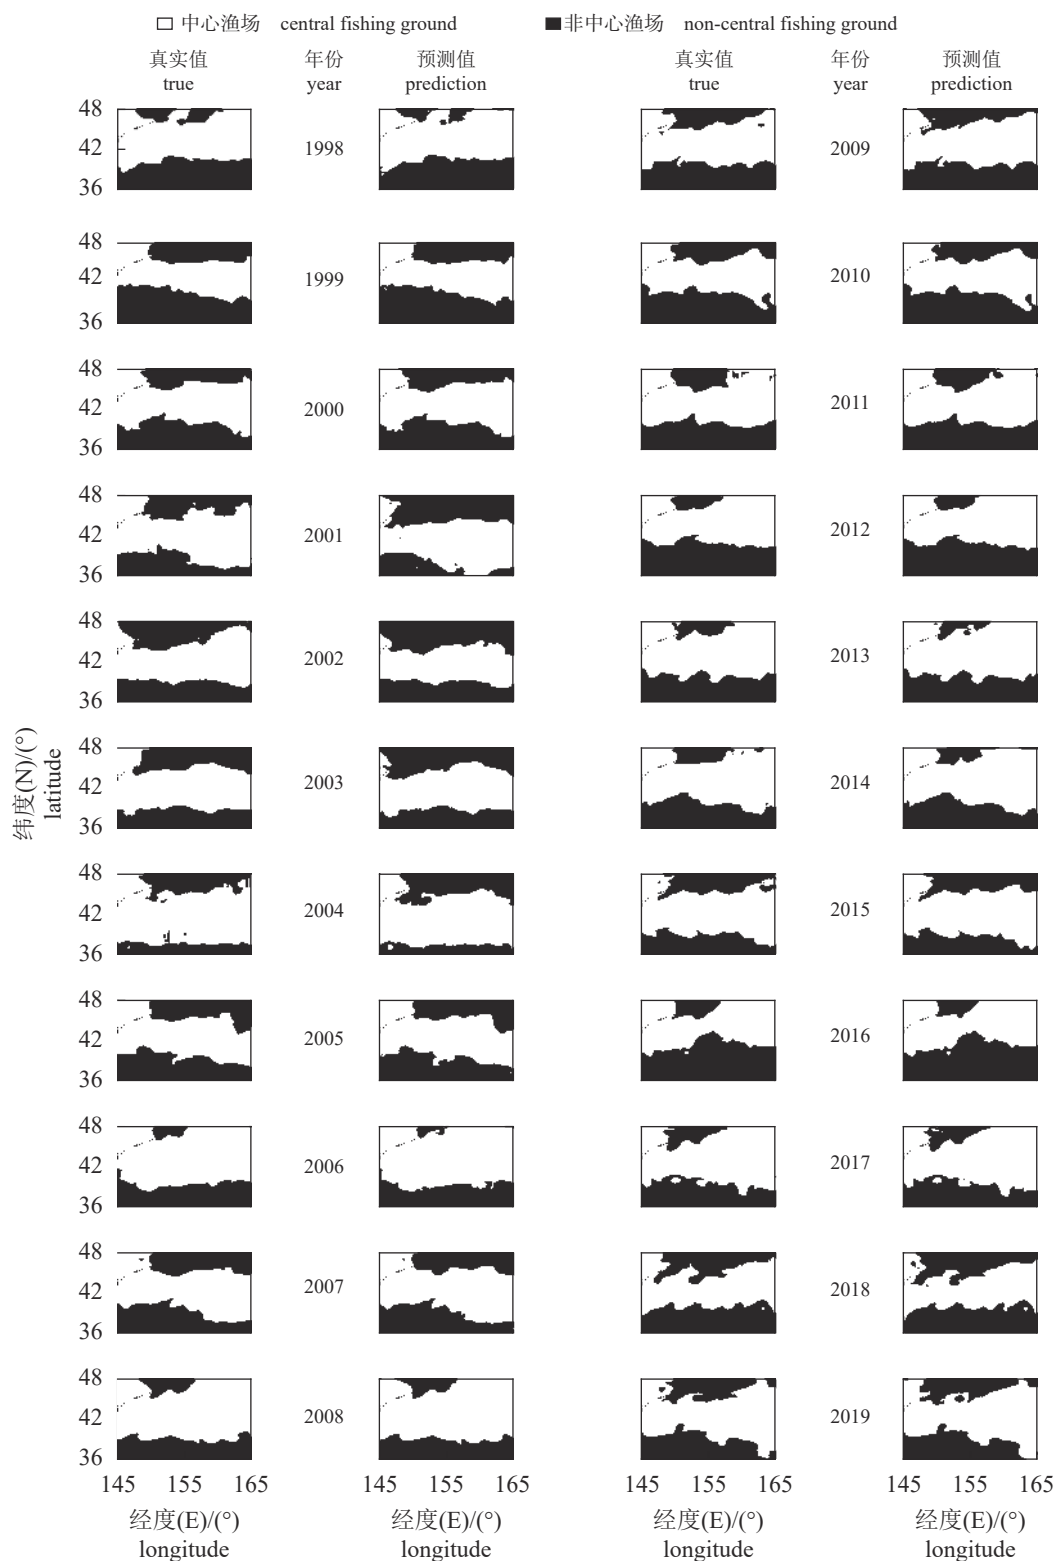


图 9 1998—2019 年 8 月第 3 旬柔鱼的中心渔场与预测结果对比

Fig. 9 Comparison between the central fishing ground of *O. bartramii* and prediction in the 3rd ten-days of August from 1998 to 2019

CNN 具有的权值共享、局部连接的特点能够更好地降低图像的复杂性, 提高拟合效果。同时,

<https://www.china-fishery.cn>

