

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.
doi: 10.3969/j.issn.1000-4440.2020.02.024

基于全卷积网络的南太平洋长鳍金枪鱼渔场预报模型

袁红春¹, 陈冠奇¹, 张天蛟¹, 宋利明²

(1. 上海海洋大学信息学院, 上海 201306; 2. 上海海洋大学海洋科学学院, 上海 201306)

摘要: 长鳍金枪鱼 (*Thunnus alalunga*) 为南太平洋延绳钓的主要目标鱼种之一, 精确预报其渔场对于提高捕捞效率和优化渔业资源管理具有重要意义。本研究依据2000–2015年南太平洋长鳍金枪鱼的延绳钓数据、渔场时空数据以及海表温度、叶绿素 a 浓度和海面高度 3 种环境因子, 采用全卷积网络构建了一种以月为单位、空间分辨率为 $5^{\circ} \times 5^{\circ}$ 的渔场预报模型。本研究提出三维独热编码技术将各月环境数据映射到三维矩阵的不同层上, 并设计 2 种卷积结构和 3 种全卷积网络模型, 利用 2015 年数据对研究模型进行验证, 最佳模型总精准率达到 72.0%。结果表明, 全卷积网络在一定程度上解决了传统渔场预报方法在处理高维复杂海洋数据时准确率偏低的问题, 为渔场预报提供了一种新方法。

关键词: 全卷积网络; 三维独热编码; 渔场预报; 长鳍金枪鱼

中图分类号: S934 **文献标识码:** A **文章编号:** 1000-4440(2020)02-0423-07

Fishing ground forecast model of albacore tuna based on fully convolutional networks in the South Pacific

YUAN Hong-chun¹, CHEN Guan-qi¹, ZHANG Tian-jiao¹, SONG Li-ming²

(1. College of Information Technology, Shanghai Ocean University, Shanghai 201306, China; 2. College of Marine Sciences, Shanghai Ocean University, Shanghai 201306, China)

Abstract: *Thunnus alalunga* is one of main objects of longline fishing in the South Pacific. Accurate prediction of albacore tuna fisheries is of great significance for improving fishing efficiency and optimizing the management of fishery resources. Based on the historical catching data of albacore tuna, spatio-temporal data and three environmental data including sea surface temperature (SST), sea surface height (SSH) and chlorophyll-a concentration (Chla) from 2000 to 2015 in the South Pacific, a fishing ground prediction model with a monthly unit and spatial resolution of $5^{\circ} \times 5^{\circ}$ in the South Pacific was established using fully convolutional networks. This model mapped the environmental data to 3D array using 3D one-hot encoding, and designed two types of convolution kernel and three types of convolution network models. The prediction accuracy reached 72.0% based on the environmental data in 2015. The results show that the fully convolutional network solves the problem of low accuracy of the traditional prediction methods in processing high-dimensional complex ocean data to a certain extent, and provides a new idea for fishing ground prediction.

Key words: fully convolutional networks; 3D one-hot encoding; fishing ground forecasting; albacore tuna

收稿日期: 2019-07-21

基金项目: 国家自然科学基金项目 (41776142); 上海市青年科技英才扬帆计划项目 (YF1407700); 上海海洋大学海洋科学研究院开放课题 (A1-2006-00-601606)

作者简介: 袁红春 (1971-), 男, 江苏海门人, 博士, 教授, 博士生导师, 主要从事专家系统、智能计算、智能信息处理等研究工作。
(E-mail) hcyuan@shou.edu.cn

长鳍金枪鱼 (*Thunnus alalunga*) 作为高度洄游的大洋性鱼类, 广泛分布于三大洋, 具有较高的经济价值和丰富的资源量。通过分析区域渔业管理组织的渔获量和努力量数据库发现, 长鳍金枪鱼的种群主要分布于太平洋, 并且近二十年来在南太平洋海域长鳍金枪鱼产量呈增长趋势。目前长鳍金枪鱼已经成为南太平洋金枪鱼延绳钓渔业的主要捕捞对象

