

# 提示工程下的海洋牧场经济效益分析方法

张伊伊<sup>1</sup>, 杨 习<sup>2†</sup>, 钟 欣<sup>3</sup>

1. 武汉职业技术大学 数智商务学院, 湖北 武汉 430074;
2. 广东海洋大学 数学与计算机学院, 广东 湛江 524000;
3. 武汉理工大学 计算机与人工智能学院, 湖北 武汉 430070

收稿日期: 2026-04-04 † 通信联系人 E-mail: yang20961113@163.com

基金项目: 国家自然科学基金(62271361); 湖北省重点研发计划(2024BAB039)

第一作者: 张伊伊, 女, 讲师, 现从事量化金融、小样本学习、多模态数据融合等研究。E-mail: 20180021@wtc.edu.cn

**摘 要:** 海洋牧场经济效益智能化分析是海洋养殖产业精细化运营的核心支撑。现有数据驱动下的智能化分析方法依赖大量的标注样本, 难以在小样本场景下充分挖掘海洋牧场的深层语义, 从而导致模型出现欠拟合的问题。为缓解上述问题, 本文提出了两种提示工程下的智能分析方法: 零样本下的经济效益分析方法(Prompt-Engineered Sea Ranching Economic Analysis, PE-SEA)和样本增强下的经济效益分析方法(Prompt-Augmented Pretraining for Sea Ranching Economic Analysis, PAP-SEA)。这两种方法均使用提示工程引导大语言模型对海洋牧场相关数据进行分析, 预测未来的经济效益。PE-SEA 基于 GPT-4 进行零样本推理, 不依赖额外训练数据; PAP-SEA 则使用 ChatGPT 进行样本增强, 模型训练与推理均在本地完成。PE-SEA 适合性能优先的场景, PAP-SEA 适合数据安全与隐私保护要求较高的场景。为便于实际应用, 本文开发了海洋牧场经济效益实时智能化分析工具 SeaPastureGPT。实验在三个不同海域、不同养殖品种的实际监测数据集上进行。实验结果表明, 本文的两种方法在 6 个评价指标(精确率, 召回率,  $F1$ , ROC 曲线下方的面积, 马修斯相关系数, 准确率)上整体性能均优于现有的主流方法。其中, PE-SEA 较性能最好的基线方法 KnowledgeGraph-BERT 在  $F1$  上提升了 70.67%。文本的方法为产业研究与从业者提供了理论依据。

**关 键 词:** 海洋牧场; 经济效益分析; 提示工程; 大语言模型; 预训练模型; SeaPastureGPT

中图分类号: F326.4

文献标志码: A

文章编号: 1671-8836(2026)04-0519-12

## Economic Benefit Analysis Method for Marine Ranching Under Prompt Engineering

ZHANG Yiyi<sup>1</sup>, YANG Xi<sup>2†</sup>, ZHONG Xian<sup>3</sup>

1. School of Digital and Intelligent Business, Wuhan Technical University, Wuhan 430074, Hubei, China;
2. School of Mathematics and Computer Science, Guangdong Ocean University, Zhanjiang 524000, Guangdong, China;
3. School of Computer Science and Artificial Intelligence, Wuhan University of Technology, Wuhan 430070, Hubei, China

**Abstract:** Intelligent analysis of economic benefits in marine ranching is essential for fine-grained aquaculture management. However, existing data-driven methods rely heavily on large labeled datasets and often suffer from under fitting in small-sample scenarios. To address this problem, this paper proposes two prompt-engineering-based intelligent analysis methods: a zero-shot economic benefit analysis method, named Prompt-Engineered Sea Ranching Economic Analysis (PE-SEA), and a sample-augmentation-based economic benefit analysis method, named Prompt-Augmented Pretraining for Sea Ranching Economic Analysis (PAP-SEA). Both methods use prompt engineering to guide large language models in analyzing marine ranching-related data and predicting future economic benefits. PE-SEA performs zero-shot inference based on GPT-4 and does not rely on additional training data; PAP-SEA uses ChatGPT for sample augmentation, while model training and inference are both completed locally. PE-SEA is more suitable for performance-prioritized scenarios, while PAP-SEA is more suitable for scenarios with higher requirements for

引用格式: 张伊伊, 杨习, 钟欣. 提示工程下的海洋牧场经济效益分析方法[J]. 武汉大学学报(理学版), 2026, 72(4): 519-530. DOI: 10. 14188/j. 1671-8836. 2026. 0063.

ZHANG Yiyi, YANG Xi, ZHONG Xian. Economic Benefit Analysis Method for Marine Ranching Under Prompt Engineering [J]. *J. Wuhan Univ. (Nat Sci Ed)*, 2026, 72(4): 519-530. DOI: 10. 14188/j. 1671-8836. 2026. 0063(Ch).

data security and privacy protection. To facilitate practical application, this paper develops a real-time intelligent analysis tool called SeaPastureGPT for the economic benefits of marine ranching. Experiments are conducted on real monitoring datasets from three different sea areas and aquaculture species. The results show that both methods outperform existing mainstream methods across six evaluation metrics (precision, recall,  $F1$ , area under the ROC curve, Matthews correlation coefficient, and accuracy). In particular, PE-SEA improves the  $F1$  by 70.67% compared with the best-performing baseline method called KnowledgeGraph-BERT. Overall, our methods offer new insights and practical guidance for both academic research and industrial applications.

**Key words:** marine ranching; economic benefit analysis; prompt engineering; large language model; pre-trained model; SeaPastureGPT

## 0 引言

海洋牧场经济效益分析贯穿整个养殖过程,对提升海洋养殖产业的精细化和智能化水平具有重要作用。其分析内容涵盖养殖成本核算、收益预测、投入产出比评估等,分析结果直接决定海洋牧场的养殖品种选择、养殖密度调控、资源投入优化等运营决策<sup>[1]</sup>。智能化分析主要借助人工智能技术,对经济效益指标进行自动化趋势预测、效益计算以及关联分析,从而提升其效率与准确性<sup>[2]</sup>。

近年来,基于学习的海洋牧场经济效益智能化分析方法<sup>[3-10]</sup>受到研究者的广泛关注。这类方法主要将海洋牧场经济效益智能化分析任务转换为二分类问题,以判断该牧场未来收益是否可观。然而,这类方法需要大量的样本进行训练<sup>[11]</sup>,但海洋牧场养殖周期长、检测成本高以及数据碎片化,实际可获取的样本数量有限。这使得模型难以充分学习数据规律,最终导致模型欠拟合,性能下降。

大语言模型(Large Language Model, LLM)<sup>[12]</sup>的兴起为解决样本稀缺问题提供了新的方法。LLM依托海量开源语料完成自监督预训练,具备丰富的语言知识与领域知识,能够实现小样本或零样本学习下的高质量文本生成与语义推理,有效解决了样本稀缺与人工标注成本高的问题<sup>[13-14]</sup>。同时,提示工程的发展能够引导大语言模型完成不同的下游任务。现有的研究表明,通过设计合理的提示模板,大语言模型能够在软件跟踪、实体识别、数据增强等任务中展现出优越性能<sup>[15]</sup>。

受此启发,针对海洋牧场样本不足导致的模型训练不够充分问题,本文提出两种提示工程下的智能分析方法。本文的主要贡献如下:

1) 提出了提示工程下海洋牧场经济效益分析(Prompt-Engineered Sea Ranching Economic Analysis, PE-SEA)方法,该方法是零样本下的经济效益分析方法,它无需构建训练数据集,通过设计结构化、多维度提示模板直接引导大语言模型完成海上经济

