

突破多模态大模型的效率瓶颈： 结构、数据与训练优化

演讲人：余天予

清华大学 / 博士生

AiCon

全球人工智能开发与应用大会

目录

多模态大模型

多模态大模型的效率瓶颈

MiniCPM-V 4.5 高效多模态大模型

极客邦科技 2026 年会议规划

促进软件开发及相关领域知识与创新的传播



参会咨询



查看会议



01 多模态大模型

■ 多模态大模型

- 传统语言大模型仅能处理文本模态信息
- 多模态大模型拓展大模型能力边界和应用场景，已成为人工智能前沿趋势和发展焦点

主要特点

基于大数据和人类反馈进行学习，与用户通过对话进行交互，能够处理多模态信息及多种任务，深层推理与常识运用能力大幅度提升

里程碑事件

2023/03/15: OpenAI 发布**多模态对话模型 GPT-4**
2023/12/06: Google 发布**多模态模型 Gemini**
2024/03/04 : Anthropic发布**多模态模型 Claude 3**
2024/05/13: OpenAI发布原生**多模态模型 GPT-4o**
2025/03/25: Google发布**多模态模型 Gemini 2.5**
2025/08/07: OpenAI发布**多模态模型 GPT-5**

多模态能力

支持多种模态建模，包括文本、图像、视频等



What would happen if
the strings were cut?



The balloons would
fly away.

■ 多模态大模型

- 多模态大模型的研究具有科学意义与实用价值
- 科学意义
 - 从多模态数据中学习为智能突破带来巨大潜力，是**智能跃迁的下一个关键引擎**
- 实用价值
 - 现实世界许多任务都需要**理解多模态输入**，例如具身智能、自动驾驶和视障群体辅助技术



