

言語モデルを使った 異常検出 AI の準備

[ご購入はこちら](#)

佐藤 聖

ステップ1…OpenAIのAPIサービスの中から最適な VLMモデルを選ぶ

第1部では、VLMを使った異常検出AIを体験するために、Google ColabとOpenAIのAPIサービスを利用します。OpenAIのAPIサービスとは、OpenAIが開発した高性能なAIモデル(GPT-4o, DALL・E, Whisperなど)を、外部のアプリケーションやサービスに組み込むためのインターフェースです。

● OpenAI APIを使う理由

本格的なVLM実験には、環境構築が不要で手軽に始められるOpenAI APIがお勧めです。理由を次に示します。

▶ ローカル環境の場合

Hugging Faceからモデルをダウンロードできますが、業務レベルの性能には高性能なワークステーションが必要です。一般的なGPUではメモリ不足になりがちで、モデル量子化などの工夫が求められます。

▶ クラウド環境の場合

AWSなどのクラウドを利用すると、複数GPU構成が必要となり、コストがかさむ傾向があります。

▶ APIサービスの場合

ローカル環境の制約を受けずに高性能なVLMを利用できるOpenAI APIが、効率的で手軽な選択肢となります。

● Google Colabでモデルを実行することも可能だが…

今回は実験環境にGoogle Colabを利用し、モデルの実行にはOpenAIのAPIサービスを使用します。OpenAIのAPIサービスを利用すると、応答速度はColab上のGPTモデル実行に比べてかなり高速で、より低コストで利用できます。

Google Colabには、実験時の負担や非効率な要因があります。例えば、コンシューマ向けGPUを上回るデータ・センタ向けGPUを利用できますが、大規模モデルの処理にはメモリが不足し、利用できるGPUはときどきで変動するため、推論速度が遅くなりがちです。

さらに、Google Colabでのモデルのダウンロードには時間がかかり、ストレージやメモリの制限により大容量モデル・ファイルの扱いが困難です。ランタイムが停止するとモデルや画像ファイルが消失するため、その都度、再ダウンロードやアップロード、またはGoogleドライブへの退避が必要になる点も大きな負担です。

表1⁽²⁾ 候補モデルの比較 (2025年6月22日時点)

カテゴリ	推論モデル	フラッグシップ・チャット・モデル	コスト最適化モデル
概要	複雑な文脈や因果関係を理解し、高度な推論に対応する	高精度かつ汎用性の高い主力モデルで、あらゆる用途に対応する	軽量/高速/低コストで限定的な用途に向く
参考モデル	GPT-4o	GPT-4.1, GPT-4o	GPT-4.1 mini, GPT-4o mini
推論/知能(5段階評価, 主観)	3	4	3
コンテキスト・ウィンドウ	128,000	1,047,576	1,047,576
最大出力トークン	16,384	32,768	32,768
入力コスト(100万トークン)	250ドル	2.00ドル	0.15ドル
出力コスト(100万トークン)	10.00ドル	8.00ドル	0.60ドル