之一^[1],准确预报南太平洋长鳍金枪鱼渔场,对于合理安排渔业生产,提高捕捞效益具有重要意义。

目前国内外学者将渔场预报看作是一种分类问题或者回归问题,通过统计学方法和 GIS 技术对渔场进行分析和预测。但是,由于海洋数据的复杂性和多变性,预测过程中需要人为对数据进行预处理和样本组织,整个过程较为复杂,且特征的筛选和预处理会直接影响模型的预测准确率,预测结果受人为因素影响较大。近年来国内外有研究者构建多种模型进行渔场预报,如 Zagaglia 等^[2-3]使用广义加性模型(GAM)和广义线性模型(GLM)对长鳍金枪鱼渔场进行回归预测。崔雪森等^[4]使用朴素贝叶斯方法对西北太平洋柔鱼渔场建立预报模型,在高产区取得了 69.9%的预报准确率。宋利明等^[5]使用支持向量机对不同水层的环境因子进行分析,得到了库克群岛海域长鳍金枪鱼栖息环境综合指数。

随着技术水平的提高,渔业数据规模变得更加巨大,而传统的线性模型在对高维度数据进行分析时,数据量较大往往导致模型准确率降低^[6],所以现有渔场预报模型多基于小范围海域或者短期数据进行预测。深度神经网络在复杂动态场景中可以挖掘出重要的语义特征,对大规模数据有较好的拟合效果,其中深度 CNN 模型可以通过卷积和池化操作将不同环境因子进行交互运算,分析渔场等级。目前基于独热编码的神经网络模型已经在多个领域应用并取得了较好的结果^[7-9]。基于上述方法,本研究通过独热编码技术将环境数据映射到三维矩阵,构建全卷积网络的预测模型对南太平洋长鳍金枪鱼进行渔场预报,以提高南太平洋长鳍金枪鱼渔场预报的精度。

1 材料与方法

1.1 数据来源

根据南太平洋长鳍金枪鱼的作业范围,选取 135° W ~ 110° E, 5° S ~ 40° S 为研究海域,采用 2000-2015 年的数据进行分析研究。

本研究的渔业作业数据来源于中西太平洋渔业委员会(Western and central pacific fisheries commission, WCPFC)的南太平洋延绳钓数据。该数据包括作业时间、作业空间坐标位置、钓钩数、捕获量(吨数和尾数)。该捕捞数据以月为时间分辨率进行记录,将产量以 5°×5°空间分辨率进行汇总。

长鳍金枪鱼分布受海表温度、叶绿素 a 浓度、盐

度、涡动能和海流等多种因子影响^[10-12],因此本研究选取即时性较强、获取方便的环境遥感数据作为解释因子,包括海表温度(SST)、叶绿素 a 浓度(Chla)、海面高度(SSH)。其中海表温度、叶绿素 a 浓度数据来源于美国国家海洋和大气管理局(Nation oceanic and atmospheric administration, NOAA)环境数据库。海面高度数据来源于哥白尼海洋环境监测服务中心(Co-pernicus marine environment monitoring service, CMEMS)。该环境数据以月为时间分辨率,空间分辨率为 1°×1°。由于作业数据和实际环境因子数据的空间分辨率不一致,本研究将环境因子取在渔区网格的中心点上,归并为 5°×5°的空间分辨率。

1.2 数据预处理

1.2.1 单位捕捞努力量渔获量(CPUE)的计算 在渔业作业生产中通常采用单位捕捞努力量渔获量来表示渔业资源的丰度水平^[13]。本研究在 5°×5°的空间网格内对 CPUE 进行计算,公式如下:

$$CPUE_{(i,j)} = \frac{F_{(i,j)} \times 1\ 000}{H_{(i,j)}} \quad (1)$$

其中 $CPUE_{(i,j)}$ 表示经度 i 纬度 j 处渔区范围内的 CPUE, $F_{(i,j)}$ 和 $H_{(i,j)}$ 分别为对应的渔获尾数和钓钩数。

