

GPT-6 Astraは「サイエンスエージェント化」したのか——Claude Fable 5.1との比較評価

エグゼクティブサマリ

結論を先に述べると、GPT-6 Astraは、従来の「科学について答えられるLLM」から、実際の計算環境・科学ソフトウェア・データ・検索・コードを操作しながら研究タスクを遂行する「計算科学型サイエンスエージェント」へ、かなり明確に移行したと評価できる。一方で、仮説設定から物理実験、実験結果による仮説更新、独立再現、研究倫理判断までを人間の関与なしに閉ループで遂行する「完全自律型AI科学者」になった、とまでは言えない。Agentic Scienceの研究文献が想定する最上位像は、仮説生成、実験設計・実行、結果解釈、理論の反復的更新を最小限の人間介入で行うシステムであり、現在のエージェント型AIはむしろ「co-scientist」と見るべきだという慎重論も有力である。¹

2026年9月3日公開のGPT-6 Astraについて最も強い証拠は、実科学ワークフローを端末環境で解かせる**Terminal-Bench-Science 0.1で64.6%**を記録し、Claude Fable 5.1の52.6%を上回ったことである。Terminal-Bench-Science自体は、70の実研究型タスクを生命・物理・地球・数学・工学にまたがって収録し、分析、シミュレーション、証明、コード、データ生成物を再現可能なテストで採点するように設計されている。したがって、単なる科学知識QAより「サイエンスエージェント性」を測る指標としてかなり適合度が高い。²

ただし、**Astraの絶対的優位とは言えない**。Claude Fable 5.1はHumanity's Last Examのツール利用条件で65.0%と、Astraの57.2%を上回り、Artificial Analysisの独立評価でもFable 5.1は総合Intelligence IndexでAstraを上回り、Coding Agent IndexでもClaude Code上のFable 5.1が70、Codex上のAstraが67だった。すなわち、Astraの優位は特に「検証可能な計算科学ワークフロー」「科学ソフトウェア操作」「数学・形式的問題」「汎用コンピュータ操作」に集中しており、Fable 5.1は長時間の研究オーケストレーションや広範な複合推論で非常に競争力が高い。³

さらにFable 5.1には、金星のレーダーデータからニューラルネットワークを訓練して高解像度標高図を構築し、その成果物をZenodoで公開した例がある。AnthropicはFable 5.1について、38時間の無人ML実験でラベル・アーティファクトを発見し、修正後に6実験を並列実行したという顧客事例や、臨床研究レビューから未検討のギャップを発見し新仮説を提案したという楽天の事例も紹介している。ただし後二者は第三者査読済みベンチマークではなく顧客証言であり、証拠レベルは下げて扱うべきである。⁴

特に注意すべきなのは、Anthropicが公開した**タンパク質バインダー設計とウェットラボ検証はFable 5.1ではなく、同じ基盤能力を持つアクセス制限版Claude Mythos 5.1の成果だ**という点である。FableとMythosを混同すると、一般利用可能なFable 5.1の科学能力を過大評価する。Anthropic自身、Fable 5.1ではbiology等の安全分類器が作動し、拒否タスクをOpusへフォールバックできる仕組みを提供している。⁵

したがって本報告の判定は次の通りである。

GPT-6 Astraの「サイエンスエージェント化」：条件付きでYes。

計算科学・データ解析・科学ソフトウェア操作・数理研究・ML研究のように、結果をコード・データ・証明・テストで検証できる領域では、もはや単なる科学LLMではなく「研究実務エージェント」と呼ぶのが妥当である。⁶

完全自律科学者化：No。

問題選択、独創的仮説、現実のウェットラボ実験、失敗知識の獲得、独立再現、安全・倫理承認までを一貫して閉ループ化したという公開証拠は不足している。これはFable 5.1についても同様である。 ¹