效益分析,适合性能优先且对数据安全与隐私保护要求不高的场景。

2) 在提示增强和预训练模型下,提出了海洋牧场经济效益分析(Prompt-Augmented Pretraining for Sea Ranching Economic Analysis, PAP-SEA)方法,该方法是样本增强下的经济效益分析方法。它利用提示工程引导大语言模型生成高质量样本,然后将生成样本用于下游模型的预训练与数据增强,从语义层面缓解有效分析样本有限与数据分布失衡问题;同时它能有效防止模型在测试集数据上进行推理造成的数据泄露风险,适合数据隐私要求较高的产业应用场景。

3) 开发了经济效益实时智能化分析工具SeaPastureGPT。该工具集成了PE-SEA和PAP-SEA两种方法,能够针对不同的风险安全需求,实现零样本和样本增强下的经济效益分析。在实现海洋牧场经济效益的实时分析的同时为产业实际应用提供技术支撑。本文对工具进行了开源,链接如下:<https://github.com/728None/PAP-ILR-PE-ILR>。

## 1 研究背景与相关工作

### 1.1 预训练模型和大语言模型

以BERT、RoBERTa为代表的预训练语言模型为自然语言处理领域带来了全新范式<sup>[12-13]</sup>。这类模型通过在海量通用语料上进行自监督预训练,学习文本的特征表示,其学习能力受上下文与应用领域的影响<sup>[14]</sup>。预训练模型(如RoBERTa<sup>[16]</sup>)需要在本地结合领域专属数据集进行二次预训练或微调,才能在下游任务中取得理想性能。因此,本文的PAP-SEA方法将海洋牧场相关样本输入到预训练模型中进行微调,实现下游的经济效益分析。

随着通用语料和模型的训练参数不断增加,ChatGPT、DeepSeek以及豆包等大语言模型受到研究者的关注。ChatGPT是基于GPT-3.5(1 750亿参数量)或GPT-4(万亿级参数量)的自回归语言

模型<sup>[12]</sup>,其训练语料涵盖海量网络数据,同时融合了人类反馈的强化学习(Reinforcement Learning from Human Feedback, RLHF)算法,生成的文本更符合人类表达习惯与价值偏好。现有研究表明,ChatGPT无需额外的预训练或微调,在实体识别<sup>[17]</sup>、数据增强<sup>[14]</sup>等下游任务中均表现出卓越性能,且其具备的跨领域知识与语义推理能力,使其能够直接处理海洋牧场经济效益分析这类跨生态、养殖、经济的复合任务。因此,本文使用ChatGPT大语言模型,依托其出色领域知识,实现海洋牧场经济效益的零样本分析与样本增强。

### 1.2 提示工程

提示工程的核心目标是针对不同的下游应用场景设计提示模板,引导大语言模型完成下游任务。已有大量研究针对不同的下游任务设计了专属的提示模板,总结了相关实践经验,为大语言模型在分类、问答、数据增强等任务中的应用提供了有效的支撑<sup>[18]</sup>。提示模板的设计直接影响大语言模型的性能表现,即使是微小的修改,也可能引发模型输出结果的变化<sup>[19]</sup>。针对分类任务,主流的设计思路通常采用问题式引导。即通过设计提示模板将分类任务转化为模型更为擅长的问答形式,设计约束条件使得大语言模型输出“是/否”“相关/无关”等答案,提升模型在判别任务上的准确性<sup>[20]</sup>。本文基于这一设计思路,结合海洋牧场经济效益分析场景,设计了三类专属提示模板,实现大语言模型对分析样本的有效判别。

### 1.3 海洋牧场经济效益分析相关研究

海洋牧场经济效益分析的核心是挖掘生态环境因子(温度、盐度、溶解氧等)、养殖生产指标(养殖密度、投喂量、产量等)与经济效益指标(成本、收入、收益率等)间的关联规律,实现效益指标的预测与评估。近年来,随着海洋牧场数据量的增加,一些研究者们开始关注基于学习的经济效益分析方法。相关研究主要为基于机器学习与深度学习的经济效益分析方法两种。

机器学习下的海洋牧场经济效益分析方法主要将效益分析转化为分类问题,通过随机森林、XGBoost等模型实现经济效益的预测与分析<sup>[3]</sup>。Saville等<sup>[4]</sup>提出了一种基于随机森林预测方法,该方法旨在实时预测海水养殖中的鱼类死亡风险。该方法融合环境监测数据与养殖运行参数,实现对异常死亡事件的提前预警,提升了养殖过程的风险控制能力与生产安全性。Ghaemi等<sup>[5]</sup>针对水产养殖冷却系统在数据受限条件下的能耗优化问题,提出了结合

贝叶斯优化与XGBoost的经济效益分析方法。Jongjaraunsuk等<sup>[6]</sup>提出了一种基于投票机制的集成学习方法。该方法通过水质与环境参数作为模型的输入,融合决策树、深度学习模型和朴素贝叶斯分类器从而预测红斑罗非鱼幼鱼的死亡率。然而,这些方法依赖人工特征工程,特征的选取具有主观性,难以全面和准确地反映海洋牧场数据规律,最终影响模型的性能。

深度学习方法通过多层神经网络结构从原始数据中自动学习有效的特征信息,降低了人工特征工程的负担,成为海洋牧场经济效益分析的新方向<sup>[7]</sup>。例如,Zhang等<sup>[9]</sup>提出基于CNN-XGBoost融合模型的海洋渔业资源动态预测方法。Hao等<sup>[21]</sup>对使用领域知识对BERT进行微调,融合知识图谱揭示水产养殖富营养化的关键因素,他们提出的知识图谱通过语义抽取与关系建模构建生态—生产要素之间的知识网络,实现了复杂环境问题的结构化分析。徐贺<sup>[22]</sup>研究了基于LSTM神经网络的海洋牧场水质预测模型,通过融合非线性和时间序列特征,实现了对水质参数的高精度预测。Kim等<sup>[23]</sup>则通过卷积神经网络和长短期记忆网络对单目海洋视频进行波高分类。

然而,这些方法不适用于海洋牧场样本稀缺的情况,而大语言模型的样本生成能力,为解决这一问题提供了全新路径。因此,本文通过提示工程引导大语言模型结合,从零样本分析与样本增强两个维度缓解有效样本稀缺问题,提升海洋牧场经济效益分析的性能。

## 2 本文方法

### 2.1 PE-SEA

PE-SEA的核心在于实现零样本经济效益分析。该方法无需构建训练数据集,而是通过设计专属提示模板,将海洋牧场经济效益分析任务重构为ChatGPT擅长的问答推理任务,直接引导模型完成对经济效益的预测。整体方法框架如图1所示,PE-SEA主要分为数据预处理、提示工程以及经济效益预测三个部分。

#### 2.1.1 数据预处理

本文主要构建三个方面的数据,分别是生态环境数据、养殖生产数据以及经济收益数据。首先,对三种数据进行数据清洗,清洗步骤包含缺失值处理、异常值检测以及去除重复值。其次,将相同养殖周期内每条生态环境数据和养殖生产数据对应的经济




图1 PE-SEA 整体框架图

Fig. 1 The framework of PE-SEA

收益数据作为正样本。为保证正样本的可靠性,邀请三位领域专家对样本进行核查。若其中两位专家的标注结果一致,则该样本保留为正样本;若专家意见不一致,则由第三位专家对该样本进行复查。负样本是基于时间维度(养殖周期 $\pm 7$ 天)生成的,以7天为一个养殖周期,对7天前的生态环境数据和7天后的生产养殖数据进行随机采样,作为负样本。

### 2.1.2 提示工程

为引导大语言模型进行海洋牧场经济效益分析,本文通过提示工程将生态环境数据和养殖生产数据转换为自然语言描述。即,通过设计不同的提示模板对大语言模型进行引导的同时对输出进行约束,将经济效益分析转换为二分类任务。参考文献[24],设计如下三类提示模板。