1.2.2 渔场等级划分 研究中常使用三分位数将渔区按照 CPUE 的大小划分成若干类别,从而将 CPUE 有效进行离散化^[14],适用于分类模型。由于渔业作业中各月产量差异较大,仅以历史 CPUE 的三分位点进行分级并不能有效地表示各月渔场的实际丰度水平,甚至会导致某些月份不存在高产区或者高产区较少,不利于指导渔业作业。因此借鉴文献^[15]的分类方法,将渔区以各月 CPUE 的三分位数分位点 66.7% 和 33.3% 划分为高产区、中产区和低产区 3 类。

1.3 基于三维独热编码的全卷积网络方法

1.3.1 三维独热编码 本研究基于独热编码技术提出一种三维独热编码方法,将 2000 年至 2015 年空间因子与环境因子数据映射为 $n \times d \times m$ 大小的三维矩阵,其中 $n=5$,为空间因子和环境因子(经度、纬度、海表温度、叶绿素 a 浓度、海面高度)数目, $m=12$,为总月数, $d=320$,表示通过独热编码将每种环境因子由大到小映射到 320 个等级。三维独热编码技术通过将不同月份的空间因子和环境因子映射到三维矩阵不同的层上,建立一个 12 层的三维矩阵,实现特征属性离散化。对于每一条数据的特征值使用独热编码进行转换,即建立一个 320 维的零向量

e_i , 将特征值 i 的所有值由小到大划分为 320 个等级, 若某条记录的特征值 i 处于第 j 个等级, 则令向量 e_i 的第 j 个分量为 1, 其他值仍为 0。将多个特征按顺序组合为二维矩阵 $N = [e_1, e_2, \dots, e_n]$, 其中 n 为该条记录的空间因子和环境因子数目, 本研究中 n 为 5。若此条数据为 m 月, 则令该三维矩阵的 $m-1$ 层为 N , 其他 11 层为零。具体操作如图 1。

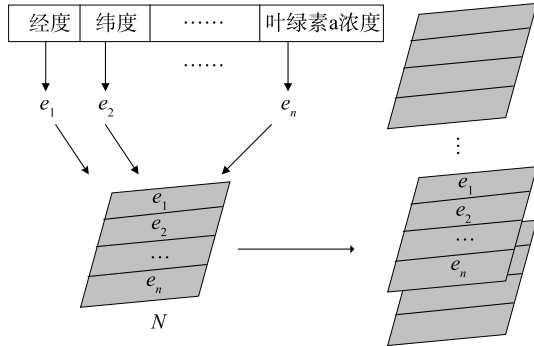


图 1 三维独热编码

Fig.1 3D one-hot encoding

1.3.2 卷积神经网络计算 卷积神经网络(CNN)作为一种深度学习网络, 由于权重共享和通过滑动窗口提取特征的特点, 可以较好地提取图片和高维数据特征, 其多层结构对于原始特征能更好地非线性表达, 也适用于渔场预报。

卷积神经网络通过交替使用卷积层和池化层对原始图片进行特征提取, 其中池化层对特征图进行降采样, 而卷积层使用滤波器在矩阵上进行滑动提取特征, 所以特征图一般为二维或三维矩阵。具体卷积运算如公式(2)所示:

$$X_j^l = f \left[\sum_{i=1}^n \text{conv} (X_i^{l-1}, w_{ij}^l) + b_{ij}^l \right] \quad (2)$$

其中 X_j^l 表示网络第 l 层的第 j 个滤波器的输出特征值, f 为激活函数, n 为网络第 $l-1$ 层特征图的数目, conv 为卷积操作, w_{ij}^l 表示网络第 l 层第 j 个滤波器的第 i 层的权重矩阵, 每一个滤波器的输出特征图都会有唯一的偏置项 b 。

