

# MeterReader++: 基于视觉语言大模型的指针表计识读框架及应用

王昌鹏<sup>1</sup>, 闫云凤<sup>1,2</sup>, 齐冬莲<sup>1,2</sup>, 沈潇军<sup>3</sup>, 储海东<sup>4</sup>

(1. 浙江大学电气工程学院, 杭州 310027; 2. 浙江大学海南研究院, 三亚 572025;

3. 国网浙江省电力有限公司信息通信分公司, 杭州 310027; 4. 国家电网有限公司, 北京 100031)

**摘要:** 指针式表计识读是工业数智化的关键任务, 当前主要依赖目标检测、关键点定位等传统识别算法, 存在低泛化性、强数据依赖等瓶颈。该文通过视觉语言大模型模拟人类知识读过程, 提出一种通用的指针表计识读框架: 1) 为突破数据依赖瓶颈, 构建工业场景下的识读多模态数据合成管道, 可自动生成 20 000 条以上问答对; 2) 为克服大模型“幻觉”瓶颈, 使用 DeepSeek-R1 模拟人类知识读, 解耦表计语义理解和识读推理过程, 平均参考误差比基础模型 Qwen2.5-VL 降低 10%; 3) 为提升泛化性, 设计基于广义策略优化的容差自适应强化学习优化方法, 将绝对精度约束转化为可学习容忍区间以增强分布外数据(out-of-distribution data, OOD)泛化, 在 OOD 测试中, 该文方法识读误差降到 2%。实验表明, 该文所提框架在模拟工业表计测试集的平均参考误差为 1.2%, 在公开真实表计测试集达到 3.16%, 超越 Qwen2.5-VL-72B 和 GPT4o 等先进大模型。该文研究为视觉语言大模型在精细化视觉理解和推理计算任务的落地应用, 提供了思路参考。

**关键词:** 指针式表计识读; 视觉语言模型; 深度学习; 强化学习; 课程学习

## MeterReader++: Pointer Meter Reading Framework and Applications Based on Visual Language Large Model

WANG Changpeng<sup>1</sup>, YAN Yunfeng<sup>1,2</sup>, QI Donglian<sup>1,2</sup>, SHEN Xiaojun<sup>3</sup>, CHU Haidong<sup>4</sup>

(1. College of Electrical Engineering, Zhejiang University, Hangzhou 310027, China; 2. Hainan Institute of Zhejiang University, Sanya 572025, China; 3. Information and Communication Branch, State Grid Zhejiang Electric Power Company Limited, Hangzhou 310027, China; 4. State Grid Corporation of China, Beijing 100031, China)

**Abstract:** Pointer-type meter reading is a key task in industrial digitalization. Currently, pointer-type meter reading mainly relies on traditional recognition algorithms such as target detection and key point positioning, which have bottlenecks such as low generalization and strong data dependence. This paper simulates the human knowledge reading process through a large visual language model and proposes a general pointer meter reading framework: (1) In order to break through the bottleneck of data dependence, a multimodal data synthesis pipeline for reading in industrial scenarios is constructed, which can automatically generate more than 20,000 question-answer pairs; (2) In order to overcome the bottleneck of “hallucination” of large models, DeepSeek-R1 is used to simulate human knowledge reading, decouple meter semantic understanding and reading reasoning processes, and the average reference error is reduced by 10% compared with the basic model Qwen2.5-VL; (3) In order to improve generalization, a tolerance adaptive reinforcement learning optimization method based on generalized strategy optimization is designed to convert absolute accuracy constraints into learnable tolerance intervals to enhance out-of-distribution data (OOD) generalization. In the OOD test, the reading error of this method is reduced to 2%. Experiments show that the average reference error of the proposed framework in this paper is 1.2% in the simulated industrial meter test set and 3.16% in the public real meter test set, outperforming the advanced large models such as Qwen2.5-VL-72B and GPT4o. The result of this paper provides a reference for the application of visual language large models in refined visual understanding and reasoning computing tasks.

**Key words:** pointer meter reading; visual language model; deep learning; reinforcement learning; curriculum learning

## 0 引言

表计识读作为工业现场监测与控制系统的关 键感知环节,直接关系到生产安全决策的可靠性。 基于视觉<sup>[1-2]</sup>的识读方式具有非接触、高精度和可集 成部署等优势,逐渐成为智能制造体系中不可或缺 的感知单元<sup>[3]</sup>。

指针式表计最为常见,例如压力表、温度计、 电压表及液位计等,由于具备安装方便、结构简单、 易于维护等特性,被广泛应用于石油化工、电力系 统、机械制造及能源监测等工业场景的实时监测<sup>[4-6]</sup> 与控制环节。国内外学者针对表计的自动识读开展 了广泛研究。例如,Howells 等人<sup>[7]</sup>提出将识读任务 分解为表计检测、矫正变换与关键点定位 3 个子任 务,但实际应用中受识读环境影响每个模块的误差 较大;Leon-Alcázar 等人<sup>[8]</sup>采用直接角度预测策略 却面临泛化性不足的局限;Reitsma 等人<sup>[9]</sup>构建的六 阶段通用框架虽适用性广却因复杂度高导致误差叠 加明显;Shu 等人<sup>[10]</sup>虽然简化了处理流程但受限于 表计部分内容理解能力;Zhang 等人<sup>[11]</sup>创新性引入 大语言模型来增强表计内容解析,显著提升了系统 的语义理解与场景适应能力。传统表计识读方法主 要包括指针分割、光学字符识别(OCR)、椭圆拟合 和关键点等模块<sup>[12-13]</sup>,由于各模块相互独立,无法 利用相邻数字和周围视觉语义关系,并造成严重的 误差累计<sup>[14]</sup>。

综上,基于视觉的表计识读方法,面临 3 个挑 战:1)数据稀缺困境<sup>[15]</sup>,现实世界仪器数据的高 注释成本和对各种测量场景的有限覆盖严重限制了 模型的泛化;2)视觉感知与计算推理间的认知脱节, 现有方法通常直接从整体图像中回归指针角度<sup>[7]</sup>, 忽略了人类认知固有的分层“定位→语义解耦→推 理”过程;3)连续回归任务中的奖励稀疏性问题<sup>[16]</sup>, 由于缺乏用于增量角度预测的密集奖励信号,传统 强化学习框架难以提供有效的策略指导。

针对上述挑战,本文提出了一个基于人类视觉 认知对齐的通用表计识读框架。

1)构建高度仿真工业场景下的多模态识读数 据合成管道和基于 DeepSeek<sup>[17]</sup>蒸馏的识读推理轨 迹。可一次性生成 20 000 张以上具有可编程参数的 工业级仪器图像(52 个表计类型,精度±0.5%)。解 决了目前真实工业表计数据稀少且标注识读过程 的高成本问题。

2)受人类视觉认知启发的多粒度提示架构。 与传统的端到端回归范式不同,本文将识读过程分 解为 3 个通用的表计识读阶段:区域定位、表盘语 义解耦和计算推理。这种分层架构在潜在空间中建 立了视觉特征和测量语义之间的拓扑映射,有效地 缓解了现有方法的认知脱节,解决了通用视觉语言 模型在表计识读中的幻觉问题。

3)构建容差自适应强化学习<sup>[18]</sup>后训练。实现 具有自适应识读容差间隔的广义奖励策略优化 (GRPO)<sup>[19]</sup>,通过动态误差界限调整将稀疏精度约束 转换为密集奖励信号,解决了表计识读强化学习过 程中奖励稀疏性问题。

## 1 基于视觉语言大模型的表计识读框架

### 1.1 问题定义

给定工业场景下的指针式表计图像  $I \in \mathbf{R}^{H \times W \times 3}$ , 其识读任务可建模为从图像空间到标量识读  $v \in \mathbf{R}$  的端到端映射函数  $v=F(I)$ ,需满足以下约束:

1)隐式物理约束,设表计类型  $T$  的刻度函数 为  $S_T(\theta)$ :

$$S_T(\theta) = \frac{S_{\max} - S_{\min}}{\theta_{\max} - \theta_{\min}}(\theta - \theta_{\min}) + S_{\min} \quad (1)$$

式中:  $\theta \in [\theta_{\min}, \theta_{\max}]$  为指针角度;  $[S_{\min}, S_{\max}]$  为量程 范围。模型需隐式学习映射  $F(I) = S_T(\theta)$ ,且无需显 式输入  $\theta_{\min}$ 、 $\theta_{\max}$ 、 $S_{\min}$ 、 $S_{\max}$  等先验知识。

2)抗干扰约束,对含噪声干扰的图像  $\tilde{I} = I + \epsilon_x$ (如 光照变化  $\epsilon_{\text{light}}$ 、遮挡  $\epsilon_{\text{occlusion}}$ ),需满足识读误差边界:

$$|F(\tilde{I}) - F(I)| \leq \delta_{\text{tol}} \cdot (S_{\max} - S_{\min}) \quad (2)$$

式中:  $\delta_{\text{tol}} \in [0, 1]$  为可学习的容差因子。

对于视觉语言大模型<sup>[20]</sup>而言,定义人类视觉认 知过程为多步推理链  $C_{\text{human}}$ ,模型需通过隐式对齐 策略  $\mathcal{A}$  最小化认知偏差:

$$\mathcal{A} = \arg \min_{\phi} E_{(I,v) \sim P} (\mathcal{L}_{\text{CE}}(\mathcal{F}_{\phi}(I), v) + \lambda D_{\text{KL}}(p_{\phi}(C|I) \| p_{\text{human}}(C|I))) \quad (3)$$

式中:  $\mathcal{L}_{\text{CE}}$  为识读误差损失;  $\phi$  为模型参数;  $E_{(I,v) \sim P}$  表示对数据分布  $P$  下的样本  $I$ 、 $v$  进行数学期望;  $\lambda$  为超参数;  $D_{\text{KL}}$  为 Kullback-Leibler 散度,衡量模型 推理的条件概率分布  $p_{\phi}$  与人类认知分布  $p_{\text{human}}$  之间 的差异;  $p_{\phi}(C|I)$  表示基于输入图像  $I$  由模型参数  $\phi$  生成的推理逻辑  $C$  的概率分布;  $p_{\text{human}}(C|I)$  表示基于 输入图像  $I$  的人类认知逻辑分布。

该形式化定义将工业表计识读任务转化为带

隐式物理约束的抗干扰认知对齐优化问题, 要求模型在无需显式标注关键点与刻度信息条件下, 直接实现鲁棒端到端映射。

### 1.2 视觉语言模型架构

本文以 Qwen2.5-VL-7B<sup>[21]</sup>作为视觉语言基座模型, 如图 1 所示, 其架构主要包括 3 个部分: 视觉编码器、语言模型解码器和视觉语言融合器。视觉编码器采用改进的 Vision Transformer(ViT)架构和 2D-RoPE 技术, 可有效捕捉图像中的空间关系和细节特征。语言模型解码器基于 Qwen2.5 LLM, 具备强大的语言理解和生成能力。视觉语言融合器则通过多层感知机(MLP)将视觉特征与语言特征进行融合, 实现跨模态的理解和推理。

目前, 通用的视觉语言模型在视觉问答任务中表现优秀, 但在表计识读等需要细粒度视觉理解和推理计算的任务中表现一般, 其主要原因是: 视觉感知与计算推理之间的认知脱节, 导致模型无法完全理解表盘内容并且难以逻辑推理计算识读, 最终导致严重的识读“幻觉”。因此, 本文提出了一种基于人类视觉认知对齐的通用表计识读框架(如图 2 所示)。在训练阶段, 利用课程学习<sup>[22]</sup>框架和容差自适应强化学习框架逐步提高模型对表计理解和通用识读的能力。在推理阶段, 使用多粒度提示方法进一步提高推理识读精度, 弥补表计识读中的认知脱节并减少识读幻觉。

### 1.3 基于人类视觉认知机理的多粒度提示技术

基于 1.2 节提出的表计识读框架, 为进一步抑

制视觉语言模型的识读“幻觉”并提高识读精准度, 本文继而提出一种基于人类视觉认知推理的多粒度提示方法, 模拟人类的表计识读过程, 通过设计提示词, 将识读过程分解为区域定位、表盘语义解耦和计算推理 3 个阶段, 具体描述如下所述。

1) 区域定位阶段。模拟人类在观察表计时的初步扫视, 模型首先识别出表计的大致位置和范围, 利用视觉编码器提取图像的全局特征, 并通过注意力机制聚焦于可能包含表计的区域。这一阶段的提示设计旨在引导模型关注图像中的关键区域, 减少后续处理的计算量。

2) 表盘语义解耦阶段。模拟人类在表计识读时对表盘细节的仔细观察和理解, 模型识别出表盘上的刻度、数字、指针等元素, 并理解它们的语义关系。通过视觉语言融合器将视觉特征与语言知识相结合, 对表盘上的各个元素进行分类和解析, 为计算推理阶段提供有力证据, 减少了计算推理幻觉。

3) 计算推理阶段。模拟了人类在表计识读时的思考和推理过程, 模型根据表盘语义解耦的结果, 利用语言模型解码器的推理, 得出最终的识读结果。

通过 3 个阶段的分层处理, 多粒度提示工程有效模拟了人类的视觉认知过程(如图 3 示例), 不仅增强模型对复杂表计场景的理解, 减少了细粒度识读任务中的幻觉, 使得模型识读过程更可靠。

### 1.4 基于 DeepSeek-R1 的“渐进式课程学习”策略

在表计识读任务中, 传统预训练的视觉感知与语言模型之间存在认知脱节, 因此, 本文基于



图 1 Qwen2.5-VL<sup>[19]</sup>框架中的视觉编码器与语言模型解码器

Fig.1 Visual encoder and language model decoder in the Qwen2.5-VL<sup>[19]</sup> framework decoder

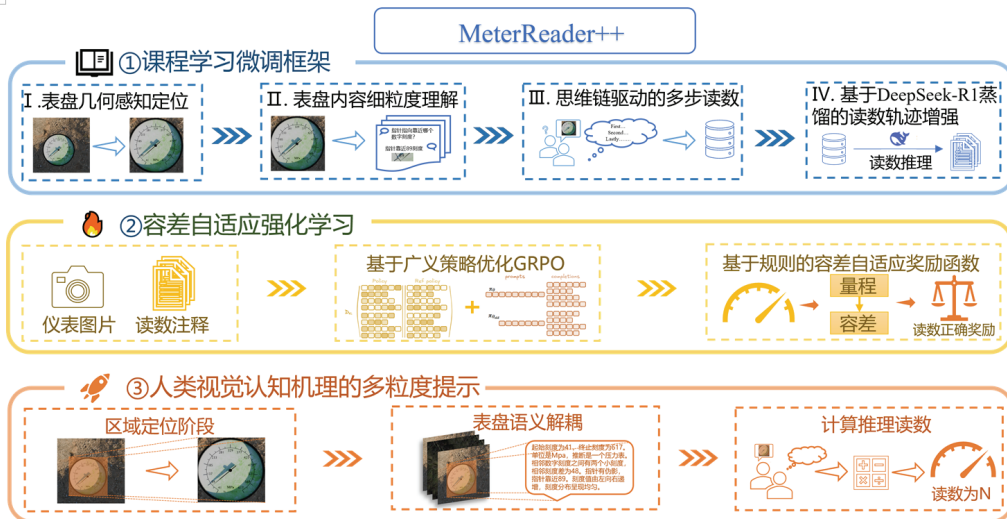


图2 基于人类视觉认知对齐的通用表计识读架构图

Fig.2 The general meter reading architecture diagram based on human visual cognition alignment

