

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.
doi: 10.3969/j.issn.1000-4440.2021.02.021

基于双模态深度学习模型的渔场渔情预报

袁红春^{1,2}, 张 硕¹, 陈冠奇¹

(1. 上海海洋大学信息学院, 上海 201306; 2. 农业农村部渔业信息重点实验室, 上海 201306)

摘要: 为解决传统渔场渔情预测方法在处理高维复杂海洋数据时存在人工干预较多、拟合困难、精度不高的问题, 提出了一种基于双模态深度学习的渔场渔情预测方法。首先, 该方法将不同海洋环境因子在 $5^{\circ} \times 5^{\circ}$ 渔业作业区域范围内按照空间相对位置映射为三维矩阵。然后, 分别使用卷积神经网络模型(CNN)和深度神经网络模型(DNN)对海洋环境因子和时空因子2种异构数据进行特征提取。最后, 将基于时空信息的深度神经网络模型与卷积结构进行特征融合, 再将融合后的特征经过全连接层进行分类。试验结果表明, 双模态深度学习模型对南太平洋长鳍金枪鱼中心渔场的渔场渔情预报率达到了89.8%, 较其他渔场渔情预报模型精度提高10%~30%。同时由于该模型使用卷积神经网络, 可以对任意空间分辨率的海洋环境因子进行特征提取, 省去了手动匹配不同空间分辨率的过程, 减少了人工干预, 对南太平洋长鳍金枪鱼的渔业作业与渔场渔情预报有极高的指导意义。

关键词: 双模态深度学习模型; 渔场渔情预报; 长鳍金枪鱼

中图分类号: S934 **文献标识码:** A **文章编号:** 1000-4440(2021)02-0435-08

Fishery forecasting in the fishing ground based on dual-modal deep learning model

YUAN Hong-chun^{1,2}, ZHANG Shuo¹, CHEN Guan-qi¹

(1. College of Information Technology, Shanghai Ocean University, Shanghai 201306, China; 2. Key Laboratory of Fisheries Information, Ministry of Agriculture and Rural Affairs, Shanghai 201306, China)

Abstract: To solve the problems of much manual intervention, difficulty in fitting and low accuracy in processing ocean data of high-dimensional complex by traditional fishery forecasting methods in the fishing ground, a fishery forecasting method based on dual-modal deep learning was proposed. Firstly, the method mapped different marine environmental factors within a $5^{\circ} \times 5^{\circ}$ fishery operation area into a three-dimensional matrix according to their relative spatial positions. Secondly, features of two heterogeneous data such as marine environmental factors and spatiotemporal factors were extracted by convolutional neural network (CNN) model and deep neural network (DNN) model respectively. Finally, the deep neural network model based on spatiotemporal information and the convolution structure were fused by feature, and the fused features were classified through the fully connected layer. The results showed that, the forecast rate of fishery by dual-modal deep learning model in the central fishing ground of albacore in the South Pacific reached 89.8%, which improved the forecast accuracy by 10%~30% compared with forecast models in other fishing grounds. At the same time, because the model used a convolutional neural network, which could extract features of marine environmental factors with any spatial resolution, thus eliminated the process of matching different spatial

收稿日期: 2020-07-19

基金项目: 国家自然科学基金项目(41776142); 国家重点研发计划项目(2018YFD0701003)

作者简介: 袁红春(1971-), 男, 江苏海门人, 博士, 教授, 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

resolutions by manual and reduced manual intervention, which showed extremely high guiding significance for the fishing operations and fishery forecast in the fishing ground of albacore in the South Pacific.

