

IBM 推出Granite 3.2 全新企業級多模態及推理的AI模型

- Granite 3.2是小型的 AI 模型 通過對開發人員友好的授權條款 提供推理、視覺和護欄功能
- 更新後的 Granite 時間序列模型可提供長期預測 參數少於10M 適用於金融與經濟趨勢分析、供應鏈需求預測 以及零售業的季節性庫存規劃等用例

香港2025年3月4日 /美通社/ -- IBM於2月底**推出**其 Granite 大型語言模型家族的最新一代 品 Granite 3.2 持續推動小型、高效、企業專用的 AI 為實際應用創造效益。

所有 Granite 3.2 模型均採用 鬆的 Apache 2.0 開源授權條款 可在 Hugging Face 下載。部分模型現已在 IBM watsonx.ai、Ollama、Replicate 和 LM Studio 上提供 預計不久將支援 RHEL AI 1.5 為企業與開源社區注入更強大的 AI 能力。

主要亮點

- **全新視覺語言模型** 專為理解文件任務而設計 在關鍵企業基準測試 DocVQA、ChartQA、AI2D 和 OCRBench^[1] 中 表現可 美甚至超越更大規模的模型 如 Llama 3.2 11B 和 Pixtral 12B 。除了強大的訓練數據外 IBM **也利用其開源 Docling 工具包**處理8千5百萬 PDF 文件 並生成2千6百萬個合成問答配對 提升視覺語言模型在處理大量文件工作流時的能力。
- **強推理功能** Granite 3.2的2B與8B模型加入了「思維鏈」 Chain of Thought CoT 推理機制 且使用者可以開 或關閉推理功能以優化效率。通過這項能力 8B 模型在 ArenaHard 和 Alpaca Eval 等指令遵循基準測試中的表現^[2] 比前一代優異比例達到兩位數 且不影響其他領域的安全性或性能。此外 通過**創新的推理擴展方法** Granite 3.2 8B 模型可以調整至接近 Claude 3.5 Sonnet 或 GPT-4o 在數學推理基準 如 AIME2024 和 MATH500^[3] 上的表現。
- **Granite Guardian 安全模型更輕巧** 在保持 Granite 3.1 Guardian 模型性能的同時 模型尺寸減少三成。此外 Granite 3.2 系列還引入了語言化信心評估 Verbalized Confidence 新功能 可提供更精細的風險評估 助安全監測系統識別不確定性。

IBM 持續推動企業專用的小型 AI 模型策略 並已在測試中展現高效能。例如 Granite 3.1 8B 模型在 **Salesforce 大型語言模型CRM 基準測試**中獲得高分 顯示其在實際應用中的準確度和可靠性。

IBM Granite 模型家族擁有廣大的合作夥伴生態體系 許多領先的軟件公司已將Granite模型嵌入其技術。Granite 3.2 是 IBM 在推動企業專用小型 AI 方面的重要進展 體現了 IBM 致力於提供小型、高效、實用 AI 的 品策略。

CrushBank 首席技術官 David Tan 表示「在 CrushBank 我們親眼目睹了 IBM 開放、高效的人工智能模型如何為企業人工智能帶來真正的價 --在性能、成本效益和可擴展性之間實現適當的平衡。Granite 3.2 通過新的推理功能更進一 我們很高興能在構建新的代理 智能體 解決方案時探索這些功能。」

Granite 3.2 是 IBM 品組合和戰略發展的重要一 旨在為企業提供小型實用的 AI。雖然思維鏈在推理任務中表現強大 但它需要大量計算資源 並非所有任務都必須 用。因此 IBM 在 Granite 3.2 模型中加入了程式化開關功能 使用者可以根據需求開 或關閉推理模式 模型可在不 用推理的情況下運行較簡單的任務 以降低不必要的計算成本。

此外 其他推理技術 例如推理擴展 Inference Scaling 已顯示 Granite 3.2 8B 模型能 在標準數學推理基準測試中 美甚至超越更大模型的性能。持續發展這項推理技術也是 IBM 研究團隊的重點方向^[4] 以進一 提升 AI 的效能與應用範圍。

除了 Granite 3.2 的指令、視覺和防護模型之外 IBM 也推出了新一代 TinyTimeMixers TTM 時間序列模型 這些模型的參數少於1千

萬 具備長期預測能力 可進行長達兩年的長期預測。這些模型為長期趨勢分析提供強大工具 適用於金融與經濟趨勢分析、供應鏈需求預測 以及零售業的季節性庫存規劃。

IBM AI 研究副總裁 Sriram Raghavan 表示「AI 的下一個時代將聚焦效率、整合與實際應用的影響力 — 企業應該能 在不過度消耗計算資源的情境下 取得強大的 AI 效益。IBM 最新的 Granite 模型發展專注於開放式解決方案 逐 推動 AI 的普及 使其更具成本效益 為現代企業創造更大價。」

欲了解Granite 3.2 的技術細節 請參 相關[技術文章](#)。

關於 IBM

IBM 是全球領先的混合雲與人工智能、以及企業服務提供商 為全球175個國家和地區的客 服務 助企業把握其數據洞察、簡化業務流程、降本 效 獲得行業競爭優勢。IBM 混合雲平台和紅帽OpenShift 為全球超過4,000家政府和企業機構的關鍵性基礎設施提供有力支 例如來自金融服務、電訊和醫療健康等行業的客 助他們快速、高效、安全地實現數碼轉型。IBM 在人工智能、量子運算、特定行業的雲解決方案以及企業服務等方面的突破性創新 使其可以為客 提供開放和靈活的選擇。IBM 對信任、透明、責任、包容和服務的 久彌新的承諾 是我們業務發展的基石。詢更多資料 請瀏覽 www.ibm.com/

傳媒 詢

郭韜 gguotao@cn.ibm.com

[1] 視覺模型 Vision Model 的基準測試結果可在 IBM技術文章 [《IBM Granite 3.2 推理、視覺、預測與更多應用》](#) 2025 年 2 月 26 日發布 中 。

[2] 指令模型 Instruct Model 的基準測試結果可在 IBM 技術文章 [《IBM Granite 3.2 推理、視覺、預測與更多應用》](#) 2025 年 2 月 26 日發布 中 。

[3] 推理擴展 Inference Scaling 的基準測試結果可在 IBM技術研究部落格 [《Granite 3.2 中的推理 利用推理擴展技術》](#) 2025 年 2 月 26 日發布 中 。

[4] [推理擴展技術在 Granite 3.2 中的應用](#) IBM 技術研究部落格 2025 年 2 月 26 日發布

SOURCE IBM Hong Kong

Additional assets available online:



<https://hongkong.newsroom.ibm.com/2025-03-04-IBM-Granite-3-2-AI>