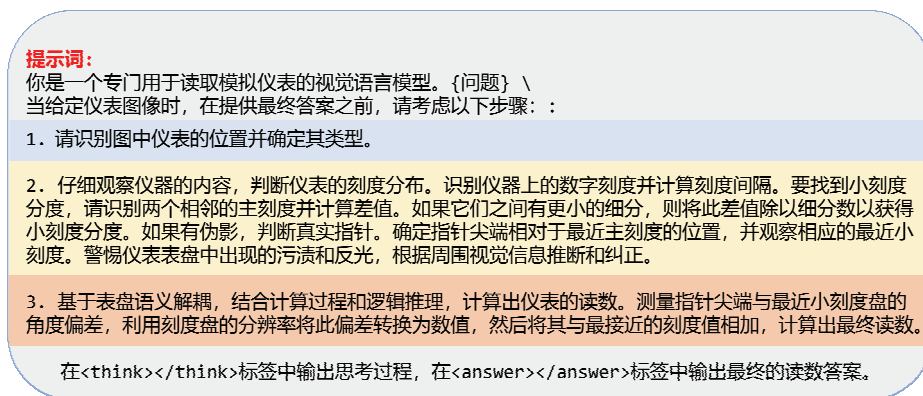


图3 基于人类视觉认知的多粒度提示工程示意图

Fig.3 Schematic diagram of multi-granularity prompt engineering based on human visual cognition

DeepSeek-R1, 引入“渐进式课程学习”策略, 从简单的表盘定位任务逐步过渡到复杂的识读推理任务, 使得模型逐步建立从视觉感知到语言理解、再到逻辑推理的能力, 示例如图4所示。

1) 基于复杂背景的表盘几何感知定位。通过真实的工业表计检测数据集训练, 模型具备识别表计种类和检测表盘边界能力, 为后续的表盘内容细粒度理解奠定基础。

2) 表盘内容细粒度理解。为了使得模型深入理解刻度、数字、指针位置等表盘细粒度内容, 训练过程加入主次刻度关系, 指针与刻度关系等细节, 建立表计视觉特征与语义信息的关联。

3) 思维链驱动的多步识读(CoT-Tuning)<sup>[23]</sup>。如图4的第3步所示, 通过逐步构建思维链条, 引导模型学习从表盘的视觉信息中提取关键数据, 并进

行逻辑推理以得出识读结果。

4) 基于 DeepSeek-R1 蒸馏的识读轨迹增强。通过模板化的视觉观察结果作为输入, 利用 DeepSeek-R1 强大的推理能力进行逻辑增强, 进一步提升模型的识读推理能力。模型通过学习先进的推理策略和轨迹, 能够更准确地处理复杂的识读任务, 从而提高推理的准确性和泛化能力。

### 1.5 容差自适应的强化学习通用识读方法

针对传统强化学习方法在表计识读连续量回归中的奖励稀疏问题, 本文引入了基于广义策略优化(group relative policy optimization, GRPO)的容差自适应训练方法, 并设计了基于规则的容差自适应奖励函数, 通过引入最小误差容忍范围, 将绝对精度约束转化为可学习的容忍区间, 提升了模型对于不同表计的 OOD 泛化能力。

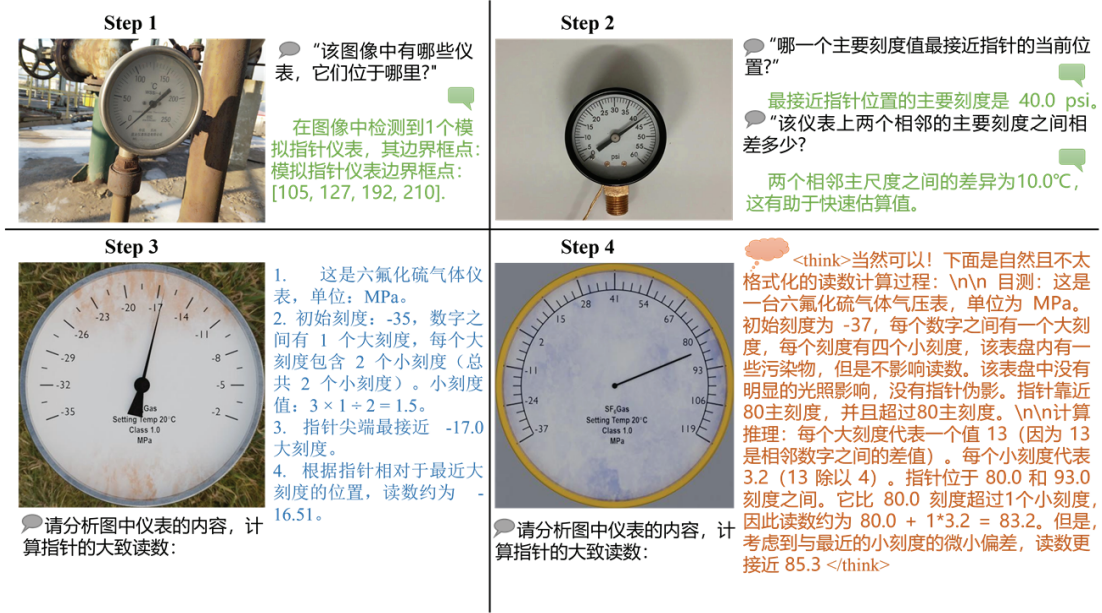


图 4 基于 DeepSeek-R1 的“渐进式课程学习”策略示意图

Fig.4 Schematic diagram of the “progressive curriculum learning” strategy based on DeepSeek-R1

GRPO 算法通过摒弃奖励模型，利用从旧策略生成的输出样本来进行奖励估算，其目标是通过最大化 1 组候选输出的优势来优化当前的策略。具体来说，本文引入了训练数据的最小误差容忍范围，根据表计的量程来自适应地调整误差范围，将绝对精度约束转化为可学习的容忍区间。只要识读在这个容忍区间内，模型就能获得正确性奖励。这种机制不仅缓解了奖励稀疏问题，还提高了模型在不同表计上的泛化能力，其优化目标函数如下：

$$J_{GRPO}(\theta) = E(q \sim P(Q), \{o_i\}_{i=1}^G \sim \pi_{\theta_{old}}(O|q))$$

$$\frac{1}{G} \sum_{i=1}^G \left( \min \left( \frac{\pi_{\theta}(o_i|q)}{\pi_{\theta_{old}}(o_i|q)}, A_i \cdot \text{clip} \left( \frac{\pi_{\theta}(o_i|q)}{\pi_{\theta_{old}}(o_i|q)}, 1-\epsilon, 1+\epsilon \right) \right) - \beta D_{KL}(\pi_{\theta} || \pi_{\theta_{old}}) \right) \quad (4)$$

式中： $q$  表示从数据集分布  $P(Q)$  采样环境状态， $\pi_{\theta_{old}}(o_i|q)$  表示旧策略采样的概率； $\pi_{\theta}(o_i|q)$  表示当前策略的概率； $G$  表示表示一组输出中包含的样本数； $\text{clip}(\cdot, 1-\epsilon, 1+\epsilon)$  表示裁剪函数； $\epsilon$  和  $\beta$  为超参数； $A_i$  为优势函数，使用  $G$  组奖励  $r_1, r_2, \dots, r_G$  计算组内归一化得到，对应于每组内的输出：

$$A_i = \frac{r_i - \text{mean}(\{r_1, r_2, \dots, r_G\})}{\text{std}(\{r_1, r_2, \dots, r_G\})} \quad (5)$$