Key words: dual-modal deep learning model; fishery forecasting in the fishing ground; albacore tuna

长鳍金枪鱼 (*Thunnus alalunga*) 是高度洄游的大洋性鱼类, 因其经济价值高, 资源量相对丰富, 故该鱼种具有较大开发潜力, 已引起包括中国在内的很多渔业国家的关注与重视。如何提高南太平洋长鳍金枪鱼的渔场渔情预测水平已成为国内外学术界研究热点之一。通过调研区域渔业管理部门的渔获量和努力量数据, 发现长鳍金枪鱼的种群主要分布于太平洋, 并且在南太平洋海域近二十年来长鳍金枪鱼产量逐年增长。目前长鳍金枪鱼已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。

目前国内外农渔学者通常将渔情预测看作是一种分类或回归问题, 通常采取的方式是统计学方法和 GIS 技术对渔场渔情进行分析和预估。但由于海洋数据的复杂性、多变性, 需要人为对海洋数据进行预处理以及样本重组, 在预测过程中, 整个流程较为复杂, 且人为筛选的特征和预处理方式直接影响模型的预测准确率, 故预测结果受人为因素影响较大, 不具备泛化性, 可普及程度低。近年来国内外有研究者构建多种模型进行渔场渔情预报, 如 Zagaglia 等^[2]、Zainuddin 等^[3] 通过广义加性模型 (GAM) 与广义线性模型 (GLM) 对长鳍金枪鱼渔场渔情建立预报模型。崔雪森等^[4] 使用朴素贝叶斯方法对西北太平洋柔鱼渔场渔情进行回归预测。宋利明等^[5] 针对不同水层的环境因子差异, 使用支持向量机进行分析, 测算了库克群岛海域长鳍金枪鱼栖息环境综合指数。

随着海洋科技的进步, 渔业数据规模变得更加巨大, 传统的线性模型在对海量高维度数据进行分析时, 模型预测的准确率往往偏低^[6]。现有渔情预测模型大多基于小范围海面区域或短期渔业数据进行预测。而深度学习的发展, 给传统渔情预测带来了新的思路。深度神经网络能够在复杂动态场景中挖掘出重要的语义特征, 在大规模数据预测上有较好的拟合效果^[7-9]。在数据结构上, 海洋环境因子在空间排列上为二维矩阵, 可以通过叠加不同的环境因子构成三维矩阵, 将其视为图像信息, 十分适合使用卷积神经网络 (CNN) 进行特征提取, 而时空因子则是均匀分布的离散特征, 此类特征适合使用深度神经网络 (DNN) 神经网络进行特征提取。本研究基于 2 种异构数

据, 使用双模态学习的方式构建模型, 先通过卷积神经网络挖掘环境因子的内在关系, 并与 DNN 提取的时空信息特征相结合, 再用卷积神经网络的特征提取方法将不同空间分辨率的数据融合到统一模型中, 共同预测渔场渔情等级, 以提高南太平洋长鳍金枪鱼渔场渔情预报的精度。

1 材料与方法

1.1 数据来源

根据捕捞南太平洋长鳍金枪鱼的作业范围, 选取 135°W~115°E、10°S~35°S 为研究海域, 采用 2000-2015 年的数据进行分析研究。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、捕捞量 (质量和尾数)。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 含量、盐度、涡动能和海流等多种因子影响^[10], 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 含量 (Chla)、海面高度 (SSH)。其中海表温度、叶绿素 a 含量的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 (Copernicus 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°。

1.2 数据预处理与评估方法

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 (CPUE) 来表示渔业资源的丰度水平^[11-13]。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 渔业作业数据处理 在渔业公司的日常作业中, 为了节省能源与提高产量, 渔船的作业区域常常围绕着高产区, 因此提升高产区预报精度对于指导渔

业作业有着十分重要的意义。研究中常使用三分位数将渔区按照 CPUE 的大小划分为若干个类别,将 CPUE 有效离散化^[14-15],从而适用于分类模型。

按照公式(1)的方法计算出 CPUE 值后,以每月 CPUE 三分位点的上三分位点(即 CPUE 最高数值的三分位点)为分界点重新将每月的 CPUE 划分为 2 类,并分别命名为中心渔场和非中心渔场,并将中心渔场标签值初始化为 1,非中心渔场标签值初始化为 0。最终得到中心渔场 2 875 个,非中心渔场 5 579 个,2 种类别的渔场数量分布不均匀。