**模板 1** “给定如下生态环境和养殖生产数据,以及对应的经济收益结果,判断这些因素是否直接影响经济收益。仅回答‘是’或‘否’。”

**模板 2** “给定如下生态环境与养殖生产数据,以及对应的经济收益结果,判断这些因素与经济收益之间是否存在关联关系。请仅回答‘是’或‘否’。”

**模板 3** “给定如下生态环境和养殖生产数据,以及对应的经济收益结果,判断这些因素是否能够合理解释该经济收益。请仅回答‘是’或‘否’。”

模板 1 为因果判断型,从因果关系方面引导模型分析样本中生态、养殖数据是否和经济效益数据有直接影响。模板 2 为关系推理型,从关联关系引导模型对样本进行经济效益分析。模板 3 为决策导向型,从实际应用价值方面,引导模型分析样本中的养殖生产策略是否能够有效改善经济效益问题。在不同的提示模板下,大语言模型的推理结果也不同。

### 2.1.3 零样本经济效益分析

采用大语言模型 ChatGPT 作为经济效益分析模型。该模型基于 Transformer 解码结构,在大规模语料数据上进行预训练,能够学习文本的上下文关

系,具备较强的语义理解与逻辑推理能力<sup>[14]</sup>。本文将 2.1.2 中设计的提示模板和海洋牧场数据进行横向拼接得到  $x$ ,然后将  $x$  输入到 ChatGPT 中进行推理分析。在提示模板的引导下,模型生成经济效益预测结果  $y$ ,即回答“是”或者“否”。ChatGPT 采用自回归方法生成结果,该模型通过链式法则根据输入数据预测下一个 token,其生成过程可表示为:

$$P(y|x) = \prod_{t=1}^T P(y_t | y_{<t}, x) \quad (1)$$

其中,  $y_t$  表示模型生成的 token,  $y_{<t}$  表示在第  $t$  个位置之前已经生成的内容。由于本文通过提示模板将模型的输出结果限制为“是”或“否”,因此输出序列长度为 1。整个过程不涉及训练样本和模型参数更新。

## 2.2 PAP-SEA

图 2 是 PAP-SEA 的整体框架图,该方法主要分为数据预处理、样本增强和预训练模型微调三个部分。其中,数据处理部分和 2.1.1 节相同,主要是进行数据的清洗和正负样本生成;样本增强部分通过大语言模型和提示模板模仿数据中的正样本生成新的样本;预训练模型微调是将增强后的样本输入预训练模型中进行 LoRA (Low-Rank Adaptation, 低秩适应)<sup>[25]</sup> 微调,微调好的模型在测试集上完成经济效益分析与评估。下面分别介绍样本增强和预训练模型微调。

### 2.2.1 样本增强

样本增强是通过对原始数据进行变换或重构以生成新样本的过程,在小样本场景下被广泛地应用<sup>[9,16]</sup>。生成的样本在保持语义一致性的同时,应具备一定的多样性,在丰富数据分布的同时提升模型的泛化能力。本文使用大语言模型对海洋牧场数据中的正样本进行扩充。

将生态环境和养殖生产数据记为  $s \in S$ , 经济效益数据记为  $m \in M$ 。海洋牧场原始样本如(2)式所示:




图2 PAP-SEA 整体框架图

Fig. 2 The framework of PAP-SEA

$$PD = \{(s_i, m_i, y_i)\}_{i=1}^N \quad (2)$$

其中,  $y_i \in \mathcal{Y} = \{0, 1\}$  表示样本标签,  $y_i = 1$  表示正样本,  $y_i = 0$  表示负样本。原始正样本如(3)式所示:

$$D^+ = \{(s_i, m_i) \mid y_i = 1\} \quad (3)$$

其中, 正样本的数量记为  $N^+$ 。本文将正样本  $(s_i, m_i)$  与设计的提示模板  $\mathcal{P}$  结合后输入到大语言模型中。随后, 大语言模型通过语义推理生成对应的生态环境、养殖生产解决方案, 形成完整的“生态、养殖、经济”增强正样本  $(s'_i, m'_i)$ 。从而构造新的有效样本  $D_{\text{aug}}^+$ 。其过程如下:

$$G_\phi: (s_i, m_i, \mathcal{P}) \rightarrow (s'_i, m'_i) \quad (4)$$

$$D_{\text{aug}}^+ = \{(s'_i, m'_i, 1)\}_{i=1}^{N^+} \quad (5)$$

其中,  $G_\phi$  表示参数为  $\phi$  的大语言模型。为避免数据分布失衡, 针对每一条原始正样本, 生成1条新的正样本, 即  $|D_{\text{aug}}^+| = |D^+|$ 。然后将生成的新正样本和原始正负样本进行组合, 组合后的训练集定义如(6)式所示:

$$D_{\text{train}}^{\text{aug}} = D \cup D_{\text{aug}}^+ \quad (6)$$

其中, 样本规模为  $N + N^+$ 。

相较于传统的数据增强方法, 引入了大语言模型的数据增强方法具有以下优势。

**语义一致性高:** 大语言模型融合了人类反馈的强化学习技术, 生成的文本更符合人类表达习惯与产业逻辑<sup>[26]</sup>。该模型通过语义推理和问答生成能力将海洋牧场的经济效益问题转化为对应的生态—养殖方案, 生成的分析样本能够准确反映生态—养殖—经济效益的关联规律, 语义一致性与实际产业样本高度匹配。

**样本多样性丰富:** 大语言模型的训练语料涵盖海量跨领域数据, 具备丰富的语言知识与领域知识, 能够生成不同生态条件、养殖模式下的有效分

析样本, 提升样本的多样性, 避免模型过拟合<sup>[26]</sup>。

**语义推理能力强:** 大语言模型具备较强的跨领域语义推理能力, 能够理解海洋牧场经济效益分析中的复杂关联规律, 生成的有效分析样本质量更高, 更能支撑模型的特征学习<sup>[27]</sup>。

### 2.2.2 基于RoBERTa的预训练模型微调

该阶段通过对预训练模型进行微调, 旨在让模型在训练集上学习海洋牧场样本规律, 从而在测试集上进行经济效益分析。本文使用 RoBERTa 作为预训练模型。该模型基于 Transformer 编码结构, 通过多层自注意力机制建模输入文本的上下文依赖关系<sup>[16]</sup>。在特征表示阶段, 将增强后的样本  $D_{\text{train}}^{\text{aug}}$  作为训练集输入预训练模型中提取语义特征。设模型输出的语义表示如下:

$$h_i = \text{RoBERTa}(s_i, m_i, [\text{CLS}]) \quad (7)$$

其中,  $h_i \in \mathbb{R}^d$  表示第  $i$  个样本的特征向量,  $[\text{CLS}]$  表示对应的掩码部分。在分类阶段, 将特征向量  $h_i$  输入到全连接层, 通过 Sigmoid 激活函数得到样本的预测概率。具体过程如下:

$$\hat{y}_i = \sigma(\mathbf{W}h_i + \mathbf{b}) \quad (8)$$

其中,  $\mathbf{W}$  和  $\mathbf{b}$  为可训练参数,  $\sigma(\cdot)$  为 Sigmoid 激活函数<sup>[28]</sup>。模型在训练过程的优化目标是 minimized 训练集上的交叉熵损失函数  $\mathcal{L}_{\text{cls}}$ <sup>[29]</sup>, 损失函数计算如下:

$$\mathcal{L}_{\text{cls}} = -\frac{1}{N'} \sum_{i=1}^{N'} [y_i \log \hat{y}_i + (1 - y_i) \log (1 - \hat{y}_i)] \quad (9)$$