式中： $r_i$  表示奖励函数对模型输出的奖励得分； $\text{mean}$  表示对  $G$  组奖励  $r_1, r_2, \dots, r_G$  计算平均值； $\text{std}$  表示  $G$  组奖励  $r_1, r_2, \dots, r_G$  计算方差。

传统基于规则的奖励函数通常要求模型的输出与真实答案一致，然而在表计识读任务中，不可

避免存在微小识读误差，因而传统的“唯一性”奖励会导致严重的奖励稀疏问题。因此，本文定义了一种自适应的奖励函数，根据表计量程自适应调整的误差容忍阈值，使得模型能获得更频繁的正向反馈，从而更有效地学习识读任务。

$$r(o) = \begin{cases} 1, & |o - o_{\text{true}}| \leq \sigma \\ 0, & \text{其他} \end{cases} \quad (6)$$

式中： $o$  为模型的输出识读； $o_{\text{true}}$  为真实识读； $\sigma$  为根据仪表量程自适应调整的误差容忍阈值。

### 1.6 基于问答对引导的推理轨迹生成方法

针对视觉语言大模型的识读“幻觉”问题，本文构建了自动生成表计识读问答对的方法，包括表计内容理解问答对和表计识读推理问答对的生成；而后，使用 DeepSeek-R1 来蒸馏格式化的识读推理过程，基于格式化的视觉描述和计算推理信息，生成详细的推理轨迹，极大抑制识读“幻觉”。

表计内容理解问答对：本文构建了 20 000 条表计理解问答对，其内容覆盖表盘结构识别、指针信息解析、表计功能与单位理解、关键区域定位。

1) 表盘结构识别。针对表计的整体布局，包括主刻度与副刻度的分布、数字标识的位置、起始与终止刻度等。例如，问题“该表计的主刻度与副刻度分别如何分布”。要求模型描述各类刻度的数量、间隔及相应的数值信息。

2) 指针信息解析。针对指针的角度、指向、偏移等细节提出问题，如“指针最接近哪个数字刻度？指针前一个小刻度的值是多少？”等，帮助模型将指针视觉特征与数值信息进行关联。

3) 表计功能与单位理解。聚焦于表计所表达的物理量及其单位，诸如温度、压力等。问题示例包括：“该表计显示的单位是什么？”“这种表计主要应用于哪些场景？”等，通过对表计功能和单位的提问，促进模型对表计背景知识的理解。

4) 关键区域定位。结合表计图像中的 YOLO 格式的表计种类和检测框等信息，设计问题让模型识别表计种类，并定位表计中重要区域。

表计识读推理问答对：模拟人类识读过程，本文设计了一种基于思维链的问答对生成方法，逐步引导模型展开推理，减少模型识读幻觉。具体步骤如下所述。

- 1) 表计基本描述。识别表计的种类和单位，如“这是一台温度表，单位为℃”。
- 2) 刻度划分与计算。从图像中提取初始刻度、主刻度和小刻度的信息，计算各刻度间的数值间隔。例如：“初始刻度为  $X$ ， $Y$  个大刻度之间，每个大刻度包含  $Z$  个小刻度，总计小刻度数为 {answer}，进而计算出每个小刻度的数值。”
- 3) 指针位置与识读估算。分析指针所处的位置，确定其相对于最近刻度的未知，预估与最近刻

度的偏移量，从而得出最终识读。例如“指针最接近第  $N$  个刻度，根据其在该区间内的位置，估算识读约为 {answer}”。

为进一步提高模型的推理能力和计算能力，本文使用 DeepSeek-R1 来蒸馏格式化的识读推理过程，基于格式化的视觉描述和计算推理信息，生成详细的推理轨迹，包括视觉观察、计算推理两部分。

1) 视觉观察。提供表计的基本信息，如表计类型、单位、初始刻度和刻度划分情况。例如：视觉观察：这是温度计，单位：℃。初始刻度：-25，数字之间有 1 个大刻度，每个大刻度包含 4 个小刻度(总共 4 个小刻度)。

2) 计算推理。利用视觉观察信息，推理和计算识读过程中的细节。给出刻度计算式和指针位置分析。例如：“计算推理：大刻度分度值等于相邻两数值  $4 \div 1 = 4$ ，小刻度分度值： $4 \div 4 = 1.0$ 。关注指针尖端所在的刻度范围：指针尖端指向的上一个大刻度值为 7.0，下一个大刻度值为 11.0。根据指针尖端相对于前一个主刻度的位置，中间有 2 个小间隔，识读约等于  $7.0 + 2 \times 1.0 +$  与最近小刻度的偏差 = 9.3”。具体案例如图 5 所示。

## 2 实验分析

为验证算法的有效性，并使得所提框架在变电站实际场景中更好的发挥作用，本文模拟了现场采

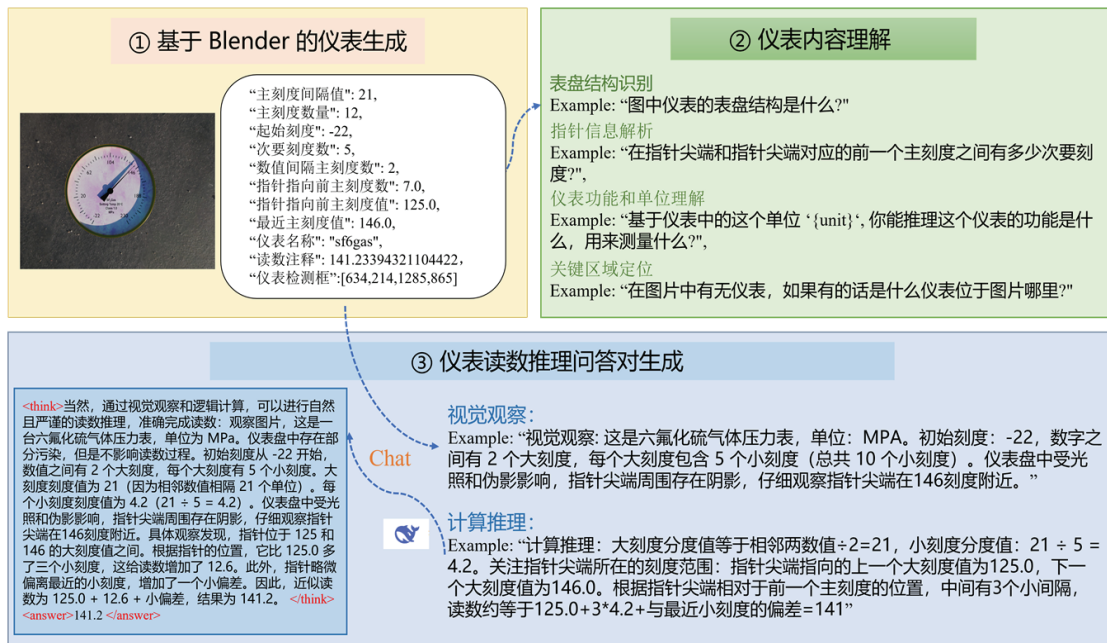


图 5 多模态表计识读数据生成流程

Fig.5 Multi-modal meter reading data generation pipeline

集的指针表计并生成高质量的指针表计读数推理数据集训练,并在域外数据集(OOD)上进行结果对比,从而分析所提的表计识读框架是否真正激发模型的通用识读推理能力。

## 2.1 数据集及评测指标

由于公开表计数据集数量较少,参考 Howells<sup>[7]</sup>和 Leon-Alcazar<sup>[8]</sup>等人,本文使用创作软件 Blender 生成 20 000 张、分辨率为 1 920×1 080 的表计图像,并模仿真实工业现场的光源、污秽、针影、玻璃反射等实景环境,提高对真实工业场景下仪表读数的鲁棒性。此外每一种表计都随机生成不同的刻度显示方式、指针角度和量程等信息,以增强对不同厂家仪表的适用性。