由于不同月份各环境因子对 CPUE 的影响程度差异较大, 所以使用同一种模型对不同月份的环境数据的拟合效果并不好。而三维独热编码后的数据在卷积运算时, 由于数据按照月份映射到了矩阵的不同层, 所以各个月份的数据在卷积运算时分别由滤波器对应层的卷积核进行卷积运算, 第一个卷积层卷积运算公式变为如下形式:

$$X_j^l = f [\text{conv} (X_i^{l-1}, w_{ij}^l) + b_{ij}^l] \quad (3)$$

此时 X_i^{l-1} 为输入特征图的第 i 层, 即矩阵的非零层, 最终该滤波器的输出结果为非零层对应卷积核对其的特征提取结果。然后通过使用 n 个过滤器对特征图进行提取, 将原特征图变为 n 个非零层, 并传递到下一层进行普通的卷积操作。

1.3.3 全卷积网络结构 目前绝大多数用于识别与分类的卷积神经网络模型都是采用交替使用卷积层和池化层的结构^[16]。由于特征向量的稀疏性, 三维独热编码矩阵在采用普通卷积神经网络提取特征时, 结果大多为零, 卷积和池化操作有过多的冗余, 所以本研究采用全卷积网络结构^[17], 使用步长为 2 的标准卷积层替代池化层。

设 f 为 CNN 某一层的特征图输出, 它可以表示为一个 $W \times H \times N$ 的三维矩阵。其中 W 和 H 分别为矩阵的宽和高, N 为该特征图的通道数 (如果 f 为卷积层的输出, 则 N 也为该层滤波器的数目)。

设池化操作尺度为 k , 步长为 r , 则池化操作具体的计算公式如下:

$$S_{i,j,u}(f) = \sum_{h=-\frac{k}{2}}^{\frac{k}{2}} \sum_{w=-\frac{k}{2}}^{\frac{k}{2}} P[f_{g(h,w,i,j,u)}] \quad (4)$$

$S_{i,j,u}(f)$ 为特征图在第 u 层第 i 行第 j 列的输出, 其中 $g(h,w,i,j,u) = (r \cdot i + h, r \cdot j + w, u)$ 是 f 中位置按照步长到 s 中位置的映射函数, P 为池化函数。一般情况下有 $r \geq k$, 所以各池化区域不重合。在全卷积网络中通常 $k=3, r=2$, 所以存在重叠区域, 但是同样达到了降维的效果。具体操作如下:

$$C_{i,j,o}(f) = \sigma \left[\sum_{h=-\frac{k}{2}}^{\frac{k}{2}} \sum_{w=-\frac{k}{2}}^{\frac{k}{2}} \sum_{u=1}^N \text{conv}_{h,w,u,o} \cdot f_{g(h,w,i,j,u)} \right] \quad (5)$$

其中 conv 为滤波器, σ 为激活函数, 通常采用 ReLU 函数, o 为卷积层的过滤器选择。

由公式(4)和(5)可以看出, 步长为 2 的卷积操作与池化操作对于上一层特征图的依赖元素是相同的, 2 种操作都降低了上一层特征图 1/2 空间维度, 但步长为 2 的卷积操作减少了卷积层的重叠, 导致特征提取时, 仅对特征图的左上角特征进行提取, 可能忽略了其他位置的某些特征。池化操作可以提取出目标区域中的最大值, 获得最明显的特征, 而全卷积网络删除了池化层, 使用增加步长的卷积操作取代池化层的降采样过程, 提高准确率。

1.3.4 预报精度检验方法 渔场预报精度是描述

渔场预报结果与真实捕捞数据符合程度的标准。由于渔业作业会受到相关法律法规和天气等影响,部分渔场并没有渔船进行作业,CPUE 并不能完全表示该渔场的等级水平,因此本研究使用总召回率(*Recall*)作为评估标准^[18],具体计算方法如下:

$$P_i = \frac{C_i \cap C'_i}{C_i} \quad (6)$$

$$P = \frac{1}{N} \sum_{i=1}^N P_i \quad (7)$$

其中 P_i 表示 i 类渔场的预报准确率, C_i 表示 i 类渔场的渔区集合, C'_i 表示预测出的 i 类渔场的渔区集合, P 为总体预报准确率, N 为渔场的总类别数。