模型通过最小化交叉熵损失和梯度下降更新模型参数, 对真实类别赋予更高的预测概率, 并对错误类别赋予更低的预测概率, 从而使得预测概率  $\hat{y}_i$  逐步接近真实标签  $y_i$ 。

为了提升微调效率并适应小样本场景, 采用 LoRA 对预训练模型的部分参数进行微调。将 LoRA 作用于 Transformer 编码层中的线性映射, 通过引入

低秩矩阵  $\Delta W$  对原始权重进行调整,过程如下:

$$W' = \Delta W + W \quad (10)$$

$$\Delta W = \frac{\alpha}{\gamma} BA \quad (11)$$

其中,  $B$  和  $A$  分别表示低秩矩阵,  $\gamma$  表示低秩维度,  $\alpha$  表示缩放系数。在训练过程中,预训练模型仅更新低秩矩阵的参数,其他参数保持不变。模型训练完成后,将测试集样本输入训练好的预训练模型中,得到预测概率  $\hat{y}_k$ 。当  $\hat{y}_k > \gamma$  (默认阈值  $\gamma = 0.5$ ) 时,判定为正样本,即生态环境—养殖生产数据和经济效益有关。否则判定为负样本,即两者无关。

### 2.3 SeaPastureGPT 工具设计与实现

本文开发了 SeaPastureGPT 工具以实现海洋牧场经济效益的实时智能化分析。该工具的开发语言为 Python,通过 API 对接 GPT-3.5-turbo-16k 与 GPT-4 大语言模型,集成了零样本分析、批量数据分析、样本增强、自定义模型与模板等功能。工具的核心功能如下。

**零样本分析:**该工具部署了 PE-SEA 方法。用户在对话框中输入海洋牧场的生态—养殖—经济效益数据,工具自动结合设计好的提示模板,调用大语言模型完成实时分析,并输出“是/否”的判别结果。

**批量数据分析:**该工具支持用户批量导入海洋牧场的数据集;自动遍历数据集中的所有样本,批量完成经济效益分析,并生成分析报告(含正样本统计、经济效益预测等)。

**样本增强:**该工具部署了 PAP-SEA 方法,具有样本增强功能。用户导入原始正样本后,工具通过大语言模型生成新的正样本,并将增强后的样本以标准化格式导出,为模型的训练提供新的数据支撑。

**自定义模型与模板:**工具预留了模型 API 与提示模板的自定义接口,用户可根据实际需求对接其他大语言模型(如 Llama3、Qwen-2),并通过设计多样化的提示模板,提升工具的场景适配性。

## 3 实验

### 3.1 研究问题

本文提出三个研究问题(Research Questions, RQs),分别从提示模板和模型选择、样本增强的有效性、方法整体性能三个维度对 PE-SEA 与 PAP-SEA 方法进行评估。

RQ1:哪种提示模板和大语言模型在 PE-SEA 方法中的表现更优?

RQ2:提示工程能否引导大语言模型生成有效

的海洋牧场数据样本?

RQ3:与当前主流的海洋牧场经济效益分析方法相比,PE-SEA 与 PAP-SEA 的性能如何?

RQ1 旨在探索不同的提示模板与大语言模型对 PE-SEA 的性能影响,从而选取最优的模板和模型组合;RQ2 旨在评估样本增强对模型性能的提升效果,同时比较不同的大语言模型生成的样本质量;RQ3 通过将本文的方法与主流方法对比从而评估两种方法的整体性能。

### 3.2 实验环境

在硬件方面,实验平台配备 Intel® Xeon® Gold 6248R 处理器,搭载 NVIDIA GeForce RTX 3090 Ti 图形处理器(24 GB 显存),并配置 32 GB 运行内存,以支持大规模语义表示计算与模型训练过程中的显存需求。在运行环境方面,运行环境为 Python 3.9,主要依赖 PyTorch 1.13.1 作为深度学习框架,Transformers 4.30.2 用于加载与调用预训练模型,Scikit-learn 1.2.2 用于模型评估与指标计算,同时结合 Pandas 1.5.3 与 NumPy 1.24.3 进行数据处理与数值计算。在模型调用方面,本文通过 OpenAI API<sup>[30]</sup>调用 GPT-3.5-turbo-16k 与 GPT-4 模型以实现样本增强与语义推理功能。预训练模型部分采用 HuggingFace<sup>[31]</sup>提供的 RoBERTa-large<sup>[16]</sup>的参数权重作为初始化模型,然后在训练集上完成微调。

### 3.3 实验数据集

选取南海金鲳鱼、黄海大黄鱼、渤海石斑鱼实际监测数据集作为实验数据。该数据集涵盖三大海域,养殖品种均为我国海洋牧场的主流养殖品种。数据由海洋养殖科研机构与牧场企业联合提供,包含了 2019—2023 年的生态环境、养殖生产以及经济效益三个方面的数据。数据集的详细信息如表 1 所示。

实验将所有数据集按照 8:1:1 的比例划分为训练集、验证集与测试集。其中训练集用于 PAP-SEA 方法的微调阶段,验证集用于在模型训练过程中早停,测试集则用于对所有方法进行性能评估。为保证对比实验的公平性和可复现性,本文方法和所有基线方法均使用相同的训练集、验证集与测试集。

### 3.4 评价指标

为全面、系统地评估本文方法与基线方法的性能,实验选取分类任务中最常用的 6 个评价指标<sup>[32]</sup>:精确率(Precision)、召回率(Recall)、F1、ROC 曲线下方的面积(Area Under Curve, AUC)、马修斯相关系数(Matthews Correlation Coefficient, MCC)以

表 1 实验数据集详细信息  
Table 1 Detailed of the experimental dataset

| 牧场所属海域 | 养殖品种 | 生态环境数据/条 | 养殖生产数据/条 | 正样本数 | 负样本数   | 数据维度 |
|--------|------|----------|----------|------|--------|------|
| 南海     | 金鲳鱼  | 12 00    | 800      | 89   | 286    | 23   |
| 黄海     | 大黄鱼  | 950      | 720      | 266  | 866    | 21   |
| 渤海     | 石斑鱼  | 3 500    | 3 200    | 725  | 13 999 | 25   |

及准确率 (Accuracy, ACC)。各指标的计算公式如下:

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (12)$$

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (13)$$

$$F1 = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (14)$$

$$\text{ACC} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FN} + \text{FP}} \quad (15)$$

MCC =

$$\frac{\text{TP} \times \text{TN} - \text{FP} \times \text{FN}}{\sqrt{(\text{TP} + \text{FP})(\text{TP} + \text{FN})(\text{TN} + \text{FP})(\text{TN} + \text{FN})}} \quad (16)$$

其中, TP 为真阳性 (正样本判为正样本), FP 为假阳性 (负样本判为正样本), TN 为真阴性 (负样本判为负样本), FN 为假阴性 (正样本判为负样本)。ROC 曲线以真阳性率 (True Positive Rate, TPR) 为纵轴、假阳性率 (False Positive Rate, FPR) 为横轴, 如 (17) 和 (18) 式:

$$\text{TPR} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (17)$$

$$\text{FPR} = \frac{\text{FP}}{\text{FP} + \text{TN}} \quad (18)$$

### 3.5 基线方法

本文选取了三种具有代表性的海洋牧场经济效益分析方法作为基线方法。这些方法包含了机器学习与深度学习方法, 均为该领域的主流方法。为确保实验结果的公平性, 所有基线方法都按照文中的参数进行训练和测试。