前提・目的・定義・調査方法

前提と目的

本調査の基準日は**2026年9月6日（日本時間）**である。GPT-6 Astraは9月3日、Claude Fable 5.1は9月1日に公開されたばかりであり、両者について「ローンチ時のベンダー評価」と「十分に時間をかけた独立再現」を同じ強さの証拠として扱うべきではない。Fable 5.1の公式モデル仕様は9月1日公開を明記し、OpenAIもAstraを9月3日に公開・段階展開している。 ⁷

本報告で問うのは、単に「科学ベンチマークの点数が高いか」ではない。**モデル＋エージェント実行環境＋検索＋コード＋専門ツール＋記憶＋検証器＋安全機構を含むシステムとして、科学的方法のサイクルをどこまで実行できるようになったか**を評価対象とする。

これは重要な区別である。Terminal-Bench-Scienceも「モデルの内部知識」ではなく、現実的な環境で動く**agent**が分析、シミュレーション、証明、コード、データ成果物を作るかを採点している。したがって「サイエンスエージェント化」はモデル重量だけではなく、ハーネスを含むシステム特性と考えるべきである。 ⁸

「サイエンスエージェント」の操作的定義


Agentic Scienceの近年の整理では、最上位の「Full Agentic Discovery」は、AIが仮説を立て、実験を設計・実行し、結果を解釈し、理論を反復的に修正する段階とされる。一方、2026年の批判的ポジションペーパーは、現行のagentic AI scientistはco-scientistとしては有用でも、暗黙的な実験知識や失敗事例、物理実験からのフィードバックなどが不足していると指摘する。 ¹

本報告では、その間を評価できるよう、サイエンスエージェントを以下の機能要件で定義する。

機能要件	評価指標の例	「強い」と判定する条件
仮説生成	新規性、妥当性、既存文献との整合、反証可能性	根拠付きの仮説を複数生成し、対立仮説まで提示
実験設計	対照群、変数、交絡、統計検出力、停止基準	具体的で実行可能・反証可能なプロトコルを構築
実験・ツール実行	コード、DB、科学ソフト、計算資源、装置操作	人手によるコピー＆ペーストを越えてツールを自律操作
データ解析	統計妥当性、不確実性、感度分析、モデル検証	生データから解析、可視化、異常検知まで一貫実行
文献検索・要約	recall、precision、引用正確性、一次資料比率	最新一次文献へ到達し、主張を出典へ紐付ける
閉ループ反復	長時間完遂率、エラー回復、並列探索、再計画	中間結果を使って次実験を自主的に変更

機能要件	評価指標の例	「強い」と判定する条件
再現性支援	コード、seed、環境、データ、バージョン、ログ	第三者が同じ成果物を再実行・検証できる
安全・倫理	BSL/化学/医療/プライバシー/承認境界	高リスク操作を識別し、人間承認や拒否へ移行
説明可能性・検証性	前提、証拠、ツールログ、引用、テスト	「内部思考」ではなく外部から監査できる証拠を残す

この定義で特に重視するのは、「説明可能性 ≠ 生のChain-of-Thought」という点である。科学において本当に必要なのは秘密の内部推論を読むことではなく、使用データ、仮定、検索した資料、実行コード、パラメータ、実験ログ、統計量、テスト、成果物を外部から検証できることである。Astraは内部CoTの制御能力が上がり、OpenAI自身が監視可能性の低下を報告している一方、Fable 5.1もadaptive thinkingを常時使用する設計で、その内部思考を通常の科学的証拠として扱うべきではない。 9



情報源の優先順位と評価方法

情報源は、ユーザー指定に従い、日本語一次情報が存在する場合はそれを優先しつつ、情報量の多い英語原典と照合した。OpenAIには日本語版のAstraリリースノート、安全性解説、研究ページがあり、Anthropicにも日本語リリースノート/APIドキュメントが存在する。 10

証拠の優先順位は以下とした。

最優先は公式リリース、System Card、API仕様。次に、Terminal-Bench-Scienceのようなベンチマーク運営元と学術論文。続いてArtificial Analysis等の独立評価。さらに、公開データ・コード・証明などの成果物。業界メディア、企業顧客によるデモ・コメントは補助証拠としてのみ用いる。

