

Golia-v2

Versão atual: golia-2504

Visão Geral

Golia-v2 é a variante menor do modelo de visão e linguagem (VLM) na família Amazônia IA. Foi projetado para fornecer fortes capacidades multimodais de forma eficiente, visando configurações de hardware acessíveis enquanto mantém desempenho competitivo, especialmente em compreensão de documentos e perguntas e respostas visuais.

- **Arquitetura do Modelo:** Arquitetura similar ao Golia-v1/Amazônia IA (LLM + ViT), mas redimensionada para maior eficiência. Processa imagens em resoluções nativas.
- **Características-chave e Capacidades Principais:**
 - Oferece funcionalidades essenciais de visão e linguagem dimensionadas para seu tamanho: Compreensão Multimodal, Análise Visual e de Documentos Avançada, Interação Agêntica, Raciocínio e Saída Aprimorados.
 - Desempenho notavelmente forte para seu tamanho em compreensão de documentos, OCR e tarefas de perguntas e respostas visuais.

Especificações Técnicas

- **Modalidades de Entrada:** Texto, Imagem, Vídeo
- **Modalidades de Saída:** Texto
- **Janela de Contexto:** Suporta até 128K tokens. Máximo recomendado de 32K tokens para tarefas de visão e linguagem. Contate WideLabs se janelas de contexto maiores forem essenciais.
- **Idiomas:** Multilíngue (dezenas de idiomas). O desempenho em idiomas específicos pode ser aprimorado via fine-tuning.

Desempenho

Entrega resultados impressionantes para seu tamanho, oferecendo uma opção VLM poderosa mas acessível. Altamente competitivo, particularmente forte em benchmarks de documentos e perguntas e respostas visuais.

Benchmark Category	Benchmark	Score	Notes
Vision (Doc/Chart)	ChartQA	86.5	Chart Visual Question Answering
Vision (Doc/Chart)	DocVQA	92.1	Document Visual Question Answering
Vision (Doc/Chart)	InfoVQA	80.8	Information Visual Question Answering
Vision (General)	MMMU	57.9	College-level Multimodal Problems
Vision (General)	MMMU-Pro	37.4	Harder College-level Multimodal Problems
Vision (Math)	MathVision	24.9	Visual Math Reasoning
Vision (Math)	MathVista	66.7	Visual Math Reasoning
Vision (OCR & Reasoning)	OCR-BenchV2	54.2	Comprehensive OCR & Reasoning

A complete and updated leaderboard comparing all Amazônia IA models will be available soon at: <https://huggingface.co/spaces/widelabs/leaderboard>

Implantação

- Framework: vLLM
- Hardware (BF16): 1x A10
- Integração de API: API compatível com OpenAI
- Formatação de Entrada: Lista de dicionários (**role**, **content**). O conteúdo do usuário é uma lista de dicionários (**type**: "text"/"image"/"video", **data**: string/URL/caminho/base64).
- Engenharia de Prompt: Princípios padrão. Aproveite detalhes/formatação aprimorados. Combine instruções claras de texto com contexto visual.
- Quantização: Geralmente não recomendada devido ao tamanho menor do modelo; a degradação de desempenho pode ser mais significativa. Contate WideLabs se a quantização for necessária.
- Fine-tuning: Suportado e pode alcançar desempenho notável em tarefas específicas. Contate WideLabs para serviços de fine-tuning.

- Limitações: Pode encontrar limites de desempenho em GPUs de menor capacidade, especialmente ao processar entradas de alta resolução ou contextos muito longos simultaneamente.