1) EL-V(DT-DL-NB)<sup>[6]</sup>: 是一种面向水产养殖死亡率预测的集成学习方法, 通过融合决策树、深度学习模型和朴素贝叶斯三类基分类器构建投票集成框架。该方法以水质与环境参数 (如温度、溶解氧、pH 值、氨氮、亚硝酸盐等) 为输入特征, 通过多模型协同决策提高预测稳定性与准确率。

2) CNN-XGBoost<sup>[9]</sup>: 该方法采用 CNN 从海洋环境时间序列数据中提取深层特征, 再将提取的特征输入 XGBoost 进行预测, 实现对海洋渔业资源动

态变化的建模。将深度特征提取和集成学习预测相结合, 该模型在复杂非线性时序预测任务中表现出较高的精度与稳定性, 是海洋牧场经济效益分析中具有代表性的方法。

3) KnowledgeGraph-BERT<sup>[21]</sup>: 该方法基于领域专用 BERT 进行语义表示学习, 并结合实体识别与关系抽取技术构建水产养殖知识图谱, 用于分析养殖活动与环境影响之间的关联关系。该模型能够自动挖掘关键驱动因素, 具有较强的语义理解能力与可解释性。

本文比较了两种样本增强方法, 以验证大语言模型在样本增强方面的性能, 分别为 SMOTE (Synthetic Minority Over-sampling Technique)<sup>[33]</sup> 和插值增强 (Interpolation-based Augmentation)<sup>[34]</sup>。其中, SMOTE 的核心思想是在特征空间中选取少数类样本及其近邻样本, 并沿两者连线方向随机生成新的合成样本。本文采用 scikit-learn 中的 imbalanced-learn 库<sup>[35]</sup> 实现 SMOTE 方法。插值增强则通过对同类别样本之间进行线性组合生成新样本。

### 3.6 实验结果与分析

3.6.1 RQ1: PE-SEA 中最优的提示模板与大语言模型

**实验设计:** 针对 RQ1, 实验首先在 GPT-3.5-turbo-16k 上验证三类提示模板的性能, 筛选出最优模板。然后, 将最优模板在 GPT-4 上进行验证, 对比两种大语言模型的性能差异。同时, 实验通过模型调用费用进行成本分析, 对实际应用场景下的模型选择策略进行综合评估。实验结果如表 2 所示。

**不同提示模板性能对比:** 由表 2 可知, 提示模板 3 的综合性能最优。在 GPT-3.5-turbo-16k 上, 提示模板 3 在所有数据集上的 F1、AUC、MCC 指标均优于提示模板 1 和 2。对于其他指标, 模板 2 和模板 3 在黄海大黄鱼上的 ACC 均为 0.870 0, 但模板 3 的 F1、AUC 和 MCC 均略高于模板 2, 说明在整体准确率相同的情况下, 模板 3 具有更好的正负类判别能力。相较提示模板 1 和 2, 模板 3 在黄海大黄鱼上的 Precision 略有下降, 但 Recall 得到大幅提升。在海洋牧场经济效益分析场景中, 较高的 Recall 意味着

能够识别出更多正样本,从而为养殖决策提供更全面的参考依据。因此,在实际应用中,为提升 Recall 而牺牲少量 Precision 是可接受的。模板 3 的优势在于其聚焦“问题解决”,更贴合海洋牧场实际运营决策需求,也更符合大语言模型的语义推理逻辑,因此能够取得更优性能。

**不同大语言模型性能对比:**在最优模板 3 的条件下,除南海金鲷鱼数据集中的 Precision 指标外,GPT-4 在其余数据集和评价指标上均优于 GPT-3.5-turbo-16k。在南海金鲷鱼数据集上,GPT-3.5-turbo-16k 的 Precision 为 0.888 9,但是其 Recall 为 0.666 7,说明模型预测为正类的样本中正确比例较高,但对边界特征不明显的样本,模型更加倾向于判断为负类,从而漏掉了较多真实正类样本。相比之下,GPT-4 虽然在南海金鲷鱼数据集上的 Precision 值略低,但其 Recall、F1、AUC、MCC 和 ACC 等综合指标均表现

更好,说明 GPT-4 能够在减少误判和降低漏判之间取得更合理的平衡。性能差异主要源于 GPT-4 具有更大的参数规模、更丰富的训练语料以及更强的语义推理能力,能够更加准确地理解生态环境、养殖生产与经济效益之间的复杂关联关系。

**成本分析:**从使用成本来看,GPT-4 的 API 调用价格为每 1 000 tokens 0.03 美元,而 GPT-3.5-turbo-16k 为 0.002 美元,前者约为后者的 15 倍。虽然 GPT-4 在性能上更优,但 GPT-3.5-turbo-16k 在结合优化提示模板(如提示模板 3)后,同样能够获得较为理想的分析效果。因此,在成本敏感的产业应用场景下,GPT-3.5-turbo-16k 具有更高的性价比。

**RQ1 的结论:**对于 PE-SEA 方法,在性能优先情况下建议选取“GPT-4”和提示模板 3;在成本受限的情况下,“GPT-3.5-turbo-16k”和提示模板 3 性价比更高。

表 2 不同提示模板与大语言模型在 PE-SEA 中的性能对比

| Table 2 Performance comparison of different prompt templates and LLMs in PE-SEA |                   |      |           |         |         |         |         |         |
|---------------------------------------------------------------------------------|-------------------|------|-----------|---------|---------|---------|---------|---------|
| 牧场数据集                                                                           | 模型                | 提示模板 | Precision | Recall  | F1      | AUC     | MCC     | ACC     |
| 黄海大黄鱼                                                                           | GPT-3.5-turbo-16k | 模板 1 | 0.750 0   | 0.321 4 | 0.450 0 | 0.639 9 | 0.386 5 | 0.780 0 |
|                                                                                 |                   | 模板 2 | 0.857 1   | 0.642 9 | 0.734 7 | 0.800 6 | 0.662 7 | 0.870 0 |
|                                                                                 |                   | 模板 3 | 0.826 1   | 0.678 6 | 0.745 1 | 0.811 5 | 0.664 7 | 0.870 0 |
|                                                                                 | GPT-4             | 模板 1 | 1.000 0   | 0.758 6 | 0.862 7 | 0.879 3 | 0.833 9 | 0.934 0 |
|                                                                                 |                   | 模板 2 | 0.862 1   | 0.862 1 | 0.862 1 | 0.905 1 | 0.810 1 | 0.924 5 |
|                                                                                 |                   | 模板 3 | 0.925 9   | 0.862 1 | 0.892 9 | 0.918 0 | 0.855 5 | 0.943 4 |
| 南海金鲷鱼                                                                           | GPT-3.5-turbo-16k | 模板 1 | 1.000 0   | 0.333 3 | 0.500 0 | 0.666 7 | 0.504 9 | 0.789 5 |
|                                                                                 |                   | 模板 2 | 0.800 0   | 0.333 3 | 0.470 6 | 0.647 4 | 0.405 5 | 0.763 2 |
|                                                                                 |                   | 模板 3 | 0.888 9   | 0.666 7 | 0.761 9 | 0.814 1 | 0.686 8 | 0.868 4 |
|                                                                                 | GPT-4             | 模板 1 | 0.916 7   | 0.916 7 | 0.916 7 | 0.939 1 | 0.878 2 | 0.947 4 |
|                                                                                 |                   | 模板 2 | 0.923 1   | 1.000 0 | 0.960 0 | 0.980 8 | 0.942 1 | 0.973 7 |
|                                                                                 |                   | 模板 3 | 0.923 1   | 1.000 0 | 0.960 0 | 0.973 7 | 0.980 8 | 0.942 1 |
| 渤海石斑鱼                                                                           | GPT-3.5-turbo-16k | 模板 1 | 0.666 7   | 0.083 3 | 0.148 1 | 0.520 8 | 0.086 1 | 0.520 8 |
|                                                                                 |                   | 模板 2 | 0.947 4   | 0.250 0 | 0.395 6 | 0.618 1 | 0.348 8 | 0.618 1 |
|                                                                                 |                   | 模板 3 | 0.814 8   | 0.611 1 | 0.698 4 | 0.736 1 | 0.487 7 | 0.736 1 |
|                                                                                 | GPT-4             | 模板 1 | 0.971 8   | 0.958 3 | 0.965 0 | 0.965 3 | 0.930 6 | 0.965 3 |
|                                                                                 |                   | 模板 2 | 0.923 1   | 1.000 0 | 0.960 0 | 0.980 8 | 0.942 1 | 0.973 7 |
|                                                                                 |                   | 模板 3 | 1.000 0   | 0.958 3 | 0.978 7 | 0.979 2 | 0.959 2 | 0.979 2 |