SST 分布图和中心渔场图具有不同的尺度特征, 如大尺度的中心渔场带状空间分布, 小尺度的边

中国水产学会主办 sponsored by China Society of Fisheries

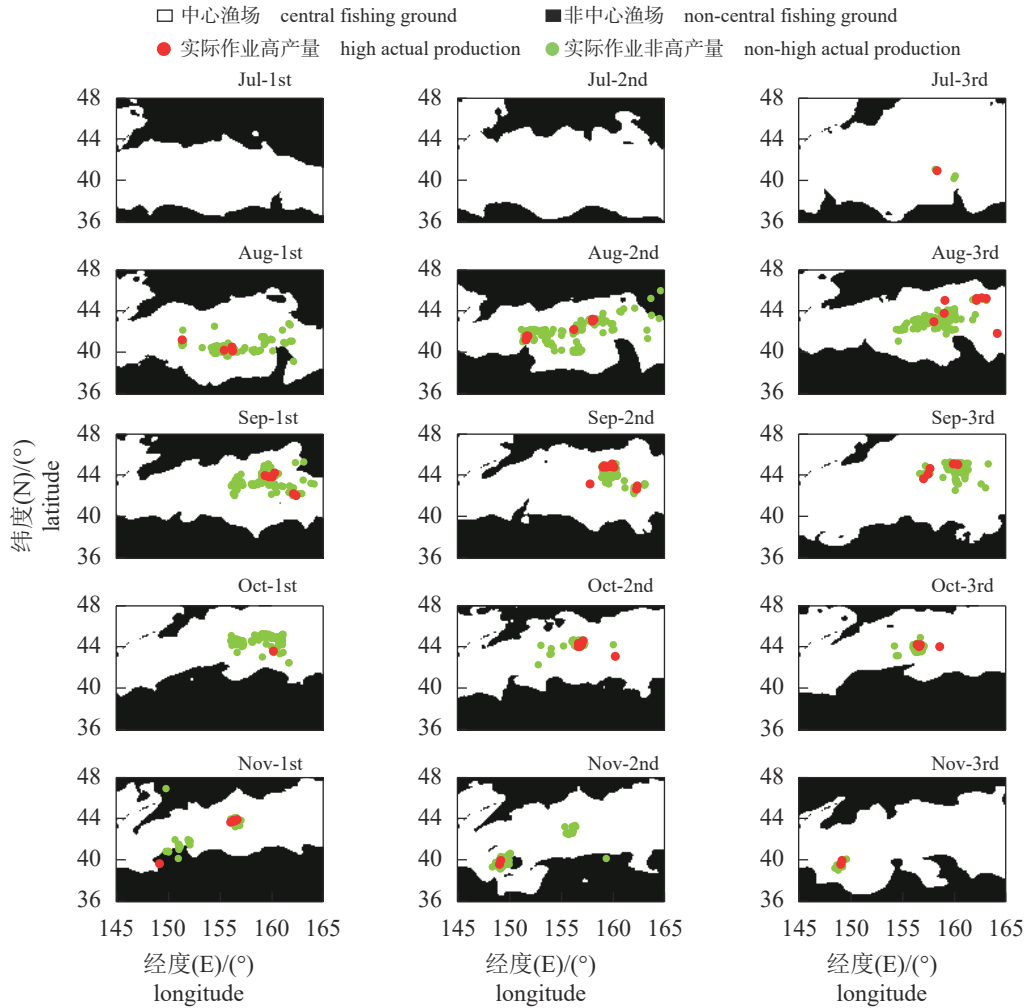


图 10 测试集 (2020 年 7—11 月) 的中心渔场分布结果与实际生产对比

Fig. 10 Comparison of the results of central fishing ground of model test (from July to November in 2020) and actual catch distribution

