

Google Project Astra 和 OpenAI 的 GPT-4o 接連登場 多模態 AI 助理時代真的來臨了！

近期，OpenAI 推出了 GPT-4o，而 Google 也不甘示弱，推出了其最新版本的多模態 AI 助理 Project Astra。這兩個重量級計劃的登場，無疑預示著多模態 AI 助理時代的到來，這將徹底改變我們的生活、工作以及學習方式。



Google Project Astra 革新之舉

Google Project Astra 是 Google 的一項創新之舉，它結合了語音、圖像、文本等多元模態，塑造出一個全方位的智能助理。這項技術能通過攝影鏡頭捕捉周遭的世界，並由人工智慧即時、持續地描述畫面細節。例如，它能描述擴音器的聲音發出部位，甚至指出被標記的喇叭部分是 Tweeter 高音單體。同時，它還能創意地組合蠟筆相關的詞彙、識別程式編碼內容，甚至從白板上畫的貓與紙箱聯想到「薛丁格的貓」等。




除此之外，當影片中的使用者詢問眼鏡的位置時，人工智慧能迅速給出答案，展示了其優秀的資訊記憶能力。當使用者從手機切換到配備攝影鏡頭的智能眼鏡時，Project Astra 依然能無縫遷移資料，讓使用者在不同裝置上繼續享受服務。這種跨模態的處理能力，將 Astra 在智能化互動的實現上推向了全新的高度。

Google 同時也推出全新的 Gemini 1.5 pro，不僅能處理更多數據，也增強了該模型編寫程式碼、推理以及解析音訊和圖像的能力。另外 Google 正準備推出一個名為「Gemini 1.5 Flash」的新模型。Google DeepMind 的 CEO Demis Hassabis 表示，Gemini 1.5 Flash 在摘要生成、聊天、圖像和影片字幕生成、以及由長文件和表格中提取資料等方面更勝一籌。

此外，Google 發布 PaliGemma，首個 Gemma 視覺語言多模態開放模型，具有處理圖像和文字並輸出文字的能力。這些模型分為預訓練 (pt)、混合和微調 (ft) 三種類型，每種均提供不同分辨率和精度選擇。PaliGemma 由 SigLIP-So400m 圖像編碼器和 Gemma-2B 文字解碼器組成，專門設計用於理解圖像和文字的聯合訓練，並可以針對各種下游任務進行微調，以實現精準的多模態互動。

Google Project Astra 和 OpenAI 的 GPT-4o 的接連登場，標誌著多模態 AI 助理時代的正式來臨。這些技術的發展，將深刻改變我們的生活方式，讓人機交互變得更加智能和自然。我們有理由期待，在不久的將來，多模態 AI 助理將成為我們生活中的重要夥伴，為我們帶來更多便利和可能性。



參考資料

<https://huggingface.co/blog/paligemma>

<https://github.com/...../configs/proj/paligemma/README.md>

Gemini 1.5 Flash



Speed and efficiency




Multimodal reasoning



Long context window


PaliGemma



PaliGemma 版本包含三種類型的型號：

1. PT 檢查點：可以針對下游任務進行微調的預訓練模型。
2. 混合檢查點：PT 模型針對混合任務進行了微調。它們適用於帶有自由文字提示的通用推理，並且只能用於研究目的。
3. FT 檢查點：一組經過微調的模型，每個模型專門針對不同的學術基準。它們有各種分辨率，僅用於研究目的。

<https://huggingface.co/blog/paligemma>



https://github.com/google-research/big_vision/blob/main/big_vision/configs/ops/paligemma/README.md

PaliGemma 模型

PaliGemma-3B 是一種視覺語言模型，其設計靈感受到 PaLI-3 啟發。這個模型的主要組件包括 SigLIP 視覺編碼器，例如 SigLIP-So400m/14 和 Gemma 2B 語言模型。

輸入處理： PaliGemma 可以接收一幅或多幅圖像作為輸入。這些圖像首先由 SigLIP 視覺編碼器處理，將圖像轉換成一種稱為「軟標記」的中間表示形式。這種轉換過程是將圖像的視覺信息編碼成一種形式，讓模型能夠理解和處理。

文本處理： 同時，輸入的文本（前綴）會由 Gemma 的標記產生器進行標記。這意味著文本會被處理成模型可以理解的格式。

資料整合與處理： 接下來，圖像的軟標記和文本的前綴標記會按照一定順序被連接在一起，然後傳遞給 Gemma 解碼器。Gemma 解碼器使用完整區塊注意力（full block attention）來處理這些連接的資料。

輸出生成： 解碼器利用屏蔽注意力（masked attention）機制進行自動回歸，生成輸出文本（後綴）。這一步驟意味著解碼器會自動地根據已處理的圖像和文本資料，生成相應的輸出文本。