1.2.3 环境数据处理 对于传统的渔场渔情预报方法在面对环境因子与渔业作业数据空间分辨率不匹配时,常常采用取平均值、取中心值等方法统一环境因子数据与作业数据空间分辨率^[16]。这是由于在传统的模型中如果采取不同空间分辨率的数据,会导致海洋环境因子在输入层所占比重较大,当时空因子与海洋环境因子分布不均匀时,最终预报精度将会受到影响。本研究分别使用 CNN 和 DNN 提取两种类型的异构数据。由于卷积神经网络特有的卷积和池化操作,可以在运算的同时将环境数据的空间分辨率下降到与时空因子相同大小,因此本研究所用数据无需对海洋环境因子数据进行匹配,使用 $1^\circ \times 1^\circ$ 的空间分辨率即可。

对于环境因子的预处理共分 2 步:第 1 步是将海洋环境因子和时空因子进行归一化,消除量纲;第 2 步则是将海洋环境因子映射为三维矩阵,可看作 RGB 三通道彩色像。

1.2.3.1 环境因子归一化 由于不同环境因子的量纲和数量级不同,首先将海表温度、叶绿素 a 含量、海面高度、月份、经度、纬度归一化到 0 至 1 范围内,具体的计算公式为:

$$X' = \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \quad (2)$$

式中 X_i 代表某环境因子初始值, X_{\max} 代表此环境因子在全部研究区域中的最大值, X_{\min} 表示此环境因子在全部研究区域中的最小值, X' 表示数据归一化后得到的值。

1.2.3.2 将海洋环境因子映射为三维矩阵 先将整个研究区域按照 $1^\circ \times 1^\circ$ 划分为网格区域,然后再将整个海域中归一化后的环境因子数据以 $5^\circ \times 5^\circ$ 渔业作业范围进行组织,从而构成 5×5 大小的环境因子矩阵,最终将 3 种环境因子叠加为三维矩阵,即每个渔

场作业点分别根据海表温度、海面高度、叶绿素 a 含量数值生成一个 $5 \times 5 \times 3$ 大小的矩阵。例如,对于处于纬度为 i 、经度为 j 的作业点,设其海面高度为 H_{ij} ,海表温度为 T_{ij} ,叶绿素 a 含量为 A_{ij} 。将此作业点 $5^\circ \times 5^\circ$ 范围内的环境因子转换为如图 1 所示的三维矩阵:

$$\begin{bmatrix} H_{i-2,j-2} & H_{i-2,j-1} & H_{i-2,j} & H_{i-2,j+1} & H_{i-2,j+2} \\ H_{i-1,j-2} & H_{i-1,j-1} & H_{i-1,j} & H_{i-1,j+1} & H_{i-1,j+2} \\ H_{i,j-2} & H_{i,j-1} & H_{i,j} & H_{i,j+1} & H_{i,j+2} \\ H_{i+1,j-2} & H_{i+1,j-1} & H_{i+1,j} & H_{i+1,j+1} & H_{i+1,j+2} \\ H_{i+2,j-2} & H_{i+2,j-1} & H_{i+2,j} & H_{i+2,j+1} & H_{i+2,j+2} \\ T_{i-2,j-2} & T_{i-2,j-1} & T_{i-2,j} & T_{i-2,j+1} & T_{i-2,j+2} \\ T_{i-1,j-2} & T_{i-1,j-1} & T_{i-1,j} & T_{i-1,j+1} & T_{i-1,j+2} \\ T_{i,j-2} & T_{i,j-1} & T_{i,j} & T_{i,j+1} & T_{i,j+2} \\ T_{i+1,j-2} & T_{i+1,j-1} & T_{i+1,j} & T_{i+1,j+1} & T_{i+1,j+2} \\ T_{i+2,j-2} & T_{i+2,j-1} & T_{i+2,j} & T_{i+2,j+1} & T_{i+2,j+2} \\ A_{i-2,j-2} & A_{i-2,j-1} & A_{i-2,j} & A_{i-2,j+1} & A_{i-2,j+2} \\ A_{i-1,j-2} & A_{i-1,j-1} & A_{i-1,j} & A_{i-1,j+1} & A_{i-1,j+2} \\ A_{i,j-2} & A_{i,j-1} & A_{i,j} & A_{i,j+1} & A_{i,j+2} \\ A_{i+1,j-2} & A_{i+1,j-1} & A_{i+1,j} & A_{i+1,j+1} & A_{i+1,j+2} \\ A_{i+2,j-2} & A_{i+2,j-1} & A_{i+2,j} & A_{i+2,j+1} & A_{i+2,j+2} \end{bmatrix}$$