缘等温线弯曲、中心渔场南北方向偏移等, CNN 都能较好地提取与把握。

U-Net 模型作为深度学习中应用于图像识别的网络架构之一, 特点在于全卷积结构, 相比于其他深度学习框架如 Alex 网络^[28]、经典卷积神经网络^[29], 其去除了最后一个全连接层, 用反卷积层还原图像分辨率, 使得在处理高精度多像素点的图像分类问题上, 模型的训练效率更加高效, 精度更高。但本研究依然存在着一些不足: ①本研究的输入因子只选取了 SST 一种影响因子, 这会使中心渔场面积过大, 且主要为纬度方向上的变化, 在经度方向上变化不明显, 后续的研究会加入多因子的分析, 更加精细化中心渔场空间的变化, 并对比各个影响因子的重要性。②在中心渔场划分上虽然考虑了不同时间尺度 (每月每旬) 的差异性来进行分组, 但时间序列上的波动变化

信息并未从深度学习模型中体现出来, 后续的研究会在此研究结果的基础上, 针对不同时序方案进行柔鱼未来中心渔场的预测, 提取和挖掘时序变化特征, 解释渔场变化的机制。

(作者声明本文无实际或潜在的利益冲突)

参考文献 (References):

[1] 陈新军, 刘必林, 王尧耕. 世界头足类 [M]. 北京: 海洋出版社, 2009: 60-69.
Chen X J, Liu B L, Wang Y G. World cephalopods[M]. Beijing: Ocean Press, 2009: 60-69 (in Chinese).

[2] Chen X J, Chen Y, Tian S Q, et al. An assessment of the west winter-spring cohort of neon flying squid (*Ommastrephes bartramii*) in the Northwest Pacific Ocean[J]. *Fisheries Research*, 2008, 92(2-3): 221-230.