Yann LeCun
图灵奖获得者

大部分的**人类知识**（以及几乎所有动物的知识）都是通过**视觉、听觉、触觉、味觉和嗅觉**等**感官体验**，通过与物理世界的互动而获得的。



Ilya Sutskever
OpenAI前首席科学家


人类是多模态的动物。**没有多模态，神经网络的作用会远不及其上限**。通过多模态学习，人类可以更好地了解世界。

02 多模态大模型的效率瓶颈

多模态大模型的效率瓶颈

传统 Scaling Law: 高资源低能效的粗放式增长

- 更多智能 = 更多参数 + 更多数据 + 更多计算

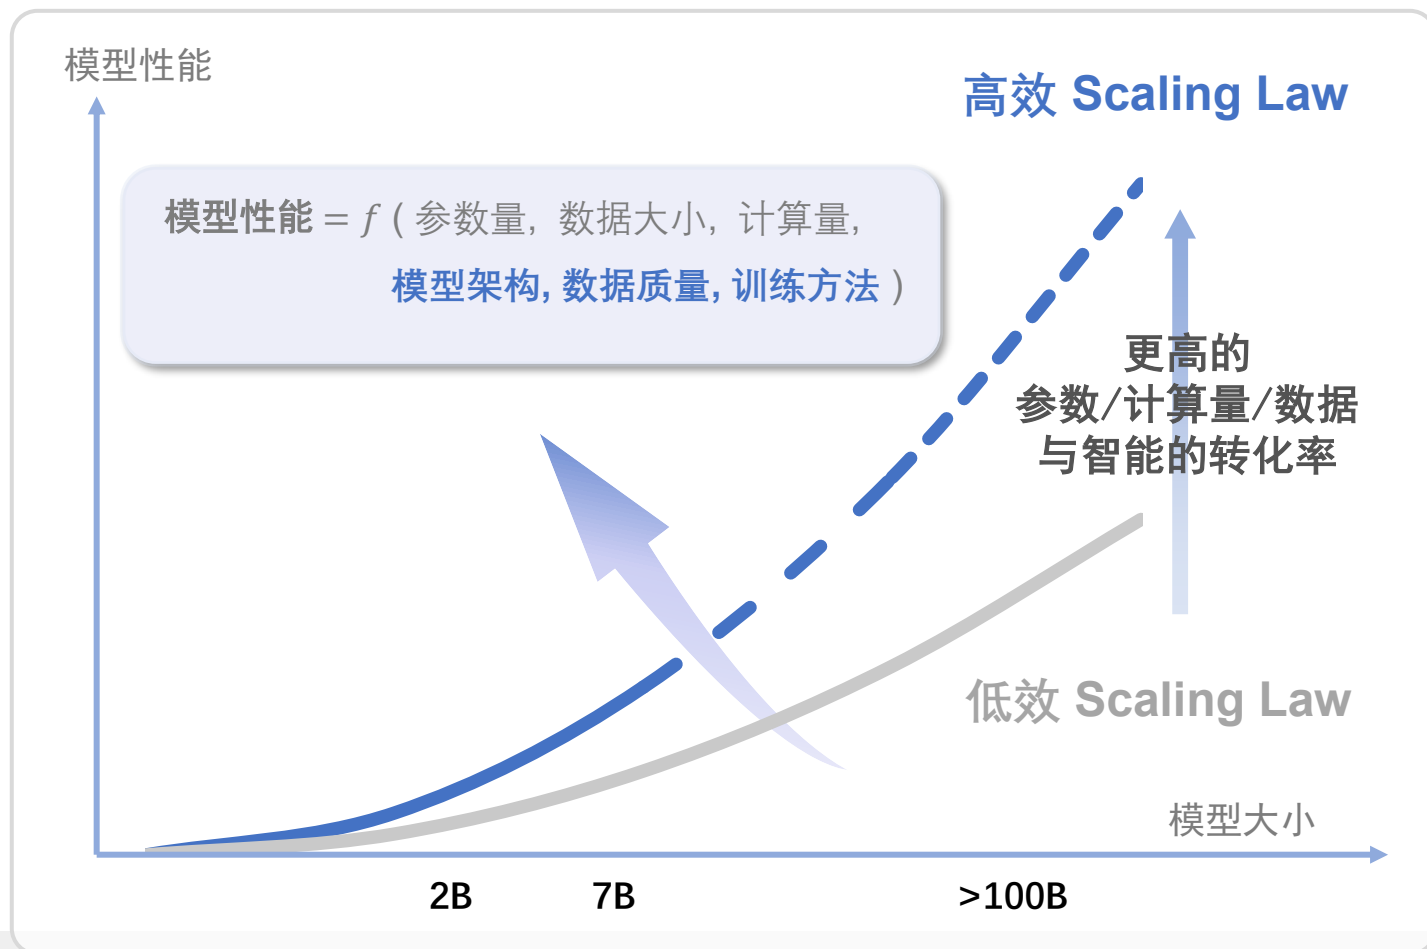


Source: Analysis by Peter Gostev (<https://www.linkedin.com/in/peter-gostev/>), Based on benchmark reports and data from Epochs.org (<https://epochai.org/blog/who-is-leading-in-ai-an-analysis-of-industry-ai-research>)

Scaling Law

更多的**智能**
=
更多的**参数**
+
更多的**数据**
+
更多的**计算**

■ 高效 Scaling Law



| | 当前范式 | 我们的方案 |
|----|-------|-------|
| 模型 | 增加参数量 | 高效率结构 |
| 数据 | 增加数据量 | 高质量数据 |
| 训练 | 增加计算量 | 高效率训练 |

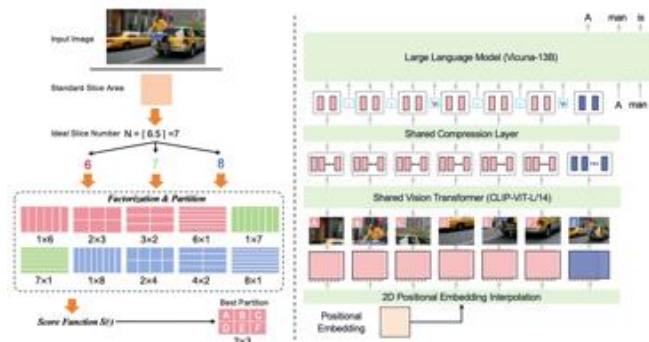
■ 关键技术研究

高效模型结构

低清图，少细节

统一高分辨率
视觉编码框架

- 支持原生长宽比
- 高效视觉 token 压缩
- 统一的单、多图、视频建模



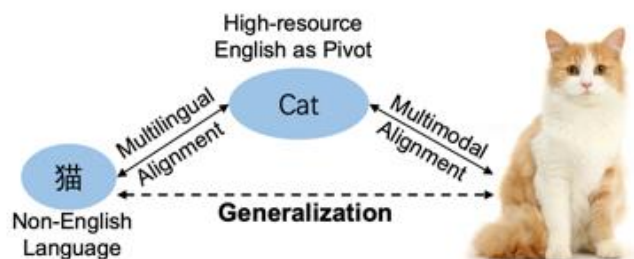
LLaVA-UHD: an LMM Perceiving Any Aspect Ratio and High-Resolution Images. ECCV 2024.

高效训练方法

英文强，中文弱

多语言多模态泛化

- 仅使用英文文本-图像数据进行预训练
- 中文跨语言多模态能力泛化



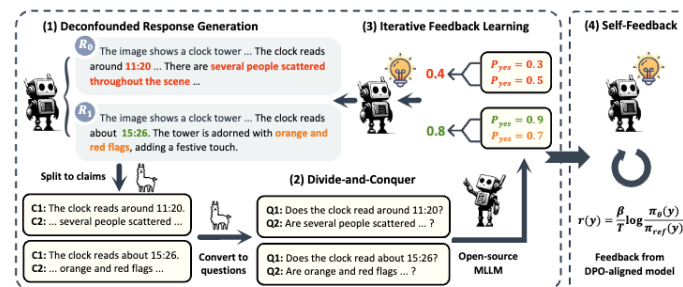
Large Multilingual Models Pivot Zero-Shot Multimodal Learning across Languages. ICLR 2024. Spotlight.