图 1 三维矩阵结构图

Fig.1 Structure diagram of three-dimensional matrix

为了方便输入卷积神经网络中进行运算,Python3.6 中的 Numpy 科学计算包将三维矩阵统一转换为 Numpy 数组并保存,原数据具体格式如表 1 所示。

1.2.4 预报精度评估方法 渔场渔情预报精度是描述渔场渔情预报结果与真实捕捞数据之间符合程度的标准。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,因此本文使用总召回率(Recall)作为评估标准^[17],具体计算方法如下:

$$P_i = \frac{C_i \cap C'_i}{C_i} \quad (3)$$

$$P = \frac{1}{N} \sum_{i=1}^N P_i \quad (4)$$

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。

表 1 部分数据集成记录

Table 1 Part of the integrated data records

序号	年	月	纬度	经度	海表温度	海面高度	叶绿素 a 含量	渔场等级
1	2000	1	0.857 143	0.782 609	0.863 805	0.622 353	0.081 651	非中心
2	2001	1	0.571 429	0.826 087	0.771 672	0.577 443	0.015 673	中心
3	2002	2	0.142 857	0.521 739	0.431 184	0.262 567	0.075 592	非中心
4	2003	3	0.857 143	0.521 739	0.932 126	0.567 492	0.056 550	非中心
5	2004	3	0.428 571	0.869 565	0.802 196	0.579 995	0.024 517	非中心
6	2005	4	0.571 429	0.826 087	0.821 125	0.637 918	0.029 460	非中心
7	2006	5	0.714 286	0.521 739	0.878 491	0.634 346	0.082 875	中心
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
8 453	2015	5	0.428 571	0.434 783	0.580 663	0.642 980	0.096 787	中心
8 454	2015	5	0.142 857	0.956 522	0.297 688	0.339 370	0.065 521	中心

1.3 多模态学习

海洋大数据具有多源异构性特点,采用多模态学习方式十分适合。Srivastava 等^[18]利用受限玻尔兹曼机分别提取 2 种不同数据的特征,然后将其进行有监督学习。除此之外还有众多学者尝试了多模态支持向量机^[19]和多模态半监督学习^[20]等多模态学习方法。

多模态学习使用不同的方式对不同种类的特征进行提取,然后映射到统一特征空间中进行学习,十分有利于多源异构数据的处理。对于不同数据类型可以各自选择合适的模型进行特征提取。通过多模态学习能够处理和关联来自多种模式信息的模型,对于许多实际问题,多模态学习常常为涉及多模式数据的问题提供了很多改进的性能。多模态学习与传统机器学习的区别见表 2。

1.4 模型结构

对不同结构的数据类型分别选择合适的神经网络类型进行特征提取,以取得更好的特征提取效果。将海洋环境遥感数据经本研究方法转换后的三维矩阵看作 RGB 三通道图像格式,在该数据类型中,同一通道内同一种海洋环境因子是相似的,但是也存在类似于纹理的差异性。不同通道的数据差异较大,但在空间位置上又相互关联,通过卷积神经网络进行特征提取能够融合多种环境因子,同时减少参数量。时空环境因子是离散的数值型数据,适用于 DNN 进行特征提取。本试验的数据类型存在图像

格式和数值型 2 种模态,所以 2 种数据类型可以分别在特征提取后进行特征融合,然后使用全连接层映射到标签空间内进行分类。

整个模型的设计分为 2 个分支结构,一个结构是使用卷积神经网络提取海洋环境因子特征,另一个结构则是利用 DNN 提取时空因子特征,将 2 种特征融合后共同输入到全连接层进行分类。具体流程如图 2 所示。

表 2 多模态学习与传统机器学习比较

Table 2 Comparison of multimodal learning and traditional machine learning

对比层面	传统机器学习方法	多模态学习方法
融合途径	多样性	较单一
对 GPU 的要求	较高	不高
特征学习途径	数据中学习特征	手动设计学习特征
超参数数目	丰富	较少
数据预处理	不苛刻	严格
扩展程度	容易	不易
实验效果	较准确	不准确