- [3] 陈新军. 渔情预报学 [M]. 北京: 海洋出版社, 2016: 13-24.
Chen X J. Fishery forecast science[M]. Beijing: China Ocean Press, 2016: 13-24 (in Chinese).
- [4] 余为, 陈新军, 易倩, 等. 北太平洋柔鱼早期生活史研究进展[J]. 上海海洋大学学报, 2013, 22(5): 755-762.
Yu W, Chen X J, Yi Q, *et al.* Review on the early life history of neon flying squid *Ommastrephes bartramii* in the North Pacific[J]. Journal of Shanghai Ocean University, 2013, 22(5): 755-762 (in Chinese).
- [5] 崔雪森, 唐峰华, 张衡, 等. 基于朴素贝叶斯的西北太平洋柔鱼渔场预报模型的建立[J]. 中国海洋大学学报, 2015, 45(2): 37-43.
Cui X S, Tang F H, Zhang H, *et al.* The establishment of Northwest Pacific *Ommastrephes bartramii* fishing ground forecasting model based on naive Bayes method[J]. Periodical of Ocean University of China, 2015, 45(2): 37-43 (in Chinese).
- [6] Wang J T, Yu W, Chen X J, *et al.* Detection of potential fishing zones for neon flying squid based on remote-sensing data in the Northwest Pacific Ocean using an artificial neural network[J]. *International journal of remote sensing*, 2015, 36(13): 3317-3330.
- [7] Sady M, Hendiarti N, Sachoemar S I, *et al.* Fishing ground prediction using a knowledge-based expert system geographical information system model in the South and Central Sulawesi coastal waters of Indonesia[J]. *International journal of remote sensing*, 2009, 30(24): 6429-6440.
- [8] Yu W, Chen X J, Chen C S, *et al.* Impacts of oceanographic factors on interannual variability of the winter-spring cohort of neon flying squid abundance in the Northwest Pacific Ocean[J]. *Acta Oceanologica Sinica*, 2017, 36(10): 48-59.
- [9] 汪金涛, 陈新军, 雷林, 等. 基于频度统计和神经网络的北太平洋柔鱼渔场预报模型比较[J]. 广东海洋大学学报, 2014, 34(3): 82-87.
Wang J T, Chen X J, Lei L, *et al.* Comparisons between two forecasting models of fishing ground based on frequency statistics and neural network for *Ommastrephes bartramii* in the North Pacific Ocean[J]. Journal of Guangdong Ocean University, 2014, 34(3): 82-87 (in Chinese).
- [10] 崔雪森, 唐峰华, 周为峰, 等. 基于支持向量机的西北太平洋柔鱼渔场预报模型构建[J]. 南方水产科学, 2016, 12(5): 1-7.
Cui X S, Tang F H, Zhou W F, *et al.* Fishing ground forecasting model of *Ommastrephes bartramii* based on support vector machine (SVM) in the Northwest Pacific[J]. South China Fisheries Science, 2016, 12(5): 1-7 (in Chinese).
- [11] Li X F, Liu B, Zheng G, *et al.* Deep learning-based information mining from ocean remote sensing imagery[J]. *National Science Review*, 2020, 7(10): 1584-1605.
- [12] Zheng G, Li X F, Zhang R H, *et al.* Purely satellite data-driven deep learning forecast of complicated tropical instability waves[J]. *Science Advances*, 2020, 6(29): eaba1482.
- [13] Ronneberger O, Fischer P, Brox T. U-net: convolutional networks for biomedical image segmentation[C]//Medical image computing and computer-assisted intervention –MICCAI 2015. 18th international conference. Munich: Springer International Publishing, 2015: 234-241.
- [14] Liu B, Li X F, Zheng G. Coastal inundation mapping from bi-temporal and dual-polarization SAR imagery based on deep convolutional neural networks[J]. *Journal of Geophysical Research:Oceans*, 2019, 124(12): 9101-9113.
- [15] Ayzel G, Scheffer T, Heistermann M. RainNet v1.0: a convolutional neural network for radar-based precipitation nowcasting[J]. *Geoscientific Model Development*, 2020, 13(6): 2631-2644.
- [16] Shen D L, Liu B, Li X F. Sea surface wind retrieval from synthetic aperture radar data by deep convolutional neural networks[C]//IGARSS. 2019-2019 IEEE International Geoscience and Remote Sensing Symposium. Yokohama: IEEE, 2019: 8035-8038.
- [17] Xu J, Chen X J, Chen Y, *et al.* The effect of sea surface temperature increase on the potential habitat of *Ommastrephes bartramii* in the Northwest Pacific Ocean[J]. *Acta Oceanologica Sinica*, 2016, 35(2): 109-116.
- [18] 雷林. 海洋渔业遥感 [M]. 北京: 海洋出版社, 2016: 161-165.
Lei L. Remote sensing of marine fisheries[M]. Beijing: Ocean Press, 2016: 161-165 (in Chinese).
- [19] Tian S Q, Chen X J, Chen Y, *et al.* Standardizing CPUE
中国水产学会主办 sponsored by China Society of Fisheries

- of *Ommastrephes bartramii* for Chinese squid-jigging fishery in Northwest Pacific Ocean[J]. *Chinese Journal of Oceanology and Limnology*, 2009, 27(4): 729-739.
- [20] 袁红春, 刘慧, 张硕, 等. 基于深度学习和典型相关分析的渔情预测方法[J]. 大连海洋大学学报, 2021, 36(4): 670-678.
- Yuan H C, Liu H, Zhang S, *et al.* Fisheries forecasting method based on deep learning and canonical correlation analysis[J]. *Journal of Dalian Ocean University*, 2021, 36(4): 670-678 (in Chinese).
- [21] Yu W, Chen X J, Yi Q, *et al.* Spatio-temporal distributions and habitat hotspots of the winter-spring cohort of neon flying squid *Ommastrephes bartramii* in relation to oceanographic conditions in the Northwest Pacific Ocean. [J]. *Fisheries Research*. 2016, 175: 103-115.
- [22] Chen X J, Liu B L. The catch distribution of *Ommastrephes batramii* in squid jigging fishery and the relationship between fishing ground and SST in the North Pacific Ocean in 2004[J]. *Marine Science Bulletin*, 2006, 8(2): 83-91.
- [23] 余为, 陈新军. 西北太平洋柔鱼冬春生群体栖息地的变化研究[J]. 海洋学报, 2018, 40(3): 86-94.
- Yu W, Chen X J. Variability in the potential habitat of winter-spring cohort of neon flying squid *Ommastrephes bartramii* in the northwest Pacific Ocean[J]. *Haiyang Xuebao*, 2018, 40(3): 86-94 (in Chinese).
- [24] Irvine J R, Fukuwaka M A. Pacific salmon abundance trends and climate change[J]. *ICES Journal of Marine Science*, 2011, 68(6): 1122-1130.
- [25] Chen X J, Zhao X H, Chen Y. Influence of *El Niño/La Niña* on the western winter-spring cohort of neon flying squid (*Ommastrephes bartramii*) in the Northwestern Pacific Ocean[J]. *ICES Journal of Marine Science*, 2007, 64(6): 1152-1160.
- [26] Yu W, Chen X J, Zhang Y, *et al.* Habitat suitability modelling revealing environmental-driven abundance variability and geographical distribution shift of winter-spring cohort of neon flying squid *Ommastrephes bartramii* in the northwest Pacific Ocean[J]. *Ices Journal of Marine Science*, 2019, 76(6): 1722-1735.
- [27] Alabia I D, Saitoh S I, Hirawake T, *et al.* Elucidating the potential squid habitat responses in the central North Pacific to the recent ENSO flavors[J]. *Hydrobiologia*, 2016, 772(1): 215-227.
- [28] 朱浩朋, 伍玉梅, 唐峰华, 等. 采用卷积神经网络构建西北太平洋柔鱼渔场预报模型[J]. 农业工程学报, 2020, 36(24): 153-160.
- Zhu H P, Wu Y M, Tang F H, *et al.* Construction of fishing ground forecast model of *Ommastrephes bartramii* using convolutional neural network in the Northwest Pacific[J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2020, 36(24): 153-160 (in Chinese).
- [29] 袁红春, 张硕, 陈冠奇. 基于双模态深度学习模型的渔场渔情预报[J]. 江苏农业学报, 2021, 37(2): 435-442.
- Yuan H C, Zhang S, Chen G Q. Fishery forecasting in the fishing ground based on dual-modal deep learning model[J]. *Jiangsu Journal of Agricultural Sciences*, 2021, 37(2): 435-442 (in Chinese).