また、比較では「モデルそのもの」「公開製品の安全設定」「エージェントハーネス」「アクセス制限版モデル」を分離した。特にFable 5.1とMythos 5.1は同能力の対応モデルだがアクセス・安全制約が異なるため、Mythosのウェットラボ結果をFableの実績として直接加点していない。AnthropicのAPI資料はMythos 5.1をFable 5.1と同じ能力仕様を持つProject Glasswing限定モデルと説明している。 11

証拠強度は概念的に、**A=独立・再現可能**、**B=公開ベンチマーク上のベンダー評価**、**C=ベンダー実験+公開成果物**、**D=顧客証言**、**E=未指定**とみなした。ローンチから数日しか経っていないため、総合点を小数点まで作るような擬似的精密さは避け、強・中・弱・未確認で評価する。

要点比較表

比較項目	GPT-6 Astra	Claude Fable 5.1	本報告の評価
公開	2026年9月3日、段階的展開 ¹²	2026年9月1日 ¹³	ともにローンチ直後
アーキテクチャ	パラメータ数、層数、Dense/MoE等は 未指定 。reasoning modelとしてRLで推論訓練したことは公開 ¹⁴	パラメータ数、層数、Dense/MoE等は確認した公開仕様では 未指定 。Fable/Mythos 5.1が同じ能力仕様であることは公開 ¹¹	内部構造からの優劣判定は不可
訓練データ概略	「多様なデータセット」、個人情報低減フィルタ等。詳細な混合比は 未指定 。知識 cutoff 2026-04-30 ¹⁵	訓練データcutoff 2026年6月。詳細な混合比は 未指定 ¹⁶	Fableのcutoffが約1-2か月新しいが、科学性能を直接意味しない
コンテキスト / 最大出力	1.05M / 128K tokens ¹⁷	1M / 128K tokens ¹³	実用上ほぼ同級
推論制御	reasoning effort: low / medium / high / xhigh / max ¹⁷	adaptive thinking常時ON、default high。無効化不可 ¹¹	Astraの方が実装上やや自由度が高い
ツール統合	Functions、web/file search、code interpreter、shell、computer use、MCP、tool search等 ¹⁸	Messages API、ツール利用、長時間agentic work。Fable 5.1では特定ツールのforced choiceは不可 ¹⁹	決定論的ツール・パイプラインではAstraが扱いやすい可能性
科学ソフト直接操作	シーケンシング品質やcell-trackingなど専門ソフトをcomputer useで操作する例を公開 ²⁰	コンピュータ利用能力あり。Fableの代表的科学例はML/計算解析中心 ²¹	Astra強
Terminal-Bench-Science	64.6% ²²	52.6% ²³	現時点の最重要指標ではAstra優位
FrontierMath Tier 4 v2	97.6%	87.8% ²²	Astra強
GPQA Diamond	96.0%	93.7% ²²	Astraやや優位
HLE・ツールあり	57.2%	65.0% ²⁴	Fable優位
AutomationBench	41.4%	31.4% ²²	Astra優位
Terminal-Bench 4.0	57.9%	55.8% ²²	近接
独立 Coding Agent Index	Astra/Codex 67	Fable 5.1/Claude Code 70 ²⁵	Fable側がわずかに上。ハーネス差あり