高质量数据构建

幻觉多，难置信

多模态反馈数据构建

- 通过细粒度的人类反馈 / AI自动反馈数据对齐模型行为
- 显著减少多模态幻觉



RLHF-V: Towards Trustworthy MLLMs via Behavior Alignment from Fine-grained Correctional Human Feedback. CVPR 2024.
RLAIF-V: Open-Source AI Feedback Leads to Super GPT-4V Trustworthiness. CVPR 2025. Highlights.

效率瓶颈：结构

多模态大模型的一个主要效率瓶颈就是巨大的视觉特征表征开销

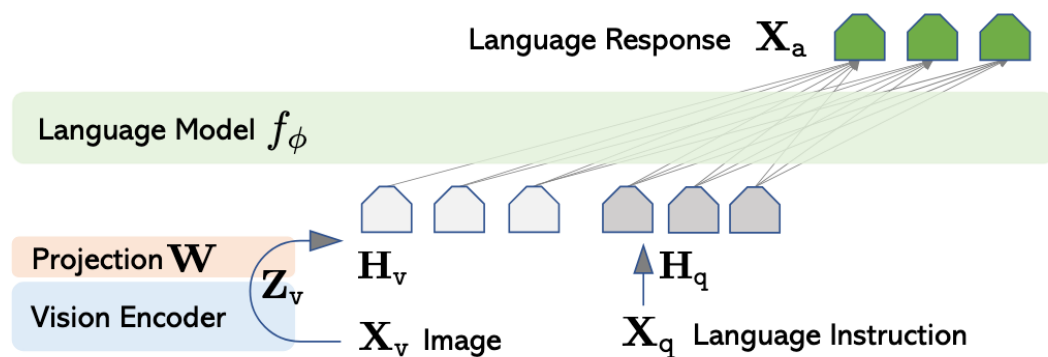



Figure 1: LLaVA network architecture.