本文随机抽样了 20 000 张表计图片用于构造表计内容问答和识读推理问答数据。此外本文模拟复杂的工业场景条件,额外生成了 1 000 张不同的表计图片用于测试。实验阶段,分别在生成的工业表计数据集和真实的表计数据集上进行测试。对于真实表计数据集,由 Howells<sup>[7]</sup>等人提供的真实表计数据集和本文手动采集的工业表计数据集构成。其中 Howells 等人提供的数据集包括 6 种不同种类的表计视频,分辨率为 1 920×1 080。本文手动采集的数据集包括电力领域的一些表计,共约 100 张。这部分数据集分辨率涉及 16 种不同的表计类型,分辨率随机。此外本文手工为这些数据进行标注,包括识读和表计量程等。如图 6 所示,手工收集的数据集包含复杂的工业背景和表盘形态,比如背景中包含复杂电力设备或者表盘内的特殊设计。而训练集中的表计图像没有复杂的背景且表盘设计较为单一。由于手工收集的数据与训练数据集差异较大,

本文把这部分数据集作为域外分布(OOD)数据集。通过在 OOD 表计数据集上测试来探究模型的域外泛化能力和强化学习训练?是否激发了模型对不同表计识读的专业推理能力?

在测试实验中,本文设置了识读成功率、绝对识读误差、平均参考误差指标<sup>[24]</sup>来评价模型的结果。识读成功率  $R$ ,该指标评估模型是否能返回得到表计识读的结果(无关真实识读值)。对于模块化框架来说,即评估整个框架是否能返回结果并且中间模块没有发生崩溃,对于视觉语言模型来说,即评估是否可以提取到回答中的识读。绝对识读误差的测量方法是真值表计识读与系统预测值之间差值的平均值  $\mu_v$  和标准偏差  $\sigma_v$ 。

$$\mu_v = \frac{\sum_{i=1}^N |P_i - T_i|}{N} \quad (7)$$

$$\sigma_v = \sqrt{\frac{\sum_{i=1}^N (|P_i - T_i| - \mu_v)^2}{N}} \quad (8)$$

式中:  $P_i$  表示预测的识读值;  $T_i$  表示表计的真实识读;  $N$  表示数据总数。绝对识读误差表示识读系统偏离正确识读的实际量。

平均参考误差以平均值  $\mu_R$  和标准偏差  $\sigma_R$  来测量,将绝对识读误差除以表计识读范围计算得到,以证明误差在每个表计方面的显著性。

$$\mu_R = \frac{\sum_{i=1}^N |P_i - T_i|/r}{N} \quad (9)$$

$$\sigma_R = \sqrt{\frac{\sum_{i=1}^N (|P_i - T_i|/r - \mu_R)^2}{N}} \quad (10)$$

式中:  $r$  表示该表计的量程。平均参考误差表示识



图 6 常见表计和域外数据集(OOD)表计可视化图

Fig.6 Visualization of normal meters and out-of-domain(OOD) meters

读系统相较于系统量程偏离正确识读的参考量。

为了探究不同表计识读框架的表计识读速度，引入表计图像平均识读时间  $Time$ 。在本次实验中不测量角度参考误差，因为本文的框架并不需要测量表计指针的角度。通过计算以上这些指标可以判断和比较模型在表计识读任务上的优势。

## 2.2 实验配置

本文使用 QWen2.5-VL-7B-instruct 作为基础模型，在 4 个 NVIDIA A100(80 GB)GPU 的高性能计算节点上训练。微调过程涉及全参数优化，使模型能够有效地适应视觉理解和识读推理数据集提供的结构化推理任务。在微调训练期间，每个设备上的  $batch\_size$  为 1，累积 4 步进行一次梯度计算，学习率为  $2.0 \times 10^{-5}$ ，SFT 期间共训练 1 个 epoch。在后训练阶段，使用 GRPO 进行强化学习，为降低训练方差，每组中生成 4 次输出，且使用  $flash\_attention\_2$ <sup>[25]</sup> 加速训练过程，共训练 2 个 epoch。在推理框架中，使用 VLLM<sup>[26]</sup>，温度设置为 0.1。操作系统是 Ubuntu20.04，Python 版本为 3.11，深度学习框架为 torch 2.5.1-cu121，CUDA 版本为 12.2。

## 2.3 SOTA 对比

为了探究所提出方法的有效性，本文在模拟工业表计数据集和真实数据集分别进行实验。

### 2.3.1 模拟数据集测试

为增大测试难度，本文首先在模拟数据集测试。模拟工业表计数据集包含复杂且苛刻的工业背景，例如光照、指针影子、表盘污染等；除此之外，模拟数据集包含随机生成的不同刻度范围、指针形态等，覆盖广泛的表计内容，有利于评测模型的泛化能力。

测试结果如表 1 所示。为保证测试的全面性，本文分别与模块化算法和端到端的算法框架进行了比较。尤其，在与最新的 QWen2.5-VL-72B<sup>[19]</sup>和 GPT4o<sup>[27]</sup>比较中，本文的方法在模拟工业表计数据集上取得了最优结果，平均参考误差只有 0.012，绝对误差为 3.6，大幅度优于目前最先进的算法。与 Reitsma<sup>[9]</sup>等在 2024 年所提出的专用表计识读框架对比，本文的方法取得 100% 的读数成功率，而模块化方法只有 27.6% 的读数成功率。为了探究模块化识读框架中不同模块对最终结果的影响，本文对每个模块进行分析，图 7 为模块化表计识读的执行顺序及常见的抄表崩溃案例。在模块化识读框架中，每个模块的失败都引入较大识读误差，由于没有模

块之间的累积误差，文本的方法有更精准的读数结果，平均参考误差相比 Reitsma<sup>[9]</sup> 等方法降低 0.021。

### 2.3.2 真实数据集测试

本文在 Howells<sup>[7]</sup> 等人提出的真实数据集 a—f 中进行测试。实验结果如表 2 所示，经过手动检查，在测试集中发现标签 e 数据集有大量的错误标注结果，因此仅分析了剩余的数据。其中在 a 和 b 两个表计中，本文的平均参考误差为 0.02 和 0.016，优

表 1 不同算法在模拟表计上的实验结果

不同算法	$\mu_R$	$\sigma_R$	$\mu_v$	$\sigma_v$	R/%
模块化方法: Reitsma <sup>[9]</sup>	0.033	<b>0.041</b>	10.72	15.30	27.6
端到端 QWen2.5-VL-72	0.151	0.260	54.02	111.60	100
GPT4o	0.121	0.211	37.14	76.24	100
MeterReader++	<b>0.012</b>	0.049	<b>3.60</b>	<b>2.14</b>	100

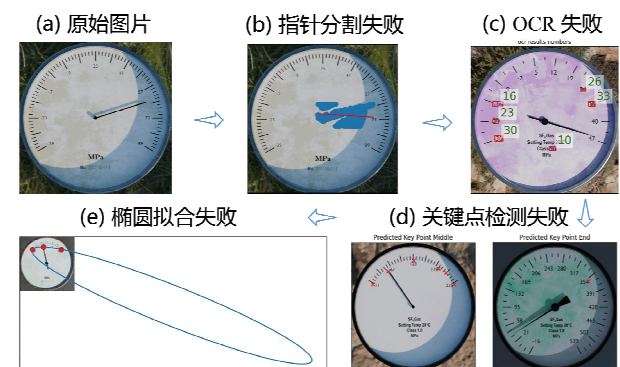


图 7 模块化抄表框架的执行顺序及常见的抄表崩溃案例

Fig.7 The execution sequence of modular meter reading framework and common reading collapse cases