1.4 算法步骤

基于全卷积网络的渔情预测算法的步骤如下:

输入: 训练集(D)为2000–2014年环境因子数据和 CPUE。

测试集 T 为 2015 年环境因子数据和 CPUE。

输出: 测试集(T)的等级分类

Step1: 对训练集和测试集进行数据预处理,并归一化到 0~1。将各条数据按月 CPUE 三分位点将渔场划分为高、中、低 3 个等级,并生成 D 和 T 的标签集 L_1 、 L_2 。

Step2: 对各条数据使用方法 1.3 的方法进行编码,将环境因子数据映射到三维矩阵。由训练集(D)构建三维矩阵集(D_1),由测试集 T 构建三维矩阵集(T_1)。

Step3: 训练模型。将 step2 构造好的训练集(D_1)输入到网络模型中作为输入数据,将标签集(L_1)使用独热编码转换为输出向量,训练全卷积网络得到分类器(F)。

Step4: 将测试集(T_1)输入分类器(F)得到渔场预报结果 R 。将 R 与标签集(L_2)进行对比得到模型的预报准确率。

1.5 试验设计

本试验工作站显卡型号为 NVIDIA GTX 1080Ti, CPU 型号为 AMD Ryzen Threadripper 1950X, 操作系统为 Windows10, 并搭建了基于 Python3.6 的 Tensor-

Flow 1.3 框架与 Keras 2.0.8 框架。

试验数据集为南太平洋海域 2000 年到 2015 年空间因子、环境因子和长鳍金枪鱼渔业作业数据。其中 2000–2014 年共有数据 9 860 条, 将其按照 85% 和 15% 的比例划分为训练集和验证集, 另外选择 2015 年 743 条数据作为测试集。

由于进行三维独热编码后数据维度较高但信息较为稀疏, 所以设置初始学习率 $lr = 0.0005$, 并采用学习率动态调整, 当进行了 10 次迭代循环后, 验证集损失值仍不下降时, 将学习率减半, 衰减率 ($decay$) = 1.0×10^{-6} , 动量参数 ($momentum$) = 0.9。训练停止方式采取早停策略 (Early stopping) 防止过拟合^[19], 即 15 次迭代循环后验证集损失值仍不下降时结束训练, 并将最大迭代次数设置为 500。

本研究设计 2 组试验分别研究卷积核大小与网络结构对模型准确率的影响, 为了评估模型性能, 除了使用方法 1.3.4 的预报精度检验方法作为主要评估标准外, 选择所有渔场的精准率 ($Precision$) 和 $F1$ 分数作为综合评估参考。

1.5.1 卷积核尺度对模型性能的影响 本研究分别使用 3×1 的一维卷积核和 3×3 卷积核进行模型构建。特别强调在测试不同卷积核的效果时, 网络结构与超参数设置均相同。

1.5.2 网络结构对模型性能的影响 对于网络卷积层数选择, 本研究分别尝试了 2 到 5 层卷积层, 并构建滤波器数目为 64/128/256、128/256/512 和 256/256/256 3 种不同结构的网络模型。

2 结果与分析

2.1 卷积核尺度对模型性能的影响

表 1 为使用不同卷积核时, 在测试集上的对比结果。由表 1 可知, 3×1 的一维卷积核模型将大量中产区误分为其他产区, 无法对各等级渔场进行明确划分, 这是由于本研究的矩阵与传统的特征矩阵相比更为稀疏, 不利于一维矩阵的特征提取。而 3×3 卷积核由于具有更大的感受野, 有利于提取特征, 因此本研究采用 3×3 卷积核构建模型进行训练。