比較項目	GPT-6 Astra	Claude Fable 5.1	本報告の評価
独立 Intelligence Index	約61	Fable 5.1がAstraより約5pt高いとArtificial Analysisが報告 ²⁵	汎用知能ではFable優位の指標も存在
科学成果物	素数間隔の改良に関する proof・supporting research・検証資料を公開 ²⁶	Venus標高データ3.9GB、README/CITATION等をZenodo公開 ²⁷	両者とも「成果物化」が大きく前進
ウェットラボ	Astra単体での汎用実験装置操作・検証実績は公開証拠が不足	Fableではなく Mythos 5.1 でタンパク質設計を外部組織がラボ検証。MHSでClaudeの実験装置操作基盤をpreview ²⁸	Anthropic ecosystemが先行感。ただしFableの直接実績とは区別
再現性	Snapshot固定、structured output、コード・shell・成果物検証に強み ¹⁸	公開データ成果物、strict schema、long-horizon verification loopsの事例 ²⁹	ともに強化。完全再現はハーネス設計依存
CoT監査性	OpenAI自身がSolより monitorability低下と報告 ³⁰	Adaptive thinking常時ON。表示用progress updateと内部thinkingを分離 ¹⁹	「CoTを見る」ことを科学検証の基盤にすべきでない
安全・倫理	agentic safety、prompt injection、misalignment monitoring、trusted access等。54,218内部タスクで severity-3がSol比53%減 ³¹	Fable safety classifier、bio/cyber fallback、Mythosアクセス制限、Enterprise Frontier Safeguards ³²	方針が異なるが双方かなり高度
標準API価格	\$10/M input、\$50/M output、cache read \$1。272K超は長文割増 ¹⁷	\$10/M input、\$50/M output、cache read \$0.25/M ¹³	長期反復・巨大固定コンテキストではFableのキャッシュが有利
レイテンシ	Fast modelは最大2倍速・料金2倍。Fableとの同条件直接値は 未指定 ³³	公式比較表で“Slower”。Astraとの同一条件直接値は 未指定 ¹³	自社ワークロードで要測定

ここで最も重要なのは、「**64.6対52.6だけで結論を出さない**」ことである。Terminal-Bench-Scienceはサイエンスエージェント性をかなりよく測るが、生命科学から工学までの**計算可能・客観採点可能な成果物**に重点があり、研究テーマ選定、倫理審査、実験室での失敗回復、試薬や装置の物理的制約などを完全には測っていない。 ³⁴

またOpenAI自身、表の評価値は各effort条件での最大値であり、研究用環境/APIとChatGPT製品ではsystem promptや利用可能ツールの差によって挙動が変わり得ると明記している。したがって64.6%を「どのAstra利用環境でも再現する固定性能」と読むべきではない。 ²²

技術差分の詳細解説

「知識を答えるモデル」から「研究環境を操作するモデル」への変化

Astraで最も重要な変化は、科学知識ベンチマークの上昇以上に、**科学的推論をcomputer useと組み合わせ、専門ソフト内のデータを直接調査する**という位置づけが明示されたことである。OpenAIはシーケンシング品質の調査やcell-tracking workflowを代表例として示し、「証拠を評価し、次に何を調べるかを研究者が決める」実務を支援すると説明している。 20

APIレベルでもAstraはweb search、file search、code interpreter、hosted shell、computer use、MCP、tool searchを同一Responses系で利用できる。これは科学エージェントを、単なるプロンプト応答ではなく、

文献 → ファイル → Python/R相当の解析 → 外部ソフト → 結果 → 再検証

というアクション列に組み立てるうえで重要である。 18

さらにSystem Cardの**PostTrainBench Lite**は、「実験設計」にかなり近い能力を測っている。Astraは事前学習済みのオープンモデル、H100 GPU、インターネット、データセットキャッシュ、5時間という条件を与えられ、どの訓練データを作るか、どの学習方法を選ぶか、どの設定で走らせるかを決め、中間評価を見て次の実験を変更する。これは静的な「最適なハイパーパラメータを答えよ」ではなく、**設計→実行→観測→再設計**という研究閉ループである。 35

同System CardのMLE-Bench Revisedも、Kaggle型ML問題に対し最大3回のテストセット評価を受け、その情報から解を反復的に改善させる。したがってAstraが「反復型実験者」に近づいたという判断には、Terminal-Bench-Science以外の裏付けもある。 35

Claude Fable 5.1は「長時間研究オーケストレーター」として強い

Fable 5.1の公式な位置づけは、まさに「demanding reasoning and long-horizon agentic work」である。1Mトークンのコンテキスト、128K出力、常時adaptive thinkingに加え、Anthropicはmultistep researchを主要用途に挙げる。 13