1.4.1 卷积结构设计 卷积部分的输入矩阵大小为 $5\times5\times3$,故在卷积过程不适合进行池化操作,全局采用 64 个 3×3 大小的卷积核进行操作,最终使用全局平均池化将三维特征值矩阵转换为二维特征向量,该向量用于后续的特征融合。具体的卷积分支结构如表 3 所示。

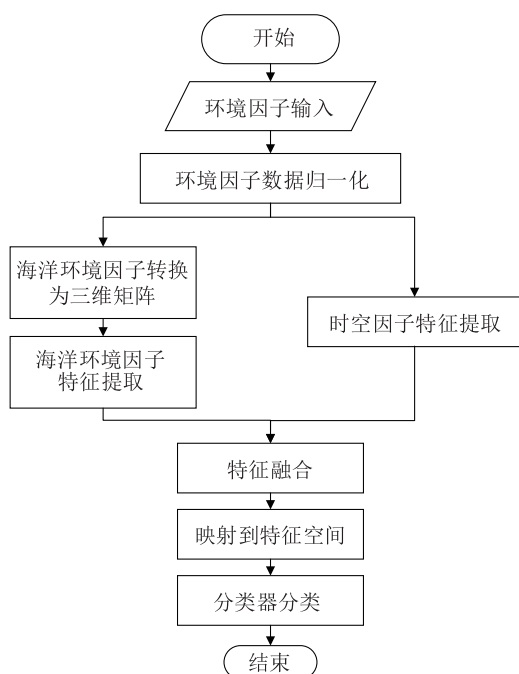


图2 模型整体操作步骤流程图

Fig.2 Flow chart of overall operation steps of the model

表3 卷积模型结构参数

Table 3 Structural parameters of the convolution model

输入矩阵大小	卷积核大小	卷积核数目	输出矩阵大小
5×5×3	3×3	32	5×5×32
5×5×32	3×3	32	5×5×32
5×5×32	3×3	32	5×5×32

5×5 大小的全局平均池化的输出矩阵大小为 1×1×32。

1.4.2 深度神经网络结构设计 深度神经网络分支的输入层为月份、经度、纬度 3 种时空因子构成的特征向量。为了使特征提取后的权重与 3 种海洋环境因子相同,该分支采用与卷积神经网络分支滤波器数目相同的隐层节点数,即 3-32-32-32 结构,如图 3 所示。

1.4.3 模型整体结构 海洋环境因子数据与时空因子数据经上述设计的 2 个分支结构进行特征提取后得到 2 个长度为 32 的特征向量。由于海洋环境因子与时空因子都对渔业 CPUE 有很大的影响,考虑到各个提取到的环境因子的重要性难以确定,本模型将 2 个特征向量进行拼接,并在融合后的特征层新增 2 个含 64 个节点的全连接层,以便于 2 种特征更加充分地融合。

由于预测中心渔场与非中心渔场为二分类问




图3 深度神经网络模型分支结构图

Fig.3 Branch structure diagram of deep neural network model

题,故在全连接层后新增一个 Sigmoid 函数作为输出层。在试验中我们视中心渔场标签为 1,非中心渔场标签为 0,当正负样本分布均匀时,我们认为输出值 y ,满足:

$$\frac{y}{1-y} > 1 \quad (5)$$

即输出 $y > 0.5$ 时,将该作业区域视为为中心渔场。由于渔场等级划分时中心渔场与非中心渔场所占比重差异很大,因此将分类阈值重新调整为:

$$\frac{y}{1-y} > \frac{T}{F} \quad (6)$$

其中 $T = 2\,669$ 为训练集中心渔场的数目, $F = 5\,182$ 为训练集非中心渔场的数目。最终得到分类阈值为 0.34。最终模型的整体结构如图 4 所示。