表 2 不同算法在 Howells 等人提出的 a—f 数据集上的实验结果

测试集	MeterReader++		Howells <sup>[7]</sup>		识读量程
	$\mu_R$	R/%	$\mu_R$	R/%	
表计 a	<b>0.020</b>	100	0.053	100	0~10
表计 b	<b>0.016</b>	100	0.070	100	0~60
表计 c	0.027	100	<b>0.009</b>	100	0~300
表计 d	0.061	97	<b>0.043</b>	43	60~430
表计 f	0.034	100	<b>0.023</b>	100	-30~60
平均	<b>0.0316</b>	<b>99.4</b>	0.0396	88.6	

于 Howells 所提框架的 0.053 和 0.070。在剩下 c—f 中本文的精度略低, 这是因为这几个表的量程较大。在本文提出的端到端推理识读中, 由于存在误差项, 预估的误差随量程增大, 导致识读精度略低。但整体的平均精度本文仍然优于 Howells。除此之外, 在 d 数据集中, 由于是非线性刻度, 导致这种模块化的算法识读成功率显著下降。然而本文提出的端到端算法却依旧保持接近 100% 的成功率。并且由于 Howells<sup>[7]</sup>在 d 数据集上的指标只算成功的一部分, 因此本文所提出的算法的实际误差仍然优于模块化算法。

### 2.4 域外数据(OOD)分析

为进一步探究模型的通用表计识读推理能力, 本文收集了广东省、浙江省等 100 张表计图像, 该部分图像由固定摄像头、无人机、移动/滑轨机器人等终端真实采集, 见图 7。这部分数据的表计内容与训练数据集有较大偏差, 因此作为域外数据(OOD), 以此来探究模型在未知表计上的通用识读能力。

在此实验中, 本文与 Reitsma<sup>[9]</sup>等人在 2024 年提出的专用表计识读框架和通用视觉大模型

QWen2.5-72B<sup>[19]</sup>进行比较。实验结果如表 3 所示。模块化的识读框架遇到大量未知的表计数据时, 展现出较大的识读误差和较低的识读成功率。而端到端的视觉语言模型, 凭借强大的视觉理解和人类先验语言知识, 在遇到未知的表计时, 展现出一定的识读能力。QWen2.5-72B 的平均参考误差为 0.183, 显著低于模块化识读框架, 同时, 由于表计解析中存在的认知断层问题, 导致 QWen2.5-72 对表计识读的幻觉问题显著且误差较大。而经过更加细致的表计内容理解和逻辑严密的识读推理训练, 本文所提出的方法平均参考误差只有 0.020, 绝对识读误差为 1.12, 显著优于上述方法。具体识读结果如图 8

表 3 不同算法在本文手动收集的域外数据集 OOD 上的实验结果

Table 3 Experimental results of different algorithms on manually collected out of domain dataset OOD

模型	$\mu_R$	$\sigma_R$	$\mu_v$	$\sigma_v$	R/%	t/s
Reitsma	3.152	6.028	12.88	31.81	50.56	8.45
QWen2.5-72B	0.183	0.467	6.34	17.87	100	
MeterReader++	<b>0.020</b>	<b>0.021</b>	<b>1.12</b>	<b>4.48</b>	100	3.13

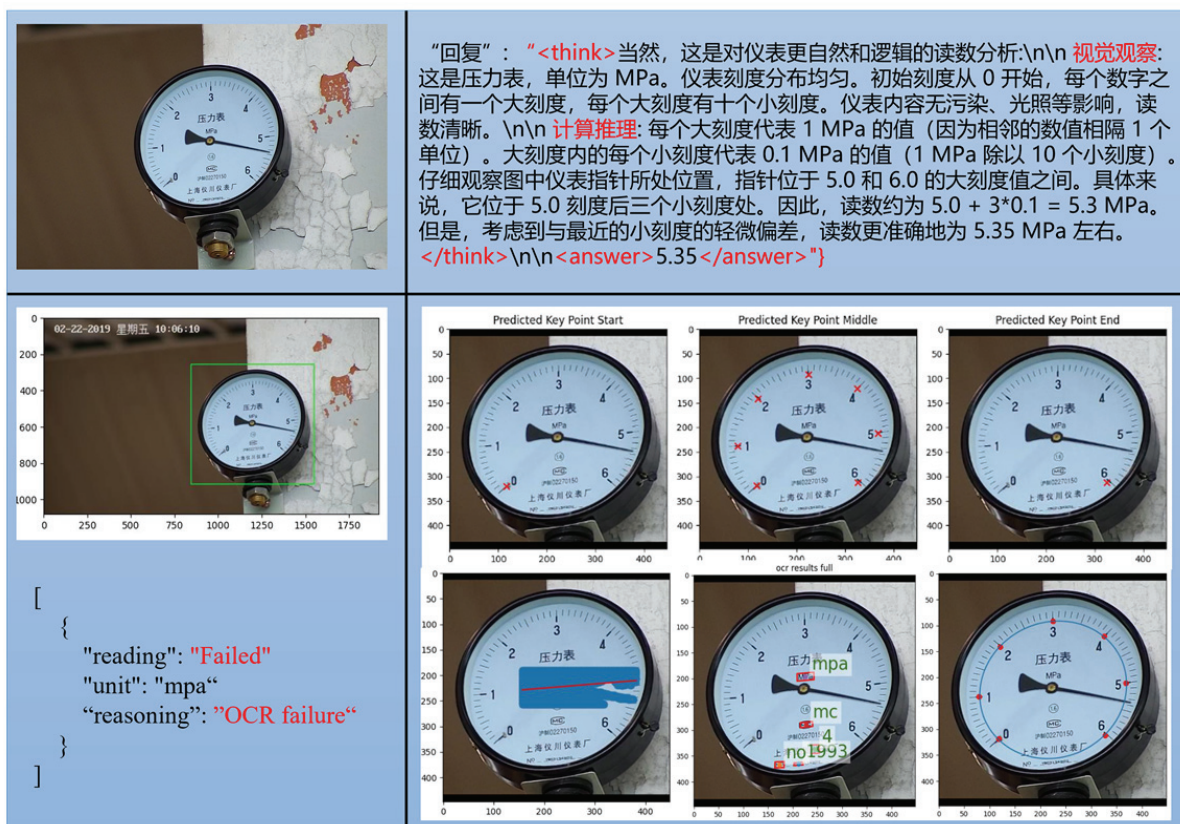


图 8 本文提出的端到端识读框架与模块化表计识读框架的识读可视化

Fig.8 The reading visualization of the modular meter reading framework and the end-to-end reading framework proposed in this paper

所示, 面对 OOD 表计数据, 传统模块化方法在指针分割和 OCR 识别等模块缺乏泛化性, 在多个模块中发生错误, 难以正确地识读表计读数。而本文提出的端到端识读框架, 通过视觉观察和计算推理, 有逻辑地识读仪表内容和推理读数, 提高了模型的鲁棒性。证明了通过细粒度的视觉理解和识读推理轨迹增强能够显著提高对表计的通用识读能力。

此外, 本文还探究了在相同设备条件下不同算法框架的表计识读效率。模块化算法由于多个模块的组合累积, 导致整体的推理效率较低, 单张表计图像的完整读数时间为 8.45 s。而本文提出的端到端识读算法凭借简洁的识读方式和高效的推理框架, 单张表计图像的读数时间为 3.13 s, 显著低于模块化识读框架, 识读效率更高。