Prediction on fishing ground of *Ommastrephes bartramii* in Northwest Pacific based on deep learning

XIE Mingyang¹, LIU Bin^{1,2,3}, CHEN Xinjun^{1,4,5,6*}

(1. College of Marine Sciences, Shanghai Ocean University, Shanghai 201306, China;

2. Key Laboratory of Marine Ecological Monitoring and Restoration Technologies,

Ministry of Natural Resources, Shanghai 200137, China;

3. State Key Laboratory of Satellite Ocean Environment Dynamics,

Second Institute of Oceanography, Ministry of Natural Resources, Hangzhou 310012, China;

4. Key Laboratory of Oceanic Fisheries Exploration, Ministry of Agriculture and Rural Affairs,

Shanghai Ocean University, Shanghai 201306, China;

5. National Engineering Research Center for Oceanic Fisheries, Shanghai Ocean University, Shanghai 201306, China;

6. Key Laboratory of Sustainable Exploitation of Oceanic Fisheries Resources, Ministry of Education,

Shanghai Ocean University, Shanghai 201306, China)

Abstract: Neon flying squid (*Ommastrephes bartramii*) is a primary economic cephalopod species in the Northwest Pacific Ocean. Accurate identification the spatial distribution of fishing ground provides a scientifically sound and effective foundation for fishery production. In the era of big data in marine fisheries and marine remote sensing, extracting and mining valuable information from vast datasets has emerged as a significant challenge in forecasting fishing grounds. Consequently, this study utilizes the theories of deep learning and fisheries oceanography, utilizing sea surface temperature (SST) data as input to develop a U-Net model for discriminating central fishing grounds from July to November in 1998-2019. The results indicate an accuracy of 86.7% for the validation set, 89.7% for the training set, and the accuracy, precision, recall and balanced F1-score values for the 2020 test set being 87.2%, 0.91, 0.87 and 0.89, respectively. The catch data from fisheries is largely consistent with the predicted central fishing grounds, and the model's application proved effective. Across various climatic conditions, the model demonstrates robust adaptability. The latitude of the central fishery shifts southward during El Niño event and shifts northward during La Niña events. The model constructed in this study can effectively address the problem of fishery discrimination under complex data set, improve the precision of fishing ground prediction models, and lay a theoretical basis and foundation for the realization of fishing ground prediction. It holds promising application prospects.

Key words: *Ommastrephes bartramii*; fishing ground; deep learning; U-Net model; Northwest Pacific

Corresponding author: CHEN Xinjun. E-mail: xjchen@shou.edu.cn

Funding projects: National Natural Science Foundation of China (NSFC42476086, NSFC42006159); Shanghai Science and Technology Innovation Action Plan (19DZ1207502); Funded Projects of the State Key Laboratory of Satellite Ocean Environment Dynamics (QNHX2238)