主流视觉编码结构



448x448, 6s, 2fps



InternVL3: 3072 tokens
Qwen2.5 VL: 1536 tokens

1920x1080, 6s, 24fps

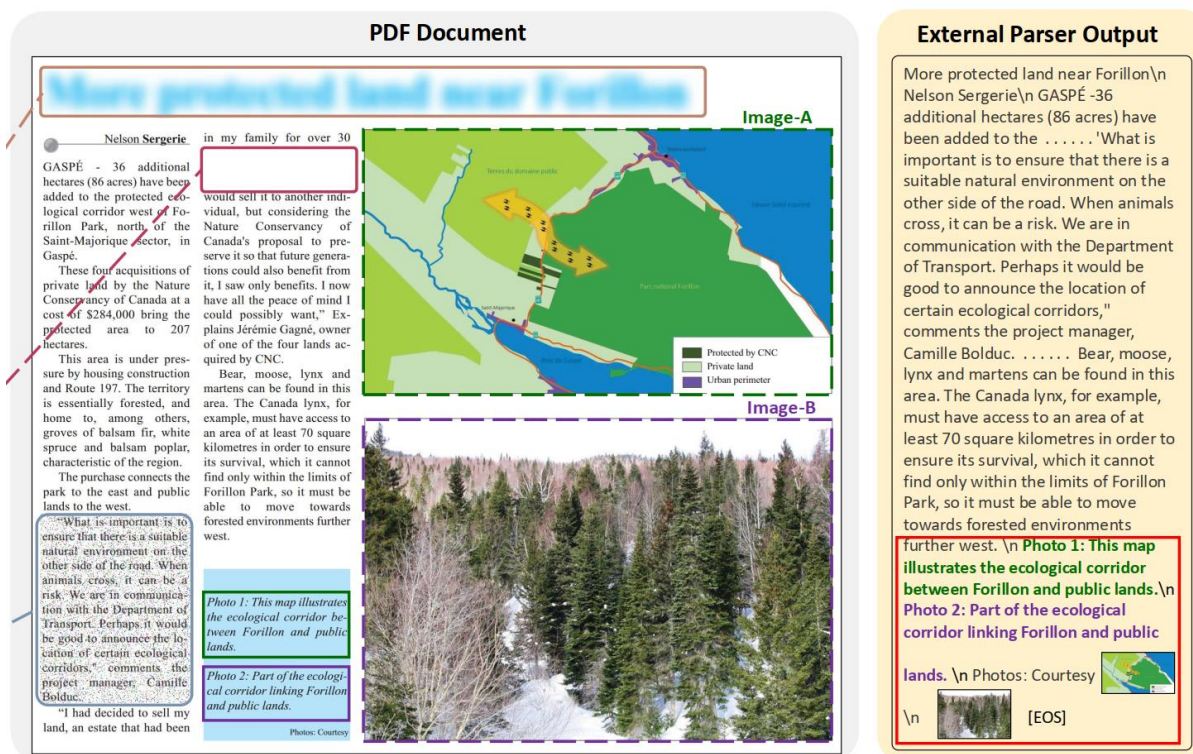


