

ローカルAIエージェントの可能性

—AIエージェント時代に加速する新たな選択肢—

2025年11月22日



安東 竜平

- ・2001年3月30日生まれ
- ・中学～大学まで駅伝
- ・2024/2/8 に Link AI を起業
- ・事業内容：
 - AIエージェント
 - AIアバターの開発
 - AI駆動開発研修など
- ・LinuC Open Network (Linuxコミュニティ) の運営

【秋元康×AI秋元康～AKB48新曲対決～】(日本テレビ特番)

音楽プロデューサー秋元康さんの思考 /過去作/見た目/声を学習した AI秋元康を開発いたしました。



イギリスの BCCに掲載された記事 ▶
<https://www.bbc.com/news/articles/c1kwvlyryjxo.amp>


音楽プロデューサー秋元康さんの
思考や過去作を学習した
AI秋元康の開発

思考だけでなく秋元康さんの
見た目、声も AIで再現

<https://www.itmedia.co.jp/aiplus/articles/2509/16/news091.html>

LinuC Open Networkとは

IT技術を活用する人の、成長と活躍を後押しする
「アウトプット共創型 エンジニアコミュニティ」



どんな人が参加している？

Linux等のオープンテクノロジーを活用するIT技術者として、
成長と活躍を目指す方々が参加しています。




より良いIT社会の実現へ

講演の目的

今後の「技術者としての成長」を加速

なぜ「ローカル AIエージェント」がテーマ？



**ローカル AIエージェント が実装できる
エンジニアは希少価値が高い**

※価値を高める＝成長としている

- ①なぜローカル AIエージェントが大事か理解する(メイン)
- ②何をしたらしいか考える

そもそもAIエージェントとは？

自律的に考え複数のツールを使いながら タスクを遂行するシステム

<https://manus.im/share/cQ3x59rgaiG76pAaee6vXJ?replay=1>

AIエージェントとは

Link AI

今まで

ブログ作り
たいな

- ・Googleで調べる
- ・ChatGPTと壁打ち
- ・midjourneyで生成



入稿



検索



骨子
生成



挿絵
生成




本文
執筆

AIエージェント

このエージェントと
やり取りができればいい

- ・検索ツールで調べる
- ・骨子を考える
- ・SVGで図解生成



分かりました！



検索



骨子
生成



挿絵
生成



本文
執筆



入稿

ツール選択に人が介入

ツール選択に人は介入なし

**なぜAIエージェントを実装できると
価値が高いのか**


まず前提…

技術者(エンジニア)の役割は

- ・人の仕事をより楽にしていく
- ・できることを拡張していく


※いろんな哲学はあると思いますが

システムがないときは人間大変




人間側の情報処理が大変
パフォーマンス発揮できない

システムがあると人間楽ちん だけどシステムが複雑になるという課題




AIによってデータの整理だけでなく 「思考」までできるようになった

Link AI




人は
「実行」に集中できる

エージェントによって 「実行」まで任せられるように



整理

なぜシステム開発するか？
→仕事を楽にする / できること増やす




AIエージェントの方が楽になる
かつ多くの人が使える



AIエージェントの開発が技術者の仕事になる
(将来はロボット?)

背景：AIエージェントの現在地

自律性アップ



<https://manus.im/app/cQ3x59rgaiG76pAaee6vXJ>

<https://notebooklm.google.com/notebook/ba1bd70b-40ff-4cde-b508-e7db608a7918>

リアルタイム性アップ

AIウィドレス



AI秘書



AIはどんどん「常時稼働」で便利になっていく

AIエージェント導入する際の課題

ランニングコストの高騰

セキュリティ課題は言わずもがな

AI実装をする際の問題点

(エージェント開発するなら、という話)

モデルの進化
(例: gpt-3.5→o3 Pro)




ツールの進化
(例: MCP/A2A)



複数並列実行
(例: Antigravity、カムイ)



さらなるコスト高騰



**エージェント化で便利になる一方
活用できる企業や用途が限定的に**

※ManusやGensparkなどクラウドのエージェントは入れられないところも多い
→セキュリティ面はもちろんだがコスト面もそう

解決策

||

ローカルAIエージェント

ローカルAIエージェントのメリット

運用コスト低価
(電気代で動く)

セキュリティ向上



AIエージェントの
活用企業/用途が広がる


懸念: ローカル LLMは精度低い
→ モデル精度は時間とともに向上していく





AI導入の論点は「コスト」のみ
になっていく？

ソリューション

モデル精度は時間とともに向上していく: Kimi K2の衝撃



テキストだけではない。
音声AIの衝撃 (Fish)




ソリューション

観点	Claude 3.7 Sonnet (API)	Tenstorrent QuietBox (ローカル)	補足
課金の仕組み	使ったトークン量に応じて変動 (\$18/100万token)	電気代のみ (稼働時間ベース)	ローカルは"何トークン使っても"コストは基本一定
1日50万tokenの場合 (月1,500万token)	約 ¥41,000 / 月	約 ¥29,000 / 月 (電気代のみ)	利用規模が大きくなるとAPIは高騰
利用量が増えると？	比例してコスト増加	ほぼ一定	"使えば使うほど高くなる"のがAPI、"ずっと使っても変わらない"
スケーラビリティ	△ コスト青天井	● 常時稼働・社内展開に強い	"全社導入"に進んだときの差が
初期導入のしやすさ	● 即導入可能	△ 初期構築あり (本体 + セットアップ)	APIはPoC向き、ローカルは運用最適化向き
長期運用コスト	✗ 利用量に応じて膨張	✓ 予測可能・定額運用	"持ち続けるAI"ならローカルが有利
向いている用途	小規模PoC 少人数の試験導入	常時稼働型エージェント 社内展開・情報統合型	拡張性が求められるほどローカルの価値が上がる