1.5 试验设计

依据上述长鳍金枪鱼渔场渔情预报方法,分别使用 DNN 和 CNN 模型提取 2 种模态的数据特征,实现双模态渔场渔情预报模型。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 TensorFlow 1.3 框架与 Keras 2.0.8 框架。其中试验训练数据为经过预处理的双模态环境因子数据。2000–2014 年共有数据 7 851 条,另外选择 2015 年 603 条数据作为测试集。模型训练时学习率设置为 0.000 1,采用 Adam 优化器进行训练,并设置最大迭代次数为 50 次。

为验证本研究模型的准确率和优越性,设置了模型对比试验。其他 4 种模型分别是只通过 CNN 分支进行特征提取海洋环境因子并分类的 CNN 模

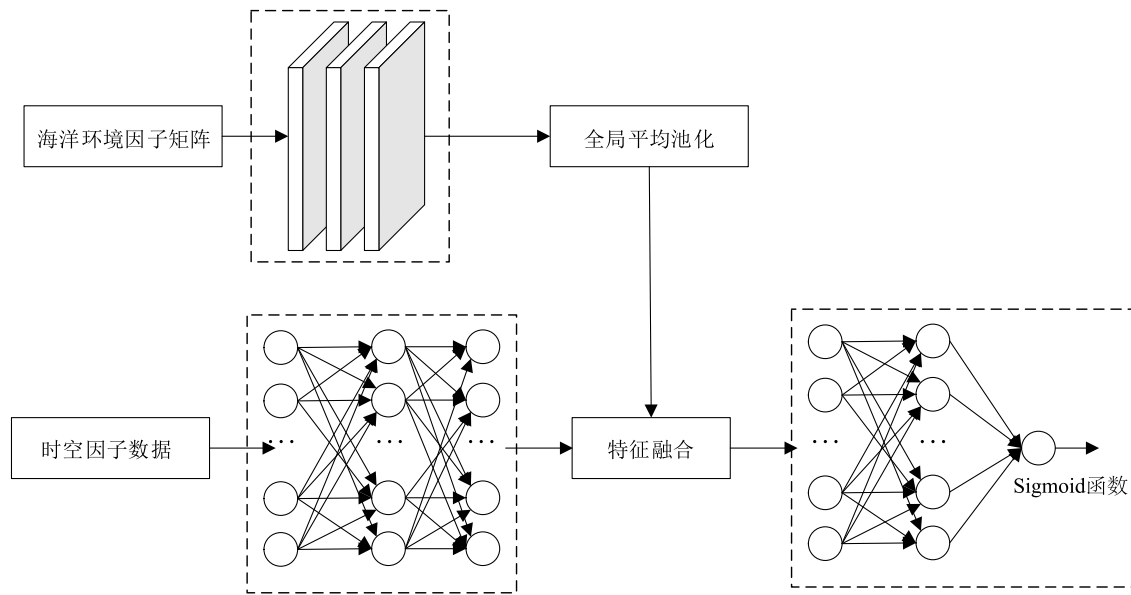


图 4 整体模型分类结构图

Fig.4 Classification structure diagram of overall model

型,只使用 DNN 分支对海洋环境因子与时空因子进行提取并分类的 DNN 模型,袁红春等^[7]提出的 F-ACN(全卷积深度神经网络)模型以及采用基于 FastICA 方法进行独立成分分析的朴素贝叶斯模型。

2 结果与分析

2.1 不同模型训练拟合过程对比分析

试验结果表明,F-CAN 模型能够对大规模海洋数据进行特征提取,在准确率上该方法与传统渔情预报方法相比有较为明显的提升。基于双模态深度学习方法是在 F-CAN 模型的基础上处理高维复杂海洋数据时提出的一种新思路。F-ACN 模型的多层非线性结构和庞大可训练参数能够比较充分地拟合多参数间的非线性关系,但 F-ACN 模型在训练初期学习进度较为缓慢,无法判明类别,梯度方向也不断变化,当进行 10 次迭代后,损失值开始快速下降。而本研究提出的多模态深度学习方式采用多分支结构,相较于传统卷积神经网络参数量较小,经过多次试验发现大约进行 50 次迭代后模型就达到了拟合状态,并且从预测结果可以看出,本研究提出的方法具备更好的拟合效果。