InternVL3: 380K tokens
Qwen2.5 VL: 190K tokens

效率瓶颈：数据

文档成为多模态大模型能力进一步增长的重要数据来源

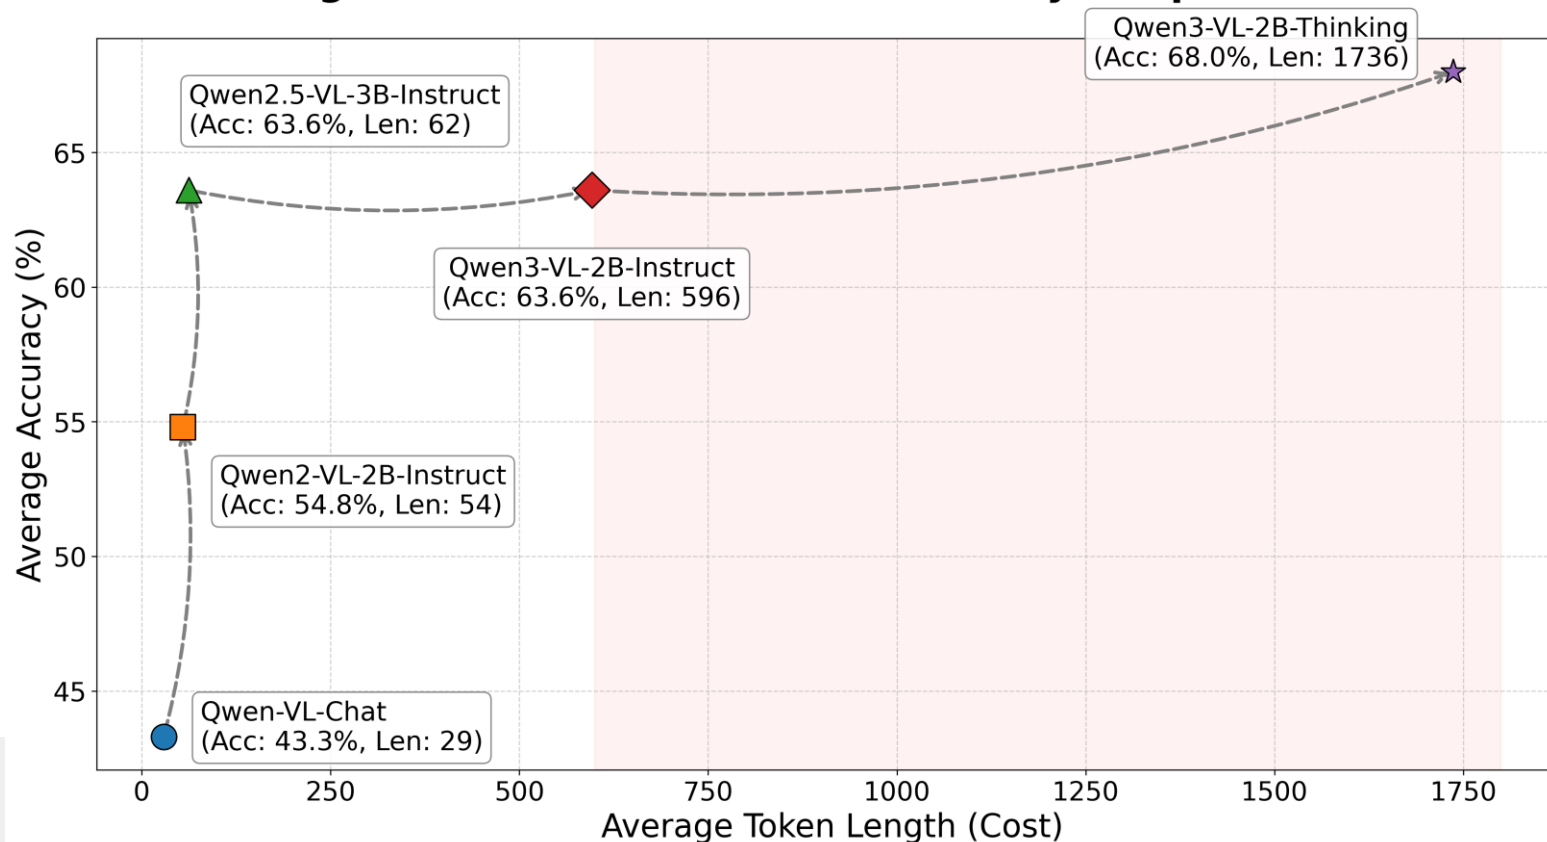