表 1 不同尺度卷积核试验结果对比

Table 1 Comparison of experimental results at different scales of convolution kernel

卷积核尺度	高产区召回率 (%)	中产区召回率 (%)	低产区召回率 (%)	总召回率 (%)	总精准率 (%)	总 $F1$ 分数 (%)
3×1	69.8	47.0	75.8	64.2	63.5	63.9
3×3	76.9	61.8	76.6	71.7	72.0	71.8

2.2 网络结构对模型性能的影响

通过观察损失值曲线发现,当网络层数增加到4层时,模型在50次迭代循环后就发生了严重的过拟合现象,因此模型最终设置3层卷积层。本研究数据经过三维独热编码后矩阵的尺寸为 $5 \times 320 \times 12$,矩阵高度较小,所以不进行高度降维,仅用步长为 1×2 和 1×3 的卷积层替代池化层(其中 1×3 大小的步长是对上一卷积层的全部输出特征值进行卷积运算的最大步长),行与行之间通过卷积核交互运算。通过分析表1,本研究将卷积核的大小设为 3×3 ,激活函数使用ReLU函数。本试验一共设置3种不同结构的全卷积网络模型,每个模型都为3个卷积层和2个全连接层,整个模型采取全卷积结构,不使用池化层,具体结构见表2。

由表3可以看出,在选择不同过滤器数目时,全卷积网络模型均取得了较高准确率,但是随着卷积层滤波器层数的增加,由于深层网络节点数过多,网络发生过拟合现象,导致中产区被误分为其他产区,

表3 不同模型试验结果对比

Table 3 Experimental result comparison of different models

模型	高产区召回率 (%)	中产区召回率 (%)	低产区召回率 (%)	总召回率 (%)	总精准率 (%)	总 F1 分数 (%)
模型 1	76.9	56.6	77.8	70.4	70.4	70.3
模型 2	75.6	55.0	78.6	69.7	69.6	69.6
模型 3	76.9	61.8	76.6	71.7	72.0	71.8

2.3 模型拟合分析

由于本研究样本数目庞大,传统渔场预报方法由于参数数目等原因预测结果并不理想,而 F-ACN 模型由于卷积神经网络的多层非线性结构和庞大可训练参数可以充分拟合多参数间的非线性关系,在大规模数据集上能取得更好的结果。如图2所示,在训练过程中训练集与验证集的准确率曲线和损失值曲线基本重合,F-ACN 在验证集和测试集上的准确率仅略低于训练集,该模型表现出良好的泛化性。F-ACN 模型在训练初期学习缓慢,这是由于本研究数据集划分没有明确的边界,模型在训练初期无法判明类别,梯度方向不断变化,当进行了约10次迭代后,损失值开始快速下降。

2.4 不同模型预测结果

虽然国内外进行了大量渔场预报模型研究,但传统渔场预报方法多针对小型数据集,为了验证 F-

整体准确率下降。由于本研究网络模型采用全卷积结构,不存在池化层造成的信息损失,所以在各层可以采取相同的节点数。模型3将各卷积层均设置为256个滤波器,在增加模型参数量的同时保持了与模型1相同的深层网络节点数,不易发生过拟合现象,并且明显提高了准确率。因此本研究选用表现最好的模型3结构作为全卷积网络最终结构并将其命名为 F-ACN。

表2 模型参数

Table 2 Parameters of the model


模型	滤波器数目/节点数			卷积核大小	步长
	模型 1	模型 2	模型 3		
Conv1	64	128	256	3×3	1×2
Conv2	128	256	256	3×3	1×2
Conv3	256	512	256	3×3	1×3
FC1	1 024	1 024	1 024	—	—
FC2	1 024	1 024	1 024	—	—