2.2 不同模型渔场渔情预测结果比较

不同模型预测结果表明,分别使用 2 种模型对 2 种模态数据进行特征提取的双模态模型极大地提高了南太平洋长鳍金枪鱼渔场渔情的预报精度,预

测结果如表 4 所示。由表 4 可以看出,相比于其他模型,本研究提出的双模态学习模型总体准确率最高。双模态学习模型的优点是能够针对不同结构的特征进行特征提取,所获得的特征值更加具有代表性。双模态学习模型对于中心渔场的预报准确率达到 89.8%,远高于其他模型,可以准确地反映南太平洋长鳍金枪鱼的渔场资源水平。由于模型的总精准率均达到了 83.5%,不仅可以准确地预报中心渔场位置,而且误报率较低。双模态学习模型分别针对矩阵型数据和数值型数据使用 2 种神经网络进行特征提取,取得了远高于单模态模型 CNN 或 DNN 的预报准确率,同时弥补了单模态模型对于不同类型特征进行提取时的不足,可以充分利用卷积神经网络的特征提取能力和 DNN 模型优秀的特征融合能力,发挥各自的优势。

朴素贝叶斯模型是通过对历史数据的频率统计得到先验概率和条件概率,从而计算出后验概率。故朴素贝叶斯模型虽同为分类模型,但其要求输入模型前各变量相互独立,在模型训练前需要对多种输入参数进行独立成分分析,这不仅会增加模型复杂度,同时还易损失数据信息量。

F-ACN 模型主要由多层卷积神经网络和 DNN 构成,具备更强的非线性,比朴素贝叶斯模型包含更多的可训练参数。与此同时,F-ACN 模型通过全卷积网络结构,取消了池化操作,使用步长为 2 的卷

积层来代替,模型在卷积层的计算量较普通卷积网络减少了 1/2,极大地加速了运算速度。针对海洋数据大规模、多源化、异构性的特点,该模型能够较好地拟合复杂的海洋数据,自动获取海量高维海洋大数据中存在的复杂关联,F-CAN 模型较朴素贝叶斯模型能更精准地预报渔场渔情。对比回归模型,F-ACN 模型得到的预报结果是一个离散值,不存在一个连续的预测概率值,所以能够更明确直观地表

示对渔场渔情等级的预测水平。F-ACN 模型结构作为一种“黑盒”模型,对渔业数据的假设条件不作要求,只先对数据进行三维独热编码简单处理即可,无需考虑环境因子间的相互影响,且当环境因子种类增加时,只需增加训练集三维矩阵的维度即可在原模型上继续训练,故相较于其他模型而言,F-ACN 模型具有较好的可扩展性与简易性。

表 4 不同模型的渔场渔情预测结果

Table 4 Fishery forecasting result of different models in the fishing ground

模型	中心渔场召回率 (%)	非中心渔场召回率 (%)	总召回率 (%)	总精准率 (%)	总 F ₁ 分数 (调和平均数) (%)
双模态学习模型	89.8	74.3	79.6	83.5	80.1
CNN 模型	77.2	66.3	71.7	69.6	69.0
DNN 模型	78.6	75.6	77.1	74.9	75.3
F-ACN 模型	84.0	75.3	78.3	81.1	78.8
朴素贝叶斯模型	52.5	59.1	63.5	64.1	63.7

但 F-ACN 模型仅考虑了渔场与环境因子的关联关系进行独立渔场渔情预报,而南太平洋长鳍金枪鱼作为一种高度洄游性的大洋鱼类,各渔区的渔场数据在一段连续时间内与时空因素存在一定的关联关系。本研究提出的基于双模态深度学习的方法将渔场的时间序列因素和空间因子分别采用 CNN 和 DNN 进行提取,将特征加入到模型中,更进一步提高了渔场渔情预报准确率。通过 CNN 模型对任意空间分辨率的海洋环境因子数据进行特征提取,解决了海洋环境因子空间分辨率与渔业作业数据空间分辨率不匹配的问题。该模型可以通过卷积运算获取5°×5°渔业作业范围内1°×1°的信息,同时卷积运算的输入矩阵保留了各个数据点的空间位置信息和5°×5°空间内环境因子的内部规律,远优于各种手工的归一化方法。在多个卷积核对不同层之间的各个环境因子进行交互运算时,由于卷积运算权重共享的特性,各卷积层的参数量仅为3×3×32,与全连接操作相比减少了近 2/3 的参数量。