但其数据质量和质量保障都带来了效率问题，广泛使用的图文解析工具频繁引入解析噪声



效率瓶颈：训练

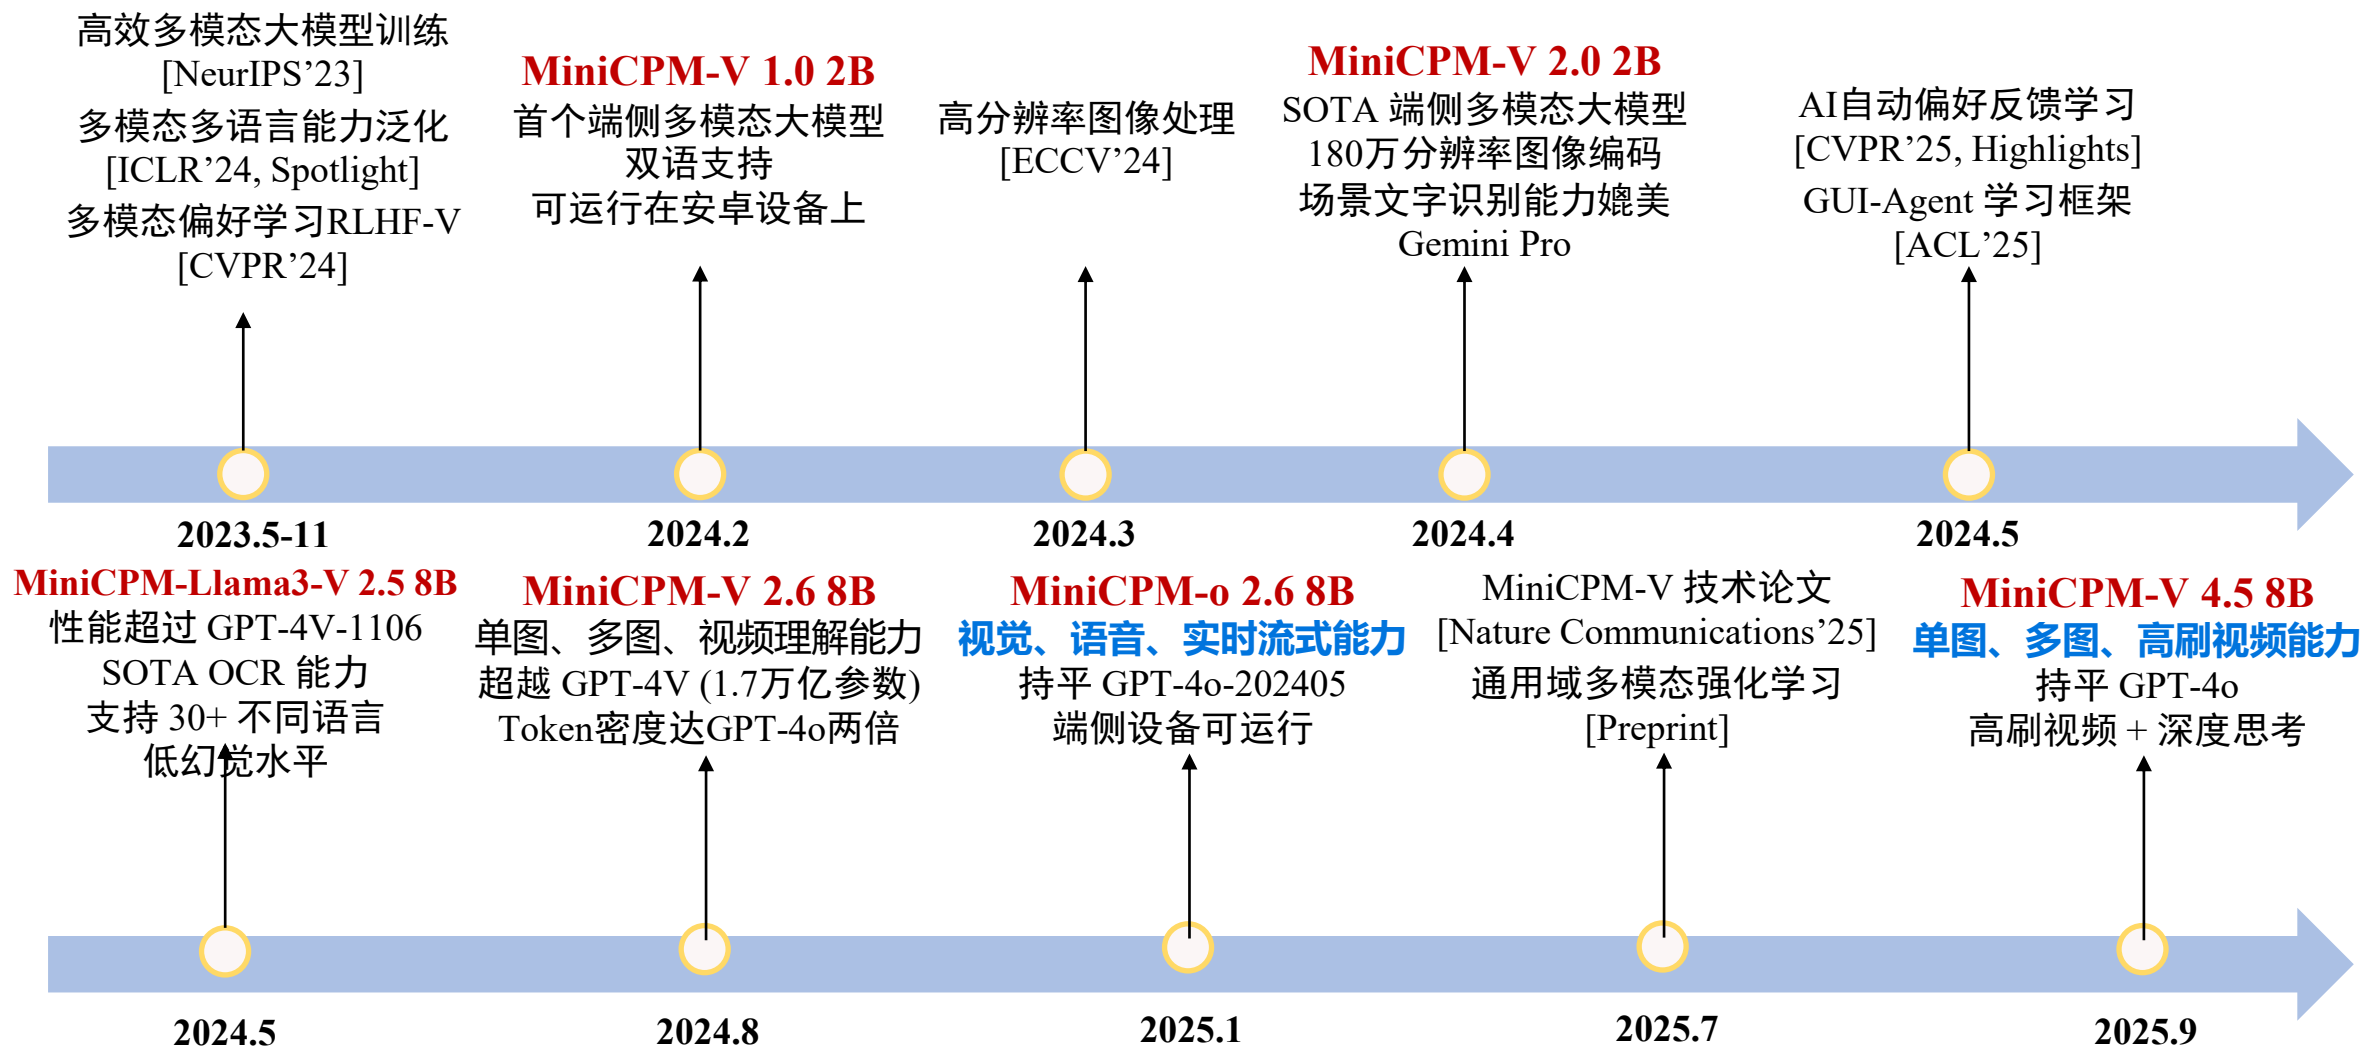
Token 的“通货膨胀”：深度推理范式提高了多模态大模型的推理能力，但于此同时显著增加了训练和推理过程的计算规模和时间开销。