3.6.2 RQ2:样本增强对 PAP-SEA 性能的提升效果

**实验设计:**RQ3 基于 RQ1 中筛选得到的最优提示模板(模板 3),采用推理成本更低的 GPT-3.5-turbo-16k 对正样本进行增强以验证大语言模型样本增强策略的有效性。图 3 展示了模型在增加了 20% 到 100% 的正样本后,模型在 F1 上的变化。

**实验分析:**如图 3 所示,随着训练样本的增加,模型的 F1 逐渐升高,但上升的幅度缓慢下降。这是

由于模型在生成正样本的同时也产生了部分噪声。表 3 进一步对比了有无样本增强的模型性能以及三种样本增强方法的性能。结果表明基于大语言模型的样本增强提升了模型在多个数据集上的整体性能。在黄海大黄鱼与渤海石斑鱼数据集上,引入增强样本后,PAP-SEA 在 F1、AUC、MCC 与 ACC 指标上均有明显提升。其中,基于大语言模型的样本增强在黄海大黄鱼数据集的性能提升效果最大,

$F1$ 从0.482 8提升至0.807 0,提升幅度达67.15%; $MCC$ 由0.218 2提升至0.736 3,提升幅度高达237.44%。结果表明,本文提出的样本增强方法有效改善了模型的判别能力。

进一步分析发现,样本增强对Recall的提升尤为明显。在南海金鲷鱼数据集上,引入增强样本后,Precision略有下降(由0.777 8降至0.769 2),但Recall从0.583 3提升至0.833 3,提升幅度达到42.86%,最终 $F1$ 提升17.43%。这一结果表明,样本增强使模型能够识别出更多有效分析样本,从而增强对正类样本的覆盖能力。在经济效益分析场景中,提高Recall有助于减少潜在有效样本的遗漏,具有更高的实际应用价值。

**RQ2 结论:**提示工程下的样本增强能有效提升PAP-SEA方法的性能。增强样本在保持语义一致




图3 不同训练样本比例下的模型在 $F1$ 上的性能变化

Fig. 3  $F1$  of the model under different training sample ratios

性的同时提高了样本多样性,有效缓解了海洋牧场经济效益分析样本稀缺的问题,为模型训练提供了更加充分的语义信息支撑。

表3 不同样本增强方法在PAP-SEA中的性能对比

Table 3 Performance comparison of different sample augmentation methods in PAP-SEA

| 海洋牧场数据集 | 样本增强              | Precision | Recall  | $F1$    | AUC     | MCC     | ACC     |
|---------|-------------------|-----------|---------|---------|---------|---------|---------|
| 黄海大黄鱼   | 无                 | 0.362 1   | 0.724 1 | 0.482 8 | 0.621 8 | 0.218 2 | 0.575 5 |
|         | 插值增强              | 0.548 7   | 0.630 7 | 0.585 8 | 0.701 6 | 0.384 5 | 0.684 2 |
|         | SMOTE             | 0.601 5   | 0.758 6 | 0.670 9 | 0.741 7 | 0.468 5 | 0.736 8 |
|         | GPT-3.5-turbo-16k | 0.821 4   | 0.793 1 | 0.807 0 | 0.864 1 | 0.736 3 | 0.896 2 |
| 南海金鲷鱼   | 无                 | 0.777 8   | 0.583 3 | 0.666 7 | 0.753 2 | 0.553 7 | 0.815 8 |
|         | 插值增强              | 0.731 2   | 0.666 7 | 0.697 4 | 0.781 5 | 0.584 1 | 0.826 3 |
|         | SMOTE             | 0.742 6   | 0.708 3 | 0.725 0 | 0.804 6 | 0.621 7 | 0.842 1 |
|         | GPT-3.5-turbo-16k | 0.769 2   | 0.833 3 | 0.800 0 | 0.859 0 | 0.703 4 | 0.868 4 |
| 渤海石斑鱼   | 无                 | 0.717 4   | 0.916 7 | 0.804 9 | 0.777 8 | 0.578 3 | 0.777 8 |
|         | 插值增强              | 0.756 1   | 0.891 7 | 0.818 3 | 0.811 2 | 0.621 4 | 0.812 5 |
|         | SMOTE             | 0.791 6   | 0.908 3 | 0.845 9 | 0.842 6 | 0.681 5 | 0.846 1 |
|         | GPT-3.5-turbo-16k | 0.932 4   | 0.958 3 | 0.945 2 | 0.944 4 | 0.889 2 | 0.944 4 |

注:“无”表示仅使用原始样本微调RoBERTa,无样本增强;“GPT-3.5-turbo-16k”“SMOTE”以及“插值增强”表示在原始样本基础上融合对应方法生成的新样本对RoBERTa进行微调。

### 3.6.3 RQ3:PE-SEA与PAP-SEA对比基线方法的有效性

**实验设计:**针对RQ3,本文将PE-SEA、PAP-SEA与三类基线方法在测试集上进行对比,以验证本文方法在经济效益分析任务中的整体性能优势。

**实验分析:**由图4~图6可知,PE-SEA与PAP-SEA在所有数据集上的 $F1$ 、AUC、MCC与ACC均优于三种基线方法,表明本文方法在经济效益分析中的性能最优。尤其是在有效样本数量较少的南海金鲷鱼数据集上(图5),PE-SEA的 $F1$ 达到0.960 0,较表现最优的基线方法KnowledgeGraph-BERT提升了70.67%。黄海大黄鱼数据集上,PE-SEA与PAP-SEA

的Recall小于KnowledgeGraph-BERT,KnowledgeGraph-BERT中的链路传播通过知识图谱中节点和边,扩大了对潜在正类样本的识别范围。因此,KnowledgeGraph-BERT能够找回更多真实正类样本,表现出更高的Recall。然而,知识图谱也引入了一定噪声,导致部分负样本被错误识别为正样本,从而使Precision降低。综合来看,PE-SEA与PAP-SEA在 $F1$ 上均高于KnowledgeGraph-BERT,在误报和正样本预测上取得了更好的平衡。

**PE-SEA与PAP-SEA的性能差异:**在所有数据集上,PE-SEA的性能均优于PAP-SEA。这是因为PE-SEA基于GPT-4实现,其语义推理能力远强于PAP-SEA使用的RoBERTa模型;同时PE-




图 4 不同方法在黄海大黄鱼数据集上的性能对比

Fig. 4 Performance comparison of different methods on the Yellow Sea Large Yellow Croaker Dataset




图 5 不同方法在南海金鲷鱼数据集上的性能对比

Fig. 5 Performance comparison of different methods on the South China Sea Golden Pomfret Dataset




图 6 不同方法在渤海石斑鱼数据上的性能对比

Fig. 6 Performance comparison of different methods on the Bohai Sea Grouper Dataset