## 2.5 消融实验

本文将实验分为 2 组。第 1 组在模拟工业数据集上进行测试, 主要探究提示工程、视觉内容理解、渐进式课程学习、R1 识读轨迹增强等方法对微调后的模型推理精度和稳健性影响。第 2 组在 OOD 表计数据集进行测试, 主要探究通过强化学习是否激发模型的视觉推理能力, 及各环节对表计识读通用能力的影响。

第 1 组实验中, 基线模型为阿里通义实验室推出的 7B 视觉语言模型 QWen2.5-VL-instruct。在 (b—e) 组中, 分别在基线模型上使用直接识读问答、提示工程识读问答、视觉内容理解问答和 R1 识读推理增强等数据微调。

由表 4 得知, 基线模型在模拟工业表计上的平均参考误差为 0.109。通过分析回答内容发现, 该基线模型能够识别表计盘上的数字, 但是对于具体刻度和指针的理解能力有限, 多数回答是基于离指针最近的数字, 无法真正理解表盘内容。为了探究多粒度提示工程对识读精度的影响, 本文分别使用直接回答识读和使用提示工程识读进行实验, 结果如表 4 中的 (b)、(c) 所示, 回答成功率只有 92%, 且方差较大, 回答准确率更不稳定。在 (d) 中, 加入视觉理解数据集, 平均参考误差降到 0.012, 方差降到 0.031, 因此得知, 表计内容理解对于对齐表计内容认知和提高精度至关重要。最后, 如 (e) 中所示, 增加了 DS-R1 蒸馏的识读推理轨迹, 不影响平均参考误差情况下, 误差的方差了减少一半, 显著提高了推理的稳健性。

为进一步研究通用的表计识读推理能力, 本文

在收集的 OOD 表计数据集上进行消融实验, 设置了 4 组实验。

首先, 测试在直接回归识读训练下的模型在 OOD 数据集上的表现。如表 5 中 (a) 所示, 平均参考误差为 0.536, 方差为 1.612, 这种直接回归识读的训练方法, 只能学习到训练集中一对一的问答模式, 在 OOD 数据上的误差值较大。然而, 若经过课程学习和 R1 推理轨迹增强训练后, 如表 5 中 (c) 所示, 平均参考误差降到 0.032, 显著提高了识读推理能力。

其次, 为分析后训练强化学习对模型通用识读能力的影响, 先对原始模型进行 GRPO 强化学习训练, 只用识读答案作为规则奖励的目标, 并没有外加任何的表计视觉信息, 结果如表 5 中 (b) 中所示, 平均参考误差降到 0.085, 大幅优于 SFT 微调方法。说明这种后训练强化学习模式, 经过自我进化后学习到了表计的细粒度内容并且尝试自我理解和识读, 泛化性显著提高。

最后, 本文在经过视觉理解微调的模型上使用后训练强化学习, 结果如表 5 中 (d) 所示, 平均参考误差降到 0.020, 方差降到 0.021, 进一步提高了模型的表计通用识读能力, 在识读的稳定性和精度上都有显著提高。同时, 本文分析了使用不同奖励函数对于表计识读训练的影响。如图 9 所示, 其中图 9(a) 强化学习训练中使用基于容差自适应奖励函数作为强化学习奖励方法, 而 (b) 中为原始的正确性奖励。通过观察正确性奖励曲线发现, 容差自适应奖

表 4 在模拟工业表计上的消融实验

模拟表计消融实验	$\mu_R$	$\sigma_R$	R/%
(a)基线	0.109	0.152	100
(b)基线+直接识读问答	0.024	0.116	92
(c)基线+提示工程识读	0.031	0.103	100
(d)基线+视觉内容理解	0.012	0.031	97
(e)基线+R1 识读推理增强	<b>0.011</b>	<b>0.015</b>	100

表 5 在域外表计数据(OOD)上进行的消融实验

OOD 数据消融实验	$\mu_R$	$\sigma_R$	R/%
(a)SFT (直接识读)	0.536	1.612	90
(b)RL	0.085	0.114	100
(c)SFT (R1 识读推理增强)	0.032	0.075	100
(d)SFT+RL	<b>0.020</b>	<b>0.021</b>	100

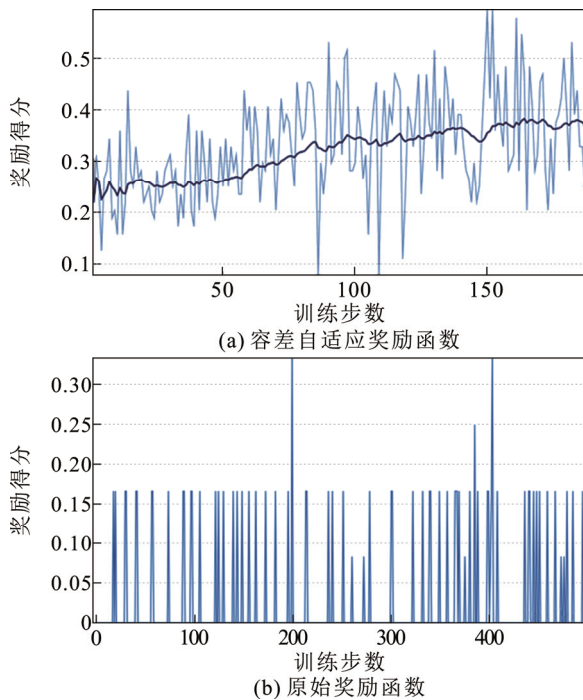


图9 强化学习中不同奖励函数导致的奖励值差异

Fig.9 Differences in reward values caused by different reward functions in reinforcement learning

励函数通过更频繁和正确地奖励,训练过程更稳健。相比之下,原始正确性奖励由于奖励条件过于严格,导致奖励信号稀疏,影响模型的有效学习,增加训练难度,使得模型难以泛化到不同类型的表计识读任务。因此得知,先经过视觉理解微调可以让模型获得专业的表计内容解析能力,再通过强化学习 RL 赋予通用的表计识读推理能力。这种结合方法从表计内容解析和表计识读推理两个方面大大提高了模型对于不同表计的通用识读能力。

### 3 结论

1) 本文提出了一种基于人类视觉认知对齐的通用表计识读框架,通过模拟人类视觉认知过程,实现了从区域定位、表盘语义解耦到计算推理的层次处理。该框架利用 QWen2.5-VL 作为基座模型,辅以多粒度提示工程,有效缓解了传统模块化方法中存在的认知脱节与误差累积问题。然后利用 DeepSeek 蒸馏技术构建数据合成管道,提出四阶渐进课程学习策略,逐步增强模型表计理解和识读推理能力,提高了模型在面对数据稀缺及细粒度识读任务时展现出更强的泛化能力和鲁棒性。

2) 进一步地,本文提出了基于 GRPO 的容差自适应强化学习优化方法。通过将绝对精度约束转

化为可学习的容忍区间,有效缓解了连续回归任务中奖励稀疏的问题,提升了模型对不同表计类型的 OOD 泛化能力。实验结果显示,在各种不同的表计场景上,本方法取得的平均参考误差比基础模型 Qwen2.5-VL 降低 10%,并超越 QWen2.5-VL-72B 和 GPT4o 等先进大模型。

3) 本文所提出的方法为工业自动化中的表计识读任务提供了一种全新的端到端解决方案参考,不仅提升了识读准确性,还增强了模型在复杂实际场景下的鲁棒性与适应性。未来将进一步探索更复杂工业环境中的应用,致力于为智能工业检测提供更高效率、更精准的技术支持。