Diminishing Returns: Token Cost vs. Accuracy in Open-Source MLLMs



03 MiniCPM-V 4.5 高效多模态大模型

MiniCPM-V: 高效端侧多模态大模型



MiniCPM-V 4.5 高效多模态大模型

MiniCPM-V 4.5 (8B)

看得准 看得快 看得长


首个 高刷 视频理解多模态大模型

可控混合推理


高密度

端侧友好


综合 & 长视频理解




长视频理解



OpenCompass 推理开销




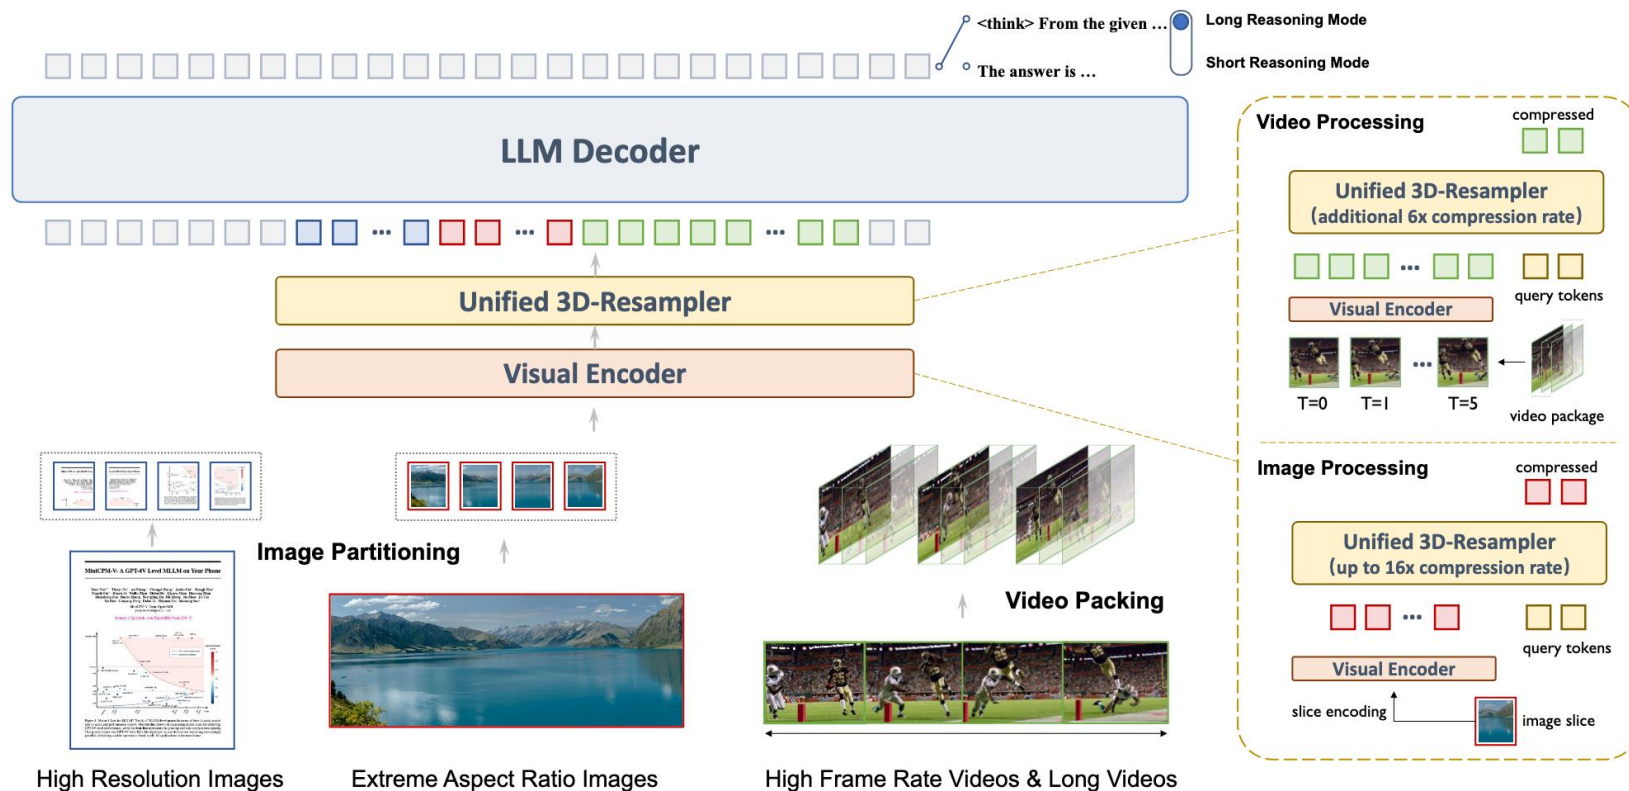
Video-MME 推理开销



注：OpenCompass 和 Video-MME 均采用 A100 * 8 卡推理，其中 Video-MME 的推理时间未统计视频抽帧时间，MiniCPM-V 4.5 在 Video-MME 推理采样 3 帧打包策略