2.3 其他影响因素对预测结果的影响分析及拓展

由于在实际渔场预报中,月份、纬度等时空因子对渔业 CPUE 的影响较大,在渔场渔情预报过程中必须要对时空因子进行兼顾,因此本模型采用多分支结构。一方面考虑到时空因子的重要性,多分支结构减少了高维度环境因子特征提取

时对预测结果产生的影响,同时在全连接层将 2 种特征进行融合,使 2 种特征相互补充,最后输入到分类器中。CNN 分支与 DNN 分支在模型结构上虽然不同,但在特征提取过程互不影响,且各分支结构的输出向量维度一致,故提取的特征向量能够较好地进行融合,并不会由于参数量的差异导致某种环境因子所占比重较小或被忽略。本模型为提高中心渔场预报精度,将渔业数据划分为中心渔场和非中心渔场 2 类,使渔场等级标签更加明确。此外,由于本模型减少了渔场的类别,一定程度上缓解了模型由于类别划分不清导致分类精度下降的问题。同时,使用卷积神经网络对海洋环境因子进行特征提取能够减少数据预处理过程中造成的信息损失,该模型能够将任意空间分辨率的海洋环境因子与时空因子相结合,对复杂的海洋大数据有较好的适用性和可扩展性。试验结果表明,本模型对中心渔场的预报准确率可以达到 89.8%,完全可以满足现有渔业作业的需求。不过长鳍金枪鱼的中心渔场分布除了受上述因素影响外,还可能受到海水流速、海面风场、海水盐度、海水溶解氧浓度等因素影响,因此下一步的延伸研究工作是收集和分析更多的海洋环境参数数据,将其加入到模型中,进行更多影响因子的综合处理与分析,以期更加准确地为海洋渔业提供技

术支撑。

3 结论

本研究针对传统渔场渔情预报方法在处理高维复杂海洋数据时难以拟合海洋大数据的缺陷,提出了一种基于双模态深度学习的南太平洋长鳍金枪鱼渔场渔情预报模型,使用 CNN 和 DNN 分别提取不同类型数据的特征。该模型能够对大规模任意空间分辨率的海洋环境因子进行特征提取,省去了手动匹配不同空间分辨率的过程,减少了人工干预,为渔场渔情预报提供了一种全新思路。

采用海面高度、海表温度、叶绿素 a 含量 3 种环境因子,增加了卷积神经网络模型的输入矩阵维度,提高了南太平洋长鳍金枪鱼渔场渔情预报准确率。在双模态学习模型中对于海洋环境因子和时空因子的融合使用特征拼接方法,进一步提高了准确率,同时也省去池化操作,提高了运算速度。本研究对各个分支结构的节点数、层数、不同尺度卷积核进行了试验,增强了模型的特征提取能力,预报精度达到了 89.8%,相较于其他模型,极大程度提高了预测精确度,对于南太平洋长鳍金枪鱼的渔业作业有较好的指导作用。试验结果证明了双模态深度学习技术在渔场渔情预测领域的优越性。

参考文献:

- [1] NIKOLIC N, MORANDEAU G, HOARAU L, et al. Review of albacore 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] 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.
- [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, 1959-1987[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] 高峰,陈新军,官文江,等.基于提升回归树的东、黄海鲈鱼渔场预报[J].海洋学报,2015,37(10):39-48.
- [17] 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.
- [18] SRIVASTAVA N, SALAKHUTDINOV R. Multimodal learning with deep boltzmann machines[J]. Journal of Machine Learning Research, 2014, 15(8):1967-2006.
- [19] 林大超,安风平,郭章林,等.滑坡位移的多模态支持向量机模型预测[J].岩土力学,2011,32(S1):451-458.
- [20] 姜远,黎铭,周志华.一种基于半监督学习的多模态 Web 查询精化方法[J].计算机学报,2009,32(10):2099-2106.

(责任编辑:张震林)