

# ローカルLLM補完技術の 導入ガイド

氏森 充

表1  
ローカルLLMの  
課題解消に役立  
つ解決策(補完技  
術)と特徴

| 技術名                         | 対応する主な課題                | 主な技術的特徴、概要                             | 主な用途・目的             |
|-----------------------------|-------------------------|----------------------------------------|---------------------|
| プロンプト・<br>エンジニアリング          | 運用、保守の負担/<br>モデル性能の制約   | 単発プロンプトの構造を工夫して精度や安定性を向上               | 推論、分類、<br>簡易対話      |
| RAG(検索拡張生成)                 | 知識ベースの鮮度と更新性/<br>拡張性の限界 | 外部知識の参照、ベクトル検索などを通じて文脈を補強、再学習不要        | ナレッジ活用、<br>FAQ、社内検索 |
| コンテキスト・<br>エンジニアリング         | 運用、保守の負担/<br>モデル性能の制約   | 会話、文脈の構成や履歴管理、外部連携、<br>情報優先度の管理などを含む   | 継続対話、<br>意思決定支援     |
| エージェント(Agent)               | 運用、保守の負担/<br>拡張性の限界     | 外部ツールを呼び出してタスク実行<br>(例：ブラウザ操作、API連携)   | タスク自動化・会<br>話型UI    |
| ファインチューニング<br>(Fine Tuning) | 知識ベースの更新/<br>モデル性能の制約   | 特定の業務や文体に応じた追加学習                       | 専門特化モデル             |
| LoRA/PEFT                   | モデル性能の制約/<br>運用、保守の負担   | 一部パラメータのみを微調整する効率的な<br>ファインチューニング      | リソース制約下の<br>適応      |
| 階層/構造化RAG <sup>注1</sup>     | 知識ベースの鮮度と更新性/<br>拡張性の限界 | 長文の論理構造を保持したまま検索・生成<br>を行うRAG          | 報告書・設計書・<br>法務文書対応  |
| 量子化/蒸留/枝刈り                  | モデル・サイズ、性能制約/<br>拡張性の限界 | 精度を維持しながらモデル・サイズや計算<br>量を削減し軽量化、高速化を実現 | ローカル実装、<br>組み込み用途   |

注1：HiRAG、RAPTOR、MC-indexing、ALoFTRAG

近年、トランスフォーマー・アーキテクチャを基盤とした大規模言語モデル(LLM)は飛躍的な進化を遂げ、業務効率化や自然言語インターフェースの構築など、多様な分野で急速に普及しています。当初はクラウドLLM<sup>注1</sup>が主流でしたが、PCや小型デバイスで動作するローカルLLMが登場し、クラウドLLMに匹敵する性能のものもあります。

ローカルLLMはインターネット接続を必要とせず、全ての処理をローカルで完結できるため、通信遅延やクラウド側の障害、ネットワークの不安定さ、外部への情報送信によるセキュリティ・リスクといった、クラウドLLMで生じやすい課題を回避できます。こうした特性が、近年ローカルLLMの採用が広がる大きな理由となっています。

一方で、ローカルLLMにはクラウドLLMとは異なる導入、運用上の課題も存在し、それらを克服するための工夫が不可欠です。

そこでローカルLLMを実用レベルで活用するため

に押さえておきたいポイントや代表的な課題を整理し、具体的な対処法(表1)を交えて解説します。

## ローカルLLMが注目される理由

### ● 理由①…クラウドLLMの構造的課題を解決できる

#### ▶ローカルLLMに注目される要因となった課題

クラウドLLMが広く使われる一方で、その運用上の課題がローカルLLMへの注目を加速させる要因となってきました。普及の背景となった4つの主要課題を説明します。

#### (1) データ秘匿性・プライバシー保護への要求

クラウドLLMは、入力データを外部サーバに送信して処理する必要があるため、機密情報や個人情報の漏えいリスクが常に指摘されてきました。

ローカルLLMは全ての処理を手元のデバイス内で完結できるため、外部送信を伴わず、プライバシー保護やコンプライアンス面で有力な選択肢となります。

#### (2) コスト構造の最適化ニーズ

クラウドLLMはAPIの呼び出しごとに料金が発生する従量課金型が多く、大規模運用では継続的なコス

注1：本稿では、クラウド上で提供される大規模言語モデルをクラウドLLM、PCなどのローカル・デバイス上で動作するモデルをローカルLLMと定義します。