结构：高效统一视觉编码

3D-Resampler 结构：时空统一压缩，显著降低图像、视频的视觉编码开销达 4~96 倍



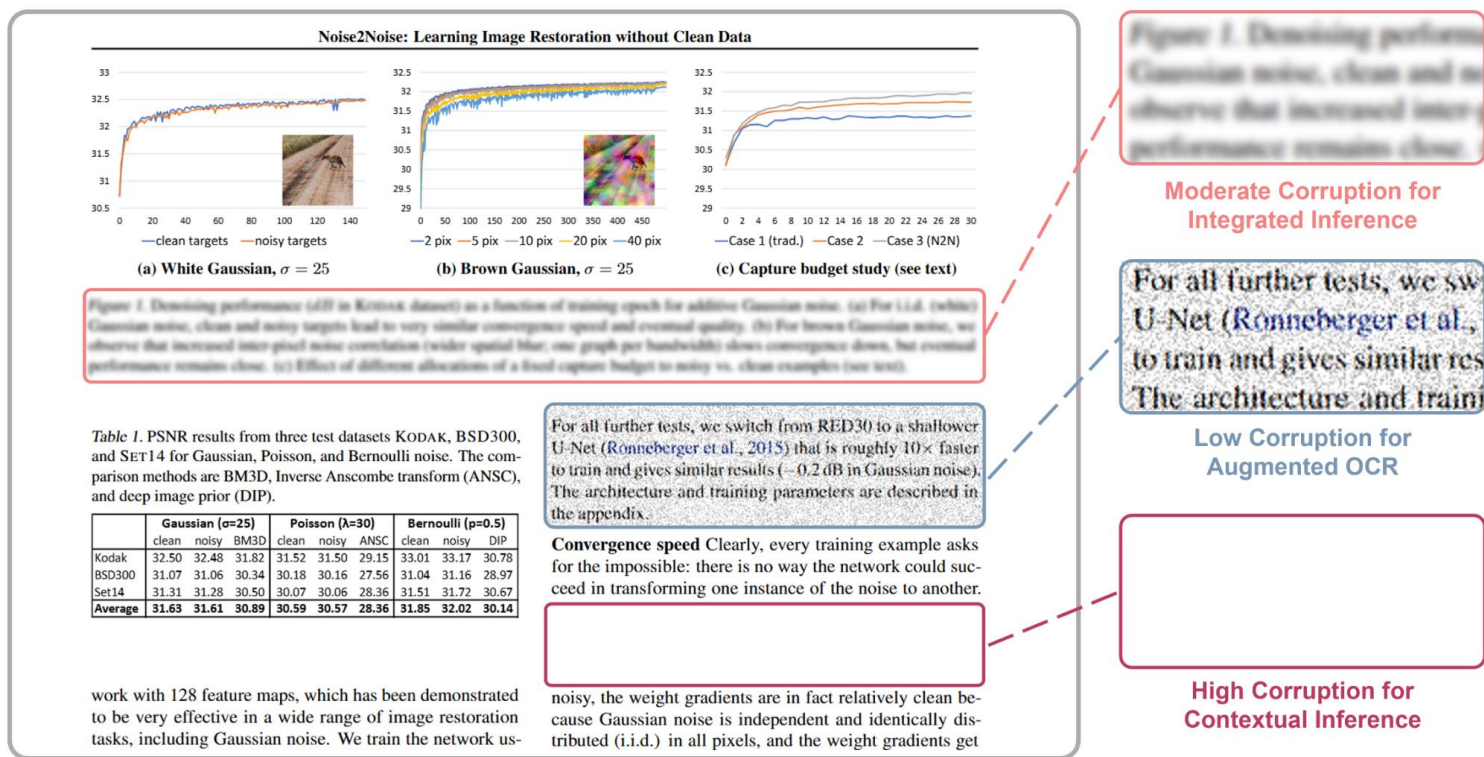
448x448, 6s, 2fps

1536 tokens
Qwen2.5 VL

128 tokens
MiniCPM-V 4.5

数据：高效文档知识统一学习格式

通过利用简单的动态视觉遮蔽，多模态文档图像可以直接用于OCR、文档知识学习等多种任务的训练，避免复杂解析器引入的数据错误问题



■ 训练：高效混合思考后训练

在 RL 过程中混合长思考模式和短思考模式采样策略，在显著降低训练开销的同时进一步提升了模型的回答效率

| Method | OpenCompass | Training Tokens |
|----------------------|-------------|-----------------|
| Short reasoning only | 76.0 | 1.6B |
| Long reasoning only | 77.0 | 4.4B |
| Hybrid | 77.1 | 3.1B |

Table 3: Ablation of hybrid reinforcement learning. We report training token cost and performance on OpenCompass.

| Model | Size | Avg Score ↑ | Time ↓ |
|----------------------|-------|-------------|-------------|
| GLM-4.1V-9B-thinking | 10.3B | 76.6 | 17.5h |
| MiMo-VL-7B-RL | 8.3B | 76.4 | 11.0h |
| MiniCPM-V 4.5 | 8.7B | 77.0 | 7.5h |

极客邦科技 2026 年会议规划

促进软件开发及相关领域知识与创新的传播



参会咨询



查看会议



THANKS

探索 AI 应用边界

Explore the limits of AI applications

AiCon

全球人工智能开发与应用大会