### 参考文献 References

- [1] 陈 汐, 韩译锋, 闫云凤, 等. 目标物智能跟踪与分割融合算法及其在变电站视频监控中的应用[J]. 中国电机工程学报, 2020, 40(23): 7578-7586.  
CHEN Xi, HAN Yifeng, YAN Yunfeng, et al. A unified algorithm for object tracking and segmentation and its application on intelligent video surveillance for transformer substation[J]. Proceedings of the CSEE, 2020, 40(23): 7578-7586.
- [2] 何 敏, 秦 亮, 刘开培, 等. 变电站电力仪表智能检测算法研究[J]. 高电压技术, 2024, 50(7): 2942-2954.  
HE Min, QIN Liang, LIU Kaipei, et al. Research on intelligent detection algorithms for substation power instruments[J]. High Voltage Engineering, 2024, 50(7): 2942-2954.
- [3] 王 波, 张迎晨, 齐冬莲, 等. 数字化安全管控视角下的全息影像: 定义、基本框架及关键技术[J]. 高电压技术, 2023, 49(8): 3335-3345.  
WANG Bo, ZHANG Yingchen, QI Donglian, et al. Holographic images for digital security control: definition, basic framework and key technologies[J]. High Voltage Engineering, 2023, 49(8): 3335-3345.
- [4] 杨剑锋, 秦 钟, 庞小龙, 等. 基于深度神经网络的输电线路异物入侵监测和识别方法[J]. 电力系统保护与控制, 2021, 49(4): 37-44.  
YANG Jianfeng, QIN Zhong, PANG Xiaolong, et al. Foreign body intrusion monitoring and recognition method based on Dense-YOLOv3 deep learning network[J]. Power System Protection and Control, 2021, 49(4): 37-44.
- [5] YANG Y, YANG S, LI C, et al. Insulator defect detection under extreme weather based on synthetic weather algorithm and improved YOLOv7[J]. High Voltage, 2025, 10(1): 69-77.
- [6] 顾晓东, 唐丹宏, 黄晓华. 基于深度学习的电网巡检图像缺陷检测与识别[J]. 电力系统保护与控制, 2021, 49(5): 91-97.  
GU Xiaodong, TANG Danhong, HUANG Xiaohua. Deep learning-based defect detection and recognition of a power grid inspection image[J]. Power System Protection and Control, 2021, 49(5): 91-97.
- [7] HOWELLS B, CHARLES J, CIPOLLA R. Real-time analogue gauge transcription on mobile phone[C]//Proceedings of 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW). Nashville, USA: IEEE, 2021: 2369-2377.
- [8] LEON-ALCAZAR J, ALNUMAY Y, ZHENG C, et al. Learning to read analog gauges from synthetic data[C]//Proceedings of 2024

- IEEE/CVF Winter Conference on Applications of Computer Vision (WACV). Waikoloa, USA: IEEE, 2024: 8601-8610.
- [9] REITSMA M, KELLER J, BLOMQUIST K, et al. Under pressure: learning-based analog gauge reading in the wild[C]//Proceedings of 2024 IEEE International Conference on Robotics and Automation (ICRA). Yokohama, Japan: IEEE, 2024: 14-20.
- [10] SHU Y, LIU S H, XU H L, et al. Read pointer meters in complex environments based on a human-like alignment and recognition algorithm[J]. arXiv: 2302.14323, 2024: 162-178.
- [11] ZHANG W B, LI P Z, BAI X J. Robust and general reading recognition for pointer meters based on key point detection and large language model[J]. Measurement Science and Technology, 2025, 36(3): 035902.
- [12] CHEN F. Application of remote digital video monitoring and image recognition technology in power system[J]. IET Conference Proceedings, 2022, 2022(20): 44-48.
- [13] YAN X W, WEI L, LI J, et al. Research on automatic recognition of pointer meter reading based on deep learning algorithm[J]. Journal of Physics: Conference Series, 2021, 1865(4): 042017.
- [14] GE W Q, YU X G, HU X Y, et al. An optimized design of the pointer meter image enhancement and automatic reading system in low illumination environment[J]. Measurement Science and Technology, 2023, 34(10): 105907.
- [15] ZHU J Y, XU Z Z, LIN Y. Pointer meter reading under noise based on virtual data generation[C]//Proceedings of 2024 China Automation Congress (CAC). Qingdao, China: IEEE, 2024: 6570-6574.
- [16] GAO J X, SU S S, YE W J, et al. On designing effective RL reward at training time for LLM reasoning[C]//The Thirteenth International Conference on Learning Representations. Singapore, Singapore: OpenReview. net, 2025: 1-24.
- [17] DeepSeek-AI, GUO D Y, YANG D J, et al. DeepSeek-R1: incentivizing reasoning capability in LLMs via reinforcement learning[J]. arXiv: 2501.12948, 2025.
- [18] 李帷韬, 侯建平, 张倩, 等. 基于强化学习和 Transformer 的输电线路缺陷智能检测方法研究[J]. 高电压技术, 2023, 49(8): 3373-3384.  
LI Weitao, HOU Jianping, ZHANG Qian, et al. Research on intelligent detection method of transmission line defects based on reinforcement learning and transformer[J]. High Voltage Engineering, 2023, 49(8): 3373-3384.
- [19] SHAO Z H, WANG P Y, ZHU Q H, et al. DeepSeekMath: pushing the limits of mathematical reasoning in open language models[J]. arXiv: 2402.03300, 2024.
- [20] 李刚, 方鸿, 刘云鹏, 等. 新型电力系统中的大模型驱动技术: 现状、机遇与挑战[J]. 高电压技术, 2024, 50(7): 2864-2878.  
LI Gang, FANG Hong, LIU Yunpeng, et al. Large-model drive technology in new power system: status, challenges and prospects[J]. High Voltage Engineering, 2024, 50(7): 2864-2878.
- [21] BAI S, CHEN K Q, LIU X J, et al. Qwen2.5-VL technical report[J]. arXiv: 2502.13923, 2025.
- [22] WANG X, CHEN Y D, ZHU W W. A survey on curriculum learning[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 44(9): 4555-4576.
- [23] XU G W, JIN P, LI H, et al. LLaVA-CoT: let vision language models reason step-by-step[J]. arXiv: 2411.10440, 2024.
- [24] FAN Z Z, SHI L R, XI C, et al. Real time power equipment meter recognition based on deep learning[J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 5017015.
- [25] DAO T. FlashAttention-2: faster attention with better parallelism and work partitioning[J]. arXiv: 2307.08691, 2023.
- [26] KWON W, LI Z H, ZHUANG S Y, et al. Efficient memory management for large language model serving with Paged Attention[C]//Proceedings of the 29th Symposium on Operating Systems Principles. Koblenz, Germany: ACM, 2023: 611-626.
- [27] OpenAI. GPT-4 Technical Report[J]. arXiv: 2303.08774, 2023.



WANG Changpeng  
Ph.D. candidate



YAN Yunfeng  
Ph.D.  
Associate professor



QI Donglian  
Ph.D., Professor  
Corresponding author

#### 王昌鹏

2003—, 男, 博士生

主要从事计算机视觉和多模态学习方面的研究工作

E-mail: 2281492659@qq.com

#### 闫云凤

1988—, 女, 博士, 副教授, 硕导

主要从事计算机视觉、运行态势感知、分布式发电设备异常监测方面的研究工作

E-mail: 21210004@zjuedu.cn

#### 齐冬莲(通信作者)

1973—, 女, 博士, 教授, 博导

主要从事智能信息处理、混沌系统、非线性理论与应用方面的研究工作

E-mail: qidl@zju.edu.cn

收稿日期 2025-01-07 修回日期 2025-02-12 编辑 卫李静