何から始めたらいいか

ローカルAIエージェントの実装が価値高い理由





普通のクラウドAIエージェントの実装より難しい

普通のクラウド AIエージェントの実装より難しい

実装
(インフラ)


活用
(効果出す)





ローカルAIエージェント始め方

普通のクラウド AIエージェントの実装より難しい



ローカルAIエージェントだと、ここも重要になるので大変

ローカルAIエージェント始め方

〇〇の用途で使うには、どんなスペックの
サーバーが必要なの？？

- ・オンプレミスって何？？
- ・GPUも必要？ LPUとか色々あるけど何？
- ・初期費用がかなりかかるけどクラウドの
エージェントじゃダメなの？

実装
(インフラ)

ビジネスサイドに
説明が大変
(基礎知識が必要)

そもそも基本的な
コンピュータの知識
ないと理解できない

ローカルAIエージェントだと、ここも重要になるので大変

ローカルAIエージェント始め方

○○の用途で使うには、どんなスペックの
サーバーが必要なの？？
・オンプレミスって何？？
・GPUも必要？LPUとか色々あるけど何？
・初期費用がかなりかかるけどクラウドの
エージェントじゃダメなの？


実装 (インフラ)

ビジネスサイドに
説明が大変
(基礎知識が必要)

そもそも基本的な
コンピュータの知識
ないと理解できない

コンピュータの知識/ローカルLLMの知識/ビジネスインパクトなど活用の知識
これらの総合格闘技が必要なのでローカルLLM実装は難しい
▶これができる人材は「希少価値が高い！」

垂直統合スキル：ローカルLLM実装の希少価値



LLMローカル推論：目的別 GPU 選択マップ




前提条件 (Q4量子化, 4K-8K ctx, 単一GPU)

⚠ 注意: 長コンテキスト(128K+)はVRAM 2-4倍消費




モデル規模 (パラメータ数 & 必要VRAM目安)



詳細
はこちら

Zone 1

入門～標準クラス
(7B-14B) / VRAM ~8GB



RTX 3060/4060系
(~12GB)
RTX 4070系
(~16GB)

手軽に試す
価格: 安価

Zone 2

実用～ハイエンドクラス
(32B前後) / VRAM 15-20GB



RTX 4090 (24GB)
TensorCore Blackhole p100a (28GB)
RTX 5090 (32GB)

32Bの鉄板・
⚠ VRAMコスパ◎, 32B余裕・将来性◎
現実的ライン 玄人向け(ソフト難) 価格: ~40万円+
価格: ~40万円 価格: ~15万円

Zone 3

ガチ勢・ワークステーション
(70B dense) / VRAM 33-40GB+



RTX Pro 5000 (48/72GB)
RTX Pro 6000 (96GB)

自宅で70B常用
価格: 高価
⚠ 電源・冷却シビア
オンプレ開発・100B級MoE
価格: 超高価 (~150万円)

Zone 4

データセンター・超巨大モデル
(MoE 200B~, マルチGPU前提)



NVIDIA H100 (80GB)
AMD Instinct MI300X (192GB)
Intel Gaudi 3 (128GB)

業務用・クラスタ必須
価格: ASK (数百万円/基~)

32Bの壁 (ここからガチ勢)

結論: 「どのハードを買うべき?」

1 「32BをPCで快適に」



RTX 4090が最低ライン。余裕なら5090。p100aは挑戦者向け。


2 「70Bもローカルで」



RTX Pro 48GB以上が必要。導入ハードル高。

※価格・仕様は2025年時点の目安であり変動します。

ローカルLLMを使えるインターフェースとなるAIサービス



Dify



ただしセットアップや
ハードウェアとの相性など
考慮することが多い

実際にローカルLLM活用を進めていく現実的な方法


ChatGPT等を活用して進める



ユースケースを決める



必要なローカルLLMを
リサーチ



必要なハー
ドウェアを
リサーチ



AIに聞きな
がら実装

LIONに入る

 LinuC Open Network

LIONに
入って！




or

この希少価値の高いローカル LLM人材を育成するために LiONでは
「ローカルLLM構築ガイドさん開発プロジェクト」を始動




必要知識 /事例/活用法を体系化



体系化したガイドラインで「AIガイドさん」を開発



頼れる相棒！ローカルLLMガイドさん




知識を力に変え、AIを使いこなす側へ。
LIONのローカルLLMガイドが支援します。



一緒に次世代の
「人材育成 AIガイドさん」を開発しましよう！


この実績/経験はいろんなところで
活用できるはずです！



LiONでの取り組み



入ってくれたら、 NotebookLMで一瞬で作ったローカル LLMガイド



私が想いを込めて手作業で作った今日の資料



も手に入れます

従来の仕事のやり方が大きく変わるため、今まで学んできた常識を捨てよう



開発者イベントに
開発者以外の招待者
開発≠エンジニアがやるもの

AI前提の
ワークフロー構築
の必要性

ローカルAIエージェント
ぜひお試し下さい。