ACN 模型准确率,本研究使用朴素贝叶斯方法、BP神经网络和深度神经网络(DNN)构建南太平洋长鳍金枪鱼预报模型与该模型进行对比。其中朴素贝叶斯模型采用文献[4]的基于 FastICA 方法进行独立成分分析的朴素贝叶斯方法。BP神经网络采用5-512-3结构。DNN神经网络模型采取与CNN完全相同的节点数。

由表4可以看出,相比于其他模型本研究算法总体准确率最高,在高产区和低产区的预测准确率上有明显优势。实际作业受捕捞效率影响,渔业作业位置一般依赖于高产区预测结果,而 F-ACN 模型在高产区和低产区预测准确率较高,对于作业渔船寻找最佳渔场有较好的指导意义。由于渔情预报方法的渔场等级划分界限并不明确,只按照月 CPUE 的三分位点进行划分,而受实际天气、政策等因素的影响,渔场的实际水平可能高于或低于等级标签,所以处在2个等

级边界部分渔场容易被误分,出现了中产区预报准确

率明显低于高产区和低产区的现象。



a:准确率曲线 ;b:损失值曲线。

图2 准确率(a)与损失值(b)曲线图

Fig.2 Curves of accuracy (a) and loss value (b)

表4 不同模型的预测结果

Table 4 Prediction results of different models

模型	高产区召回率 (%)	中产区召回率 (%)	低产区召回率 (%)	总召回率 (%)	总精准率 (%)	总 F1 分数 (%)
朴素贝叶斯模型	52.5	59.1	77.5	63.5	64.1	63.7
BP 神经网络模型	70.7	48.6	75.8	65.0	65.5	65.0
DNN 神经网络模型	75.6	49.4	72.2	65.7	67.1	65.9
F-ACN 模型	76.9	61.8	76.6	71.7	72.0	71.8

3 讨论

本研究针对传统渔情预报方法难以拟合海洋大数据的缺陷,提出了一种基于三维独热编码的全卷积网络南太平洋长鳍金枪鱼渔场预报模型 F-ACN。本研究发现,F-ACN 可以对大规模海洋数据进行特征提取,同时与传统渔情预报方法相比准确率明显提升,在一定程度上解决了传统渔情预报方法在处理高维复杂海洋数据时准确率下降的问题,为渔场预报提供了一种新思路。

F-ACN 模型由多层卷积神经网络和 DNN 构成,比传统渔场预报模型具有更多的可训练参数,且非线性更强。同时 F-ACN 模型采用全卷积网络结构,使用步长为 2 的卷积层代替了池化操作,模型在卷积层的计算量比普通卷积神经网络减少了 1/2,并且省去了所有的池化操作,极大地加速了运算速度。面对海洋数据大规模、多源化和异构性的特点,此模型可以更好地拟合复杂数据形式,自动获取海量高维数据中存在的复杂关联,精准预报渔场。

与回归模型相比,F-ACN 模型得到的预报结果是

一个离散值,即渔场等级,不存在一个连续的概率预测值,因此可以更加明确直观地表示渔场水平。同为分类模型的朴素贝叶斯方法要求各输入变量相互独立,模型进行训练前要对多种参数进行独立成分分析,这不仅增加了模型的复杂度还造成了数据信息损失。而 F-ACN 模型是一种“黑盒”模型,并不要求渔业数据满足任何假设,只需要简单的对数据进行三维独热编码,原理和实现更为简单,不用考虑环境因子间的相互影响,因此该模型使用方便。同时 F-ACN 模型具有很好的可扩展性,在环境因子种类增加时,只需增加训练集三维矩阵的维度就可以在原模型进行训练,不需要进行其他预处理操作。但 F-ACN 模型只考虑到了渔场与环境因子的关系,独立地对渔场进行预报,而长鳍金枪鱼作为一种高度洄游的大洋性鱼类,各个渔区在连续时间内存在一定的空间关系,下一步需要将渔场的时间序列因素和空间相关性加入到模型中,提高渔场预报准确率。

参考文献:

- [1] NIKOLIC N, MORANDEAU G, HOARAU L, et al. Review of al-

- bacore tuna, *Thunnus alalunga*, biology, fisheries and management[J]. Reviews in Fish Biology and Fisheries, 2017, 27(4): 775-810.
- [2] ZAGAGLIA C R, LORENZZETTI J A, STECH J L. Remote sensing data and longline catches of yellowfin tuna (*Thunnus albacares*) in the equatorial Atlantic[J]. Remote Sensing of Environment, 2004, 93(1/2): 267-281.
- [3] ZAINUDDIN M, SAITOH K, SAITOH S E I I. Albacore (*Thunnus alalunga*) fishing ground in relation to oceanographic conditions in the western North Pacific Ocean using remotely sensed satellite data[J]. Fisheries Oceanography, 2008, 17(2): 61-73.
- [4] 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(自然科学版),2015,45(2):37-43.
- [5] 宋利明,周建坤,沈智宾,等.基于支持向量机的库克群岛海域长鳍金枪鱼栖息环境综合指数[J].海洋通报,2017,36(2): 195-208.
- [6] HARRELL F E, LEE K L, MARK D B. Tutorial in biostatistics multivariable prognostic models: issues in developing models, evaluating assumptions and adequacy, and measuring and reducing errors[J]. Statistics in Medicine, 1996, 1(15): 361-387.
- [7] 李思琴,林磊,孙承杰.基于卷积神经网络的搜索广告点击率预测[J].智能计算机与应用,2015,5(5):22-25,28.
- [8] LIU Q, YU F, WU S, et al. A convolutional click prediction model[C]//Association for Computing Machinery. Proceedings of the 24th ACM international on conference on information and knowledge management. New York, USA: ACM, 2015: 1743-1746.
- [9] WANG P, XU B, XU J, et al. Semantic expansion using word embedding clustering and convolutional neural network for improving short text classification [J]. Neurocomputing, 2016, 174: 806-814.
- [10] 毛江美,陈新军,余景.基于神经网络的南太平洋长鳍金枪鱼渔场预报[J].海洋学报,2016,38(10):34-43.
- [11] 宋利明,谢凯,赵海龙,等.库克群岛海域海洋环境因子对长鳍金枪鱼渔获率的影响[J].海洋通报,2017,36(1):96-106.
- [12] 范永超,戴小杰,朱江峰,等.南太平洋长鳍金枪鱼延绳钓渔业 CPUE 标准化[J].海洋湖沼通报,2017(1):122-132.
- [13] ZAINUDDIN M, SAITOH S, SAIROH K. Detection of potential fishing ground for albacore tuna using synoptic measurements of ocean color and thermal remote sensing in the northwestern North Pacific[J]. Geophysical Research Letters, 2004, 31(20): 183-213.
- [14] ISMAIL A I, MORRISON E C, BURT B A, et al. Natural history of periodontal disease in adults: findings from the tecumseh periodontal disease study[J]. Journal of Dental Research, 1990, 69(2): 430-435.
- [15] 陈雪忠,樊伟,崔雪森,等.基于随机森林的印度洋长鳍金枪鱼渔场预报[J].海洋学报,2013,35(1):158-164.
- [16] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks[C]//NIPS. Advances in neural information processing systems. USA: Curran Associates Inc, 2012: 1097-1105.
- [17] SPTINGENBERG J T, DOSOVITSKIY A, BROX T, et al. Striving for simplicity: The all convolutional net[EB/OL]. (2015-4-13) [2019-7-15]. <https://arxiv.org/abs/1412.6806.pdf>.
- [18] 张衡,崔雪森,樊伟.基于遥感数据的智利竹筴鱼渔场预报系统[J].农业工程学报,2012,28(15):140-144.
- [19] PRECHELT L. Automatic early stopping using cross validation: quantifying the criteria[J]. Neural Networks, 1998, 11(4): 761-767.

(责任编辑:陈海霞)