SEA 为零样本分析,无需依赖训练数据,能够更好地适应不同海域、不同养殖品种的海洋牧场场景。从数据安全角度分析,PE-SEA 依赖闭源的 GPT-4 模型,需通过 API 接口调用并上传相关产业数据,存在潜在的数据隐私与安全风险;而 PAP-SEA 仅

在训练阶段使用 ChatGPT 进行样本生成,模型训练与推理均在本地完成,有效降低了数据外部传输带来的风险。因此,在对数据隐私要求较高的产业应用场景中,PAP-SEA 具有更好的安全性与可控性。

**RQ3 结论:**综合实验结果与应用场景分析可得,PE-SEA 与 PAP-SEA 均为有效的海洋牧场经济效益分析方法,整体性能均优于当前主流基线方法。在性能优先的场景下,推荐采用 PE-SEA;在数据安全与隐私保护要求较高的场景下,推荐 PAP-SEA 方法。

4 效度威胁

尽管本文在三个真实海域数据集上系统验证了 PE-SEA 与 PAP-SEA 方法的有效性,但仍然存在若干潜在效度威胁,具体分析如下。

1) 内部效度威胁 (Internal Validity)。PE-SEA 方法依赖大语言模型的语义推理能力,而模型为闭源,其训练过程的语料不可控。因此,本文无法排除预训练语料中存在相似的海洋牧场经济效益相关文本从而对实验结果产生的偏差。在 PAP-SEA 方法中,增强样本由 ChatGPT 生成。虽然本文通过一对一增强策略控制类别分布,但生成样本可能在语义空间中与原始样本存在一定相似性,从而带来潜在的过拟合风险,未来将进一步提升生成样本的质量。此外,PE-SEA 方法的经济效益分析和 PAP-SEA 方法中增强样本的质量依赖提示模板设计,其设计内容的主观性可能影响样本分布。为缓解上述威胁,本文采用固定的训练、验证以及测试集划分比例,并比较了不同提示模板在经济效益分析效果,以减少实验偏差。

2) 结构效度威胁 (Construct Validity)。本文将海洋牧场经济效益分析建模为“正/负样本”二分类问题。该问题建模方式虽符合现有研究范式,但经济效益本质上是多维连续指标,二分类标签可能无法完全刻画其复杂性。其次,本文的正样本由领域专家标注,负样本基于时间窗口规则生成。虽然样本的构建方式贴合产业实际,但仍可能存在标注偏差或规则假设偏差,从而影响模型学习的判别边界。

3) 外部效度威胁 (External Validity)。虽然来源于南海、黄海与渤海三个海域的数据具有一定代表性,但不同国家或不同生态环境下的海洋牧场生产模式可能存在差异,因此模型在其他区域或不同养殖结构下的泛化能力仍需进一步验证。

4) 结论效度威胁 (Conclusion Validity)。不同

评价指标关注模型不同性能,指标的选择可能会对模型优劣的判断,从而产生不同的结论。为降低该威胁,本文采用 Precision、Recall、F1、AUC、MCC、ACC 指标从不同方面对模型进行综合评估。此外,本文使用的大语言模型生成的内容具有随机性。尽管本文采用固定参数进行实验,但仍可能存在轻微性能波动。

## 5 结 语

海洋牧场经济效益智能化分析在保障生产养殖精细化和科学性上具有重要的作用。现有的方法主要使用数据驱动的方法进行经济效益分析,这些方法需要大量的数据集进行训练,并不适用于小样本场景。因此,本文提出了两种提示工程下的海洋牧场经济效益智能化分析方法:零样本提示分析框架 PE-SEA 与提示增强预训练框架 PAP-SEA。实验结果表明,所提出方法在三个真实海域数据集上均优于最优的基线方法 KnowledgeGraph-BERT。验证了基于大语言模型和提示工程的样本增强方法在小样本场景下的有效性。因此,提示工程不仅能够引导大语言模型实现零样本下的经济效益智能化分析,还能够作为样本增强方法提升下游模型在经济效益分析方面的性能。

综上,本文提出的方法为数据稀缺条件下的海洋牧场经济效益分析提供了一种可扩展且有效的解决方案。未来工作将进一步围绕领域专用大语言模型构建和多模态数据融合展开,以进一步提升模型稳健性与产业适用性。

## 参考文献:

- [1] 吴迪,任重进,韩荣贵,等.海上风电与海洋牧场融合发展现状与实践探索[J].中国渔业经济,2023,41(3): 78-84. DOI:10.3969/j.issn.1009-590X.2023.03.010.  
WU D, REN Z J, HAN R G, et al. Exploration and practice of offshore wind power and marine ranching integration development technology [J]. *Chinese Fisheries Economics*, 2023, 41(3): 78-84. DOI:10.3969/j.issn.1009-590X.2023.03.010 (Ch).
- [2] 李耀华,尹静,林海.人工智能与海洋经济如何“双向赋能”?[J].中国电信业,2025(11): 14-17. DOI:10.3969/j.issn.1671-3060.2025.11.006.  
LI Y H, YIN J, LIN H. How does artificial intelligence and marine economy “empower each other”? [J]. *China Telecommunication Trade*, 2025 (11): 14-17. DOI: 10.3969/j.issn.1671-3060.2025.11.006 (Ch).
- [3] KÜHN B, CAYETANO A, FINCHAM J I, et al. Machine learning applications for fisheries—At scales from genomics to ecosystems[J]. *Reviews in Fisheries Science & Aquaculture*, 2025, 33 (2): 334-357. DOI: 10.1080/23308249.2024.2423189.
- [4] SAVILLE R, FUJIWARA A, HATANAKA K, et al. AI-powered decision support system for mariculture: Real-time fish mortality prediction with random forest[J]. *Aquacultural Engineering*, 2026, 112: 102621. DOI:10.1016/j.aquaeng.2025.102621.
- [5] GHAEMI S, GHOLMOHAMADI H, ANVARI-MOGHADDAM A, et al. Optimizing power consumption in aquaculture cooling systems: A Bayesian optimization and XGBoost approach under limited data[J]. *Applied Sciences*, 2025, 15(11): 6273. DOI:10.3390/app15116273.
- [6] JONGJARAUNSU R, TAPARHUDEE W, MATONDANG P. An ensemble learning technique for predicting mortality rate in red tilapia (*Oreochromis Niloticus* Linn.) fingerlings[J]. *Journal of Fisheries and Environment*, 2024, 48(1): 37-50. DOI: 10.3390/app15116273.
- [7] WU A Q, LI K L, SONG Z Y, et al. Deep learning for sustainable aquaculture: Opportunities and challenges[J]. *Sustainability*, 2025, 17(11): 5084. DOI:10.3390/su17115084.
- [8] YANG X T, ZHANG S, LIU J T, et al. Deep learning for smart fish farming: Applications, opportunities and challenges[J]. *Reviews in Aquaculture*, 2021, 13(1): 66-90. DOI:10.1111/raq.12464.
- [9] ZHANG M Q. Marine fishery resource dynamic prediction based on CNN-XGBoost fusion model[J]. *Scientific Reports*, 2026, 16: 3244. DOI:10.1038/s41598-025-33175-4.
- [10] LIU S T, DU Z Z, WANG G X, et al. From traditional machine learning models to multimodal large models: A review of aquaculture[J]. *Reviews in Aquaculture*, 2026, 18(1): e70111. DOI:10.1111/raq.70111.
- [11] 钟欣,陈亮,刘文璇,等.时空语义驱动的渐进多视角行为去偏置研究[J].计算机工程,2025,51(1): 1-10. DOI:10.19678/j.issn.1000-3428.0069307.  
ZHONG X, CHEN L, LIU W X, et al. Research on temporal-spatial semantic-driven progressive multiview action debiasing [J]. *Computer Engineering*, 2025, 51(1): 1-10. DOI:10.19678/j.issn.1000-3428.0069307 (Ch).
- [12] BROWN T B, MANN B, RYDER N, et al. Language models are few-shot learners [DB/OL]. [2025-12-12]. [https://proceedings.neurips.cc/paper\\_files/paper/2020/file/1457c0d6bfc4967418bfb8ac142f64a-Paper.pdf](https://proceedings.neurips.cc/paper_files/paper/2020/file/1457c0d6bfc4967418bfb8ac142f64a-Paper.pdf).
- [13] MIN B N, ROSS H, SULEM E, et al. Recent advances in natural language processing via large pre-trained language models: A survey[J]. *ACM Computing Surveys*, 2023, 56(2): 1-40. DOI:10.1145/3605943.
- [14] DAI H X, LIU Z L, LIAO W X, et al. AugGPT: Leveraging ChatGPT for text data augmentation[EB/OL]. 2023: arXiv:

- 2302.13007. <https://arxiv.org/abs/2302.13007>.
- [15] ZHAO Z H, WANG S, GU J C, *et al.* Chatcad+: Toward a universal and reliable interactive CAD using LLMs [J]. *IEEE Transactions on Medical Imaging*, 2024, **43** (11): 3755–3766. DOI: 10.1109/TMI.2024.33983500.
- [16] LIU Y H, OTT M, GOYAL N, *et al.* RoBERTa: A robustly optimized BERT pretraining approach [EB/OL]. 2019: arXiv: 1907.11692. <https://arxiv.org/abs/1907.11692>.
- [17] REZAYI S, DAI H X, LIU Z L, *et al.* ClinicalRadioBERT: Knowledge-infused few shot learning for clinical notes named entity recognition [C]//Machine Learning in Medical Imaging. Cham: Springer, 2022: 269–278. DOI: 10.1007/978-3-031-21014-3\_28.
- [18] LEE U, JUNG H, JEON Y, *et al.* Few-shot is enough: Exploring ChatGPT prompt engineering method for automatic question generation in English education [J]. *Education and Information Technologies*, 2024, **29**(9): 11483–11515. DOI: 10.1007/s10639-023-12249-8.
- [19] EKIN S. Prompt engineering for ChatGPT: A quick guide to techniques, tips, and best practices [J]. *ASEE Journal of Engineering Technology*, 2026, **43**(1): 52–68. DOI: 10.18260/jet.43.1.5.
- [20] HAN X, ZHAO W L, DING N, *et al.* PTR: Prompt tuning with rules for text classification [J]. *AI Open*, 2022, **3**: 182–192. DOI: 10.1016/j.aiopen.2022.11.003.
- [21] HAO D Q, XU B Z, LENG J, *et al.* Elucidating the drivers of aquaculture eutrophication: A knowledge graph framework powered by domain-specific BERT [J]. *Sustainability*, 2025, **17**(19): 8907. DOI: 10.3390/su17198907.
- [22] 徐贺. 基于深度学习的海洋牧场水质预测模型及监测系统研究 [D]. 济南: 齐鲁工业大学, 2024.
- XU H. Research on marine ranch water quality prediction model and monitoring system based on deep learning [D]. Jinan: Qilu University of Technology, 2024 (Ch).
- [23] KIM Y H, CHO S, LEE P S. Wave height classification via deep learning using monoscopic ocean videos [J]. *Ocean Engineering*, 2023, **288**: 116002. DOI: 10.1016/j.oceaneng.2023.116002.
- [24] SCHULHOFF S, ILIE M, BALEPUR N, *et al.* The prompt report: A systematic survey of prompt engineering techniques [EB/OL]. 2024: arXiv: 2406.06608. <https://arxiv.org/abs/2406.06608>.
- [25] HU E, SHEN Y L, WALLIS P, *et al.* LoRA: Low-Rank adaptation of Large Language Models [DB/OL]. [2025-12-12]. <https://arxiv.org/pdf/2106.09685v1/1000>.
- [26] 车万翔, 窦志成, 冯岩松, 等. 大模型时代的自然语言处理: 挑战、机遇与发展 [J]. *中国科学(信息科学)*, 2023, **53**(9): 1645–1687. DOI: 10.1360/SSI-2023-0113.
- CHE W X, DOU Z C, FENG Y S, *et al.* Towards a comprehensive understanding of the impact of large language models on natural language processing: Challenges, opportunities and future directions [J]. *Science in China (Information Sciences)*, 2023, **53**(9): 1645–1687. DOI: 10.1360/SSI-2023-0113 (Ch).
- [27] VALIZADEHASLANI T, SHI Y W, WANG J, *et al.* Two-stage fine-tuning with ChatGPT data augmentation for learning class-imbalanced data [J]. *Neurocomputing*, 2024, **592**: 127801. DOI: 10.1016/j.neucom.2024.127801.
- [28] YIN X Y, GOUDRIAAN J, LANTINGA E A, *et al.* A flexible sigmoid function of determinate growth [J]. *Annals of Botany*, 2003, **91**(3): 361–371. DOI: 10.1093/aob/mcg029.
- [29] 杨莲, 石宝峰. 基于 Focal Loss 修正交叉熵损失函数的信用风险评价模型及实证 [J]. *中国管理科学*, 2022, **30**(5): 65–75. DOI: 10.16381/j.cnki.issn1003-207x.2020.2188.
- YANG L, SHI B F. Credit risk evaluation model and empirical research based on focal loss modified cross-entropy loss function [J]. *Chinese Journal of Management Science*, 2022, **30**(5): 65–75. DOI: 10.16381/j.cnki.issn1003-207x.2020.2188 (Ch).
- [30] AUGER T, SAROYAN E. Overview of the OpenAI APIs [M]//Generative AI for Web Development. Berkeley, CA: Apress, 2024: 87–116. [https://doi.org/10.1007/979-8-8688-0885-2\\_6](https://doi.org/10.1007/979-8-8688-0885-2_6).
- [31] JAIN S M. Hugging face [M]//Introduction to Transformers for NLP. Berkeley, CA: Apress, 2022: 51–67. [https://doi.org/10.1007/978-1-4842-8844-3\\_4](https://doi.org/10.1007/978-1-4842-8844-3_4).
- [32] 姚世伟, 杨盛腾, 李裕梅. 基于混淆矩阵的机器学习分类评价指标研究及 Python 实践 [J]. *数据挖掘*, 2022, **12**(4): 351–367. DOI: 10.12677/HJDM.2022.124033.
- YAO S Y, YANG S T, LI Y M. Research on performance measure indicators of machine learning classification based on confusion matrix and corresponding Python practice [J]. *Hans Journal of Data Mining*, 2022, **12**(4): 351–367. DOI: 10.12677/HJDM.2022.124033 (Ch).
- [33] CHAWLA N V, BOWYER K W, HALL L O, *et al.* SMOTE: Synthetic minority over-sampling technique [J]. *Journal of Artificial Intelligence Research*, 2002, **16**: 321–357. DOI: 10.1613/jair.953.
- [34] ZHANG H Y, CISSE M, DAUPHIN Y N, *et al.* Mixup: Beyond empirical risk minimization [EB/OL]. 2017: arXiv: 1710.09412. <https://arxiv.org/abs/1710.09412>.
- [35] PEDREGOSA F, VAROQUAUX G, GRAMFORT A, *et al.* Scikit-learn: Machine learning in Python [J]. *Journal of Machine Learning Research*, 2011, **12**: 2825–2830. DOI: 10.5555/1953048.2078195.

□