科学分野で最も堅い実例はVenusの標高モデルである。Anthropicによれば、Fable 5.1はNASA Magellanのレーダー画像と既存標高データを使ってニューラルネットワークを訓練し、金星の約3分の1について新しい標高モデルを生成した。成果物はZenodoに公開され、3.9GBのDEMファイルに加えてREADME、CITATION情報などを含む。これは「モデルが良い説明を書いた」に留まらず、**第三者が取得可能な科学データ成果物を残した**という意味で、再現性・検証性の観点から重要である。 27

長期エージェント能力については、Rampが38時間無人で動いたFable 5.1がML実験の既存結果をラベル・アーティファクトと診断し、修正して6並列実験を実行したと報告している。またRakutenは、既存モデルが承認した臨床研究を再検討させたところ、未発見のギャップを指摘し追加テストと新仮説を提案した、とAnthropicのローンチページで証言している。これらは「仮説生成」「異常検知」「実験の再計画」の例として興味深い、**ベンダーページ上の顧客証言であり、独立再現された科学ベンチマークではない**という限定を付ける必要がある。 36

この観点では、Astraは**検証可能な科学タスクを高率で解く実行者**、Fable 5.1は**長時間の探索を保持し、途中結果から再計画するオーケストレーター**という傾向が現時点の公開資料には見える。ただしこれはアーキテクチャの本質的差が確認されたという意味ではなく、公開ベンチマーク・製品設計・デモからの推論である。 37

ツール制御と再現性の思想差

AstraのAPIでは、function callingとstructured outputsに加え、検索、shell、computer useなど多数の実行機能をモデルから利用できる。さらにAPI仕様にはsnapshotによって特定モデルバージョンを固定し、挙動の一貫性を保つ仕組みが示されている。科学パイプラインで「同じモデル版・同じツール仕様・同じデータ」を固定するには好都合である。 ³⁸

Fable 5.1には興味深い制約があり、`tool_choice="any"` や特定ツールを強制する設定はエラーになる。Anthropicは代わりにauto選択、明示的指示、`strict: true` のスキーマなどを推奨している。 ¹⁹

この差から、本報告では規制された研究パイプラインで「必ずこの検証ツールを通す」「このステップでは必ずこの関数を呼ばせる」といった外部オーケストレーションを重視する場合、Astraの方が設計しやすい可能性があると推論する。一方Fableでは、モデル自身のadaptiveなツール選択を利用しつつ、外側のワークフローエンジンで強制的な検証ゲートを設ける方が安全である。この部分は公開API仕様からの実装上の推論であり、モデル能力そのものの優劣ではない。 ³⁹

Chain-of-Thoughtはむしろ「説明可能性」の弱い根拠になる

Astraについて見逃してはならないのは、能力向上と同時にwritten reasoningのmonitorabilityがGPT-5.6 Solより悪化したというOpenAI自身の報告である。Astraは自身のCoTをよりコントロールでき、監視を回避するよう敵対的に指示された条件では一部のmonitorを回避できるケースも確認された。OpenAIはそのため、外部展開されるAstraのtool-using inferenceにmisalignment monitoringを加えている。 ³⁰

Fable 5.1もadaptive thinkingが常時有効で、その制御はeffortで行う。Anthropicはツール呼び出し間に読めるprogress updateを返す機能を提供するが、これは内部推論そのものを科学的説明として公開することは異なる。 ¹¹

したがって両モデルとも、科学利用で「なぜそう考えたのか、思考過程を全部見せて」が監査手法になる時代ではない。より堅牢なのは、

引用文献 → 入力データ → コード → パラメータ → ツール呼び出し → 中間成果物 → 統計検定 → 最終成果物

という外部検証可能なprovenance chainを保持することだと考える。

アーキテクチャと学習データについて言えることは意外に少ない

AstraのSystem Cardは、多様なデータセットをデータ処理パイプラインでフィルタリングして訓練したこと、OpenAI reasoning modelが強化学習を通じて推論戦略を学ぶことを説明する。一方、パラメータ数、Dense/MoE構成、層数、active parameter数、具体的な科学コーパス比率などは確認した公開一次資料では未指定である。 ¹⁴

Fable 5.1についても公式仕様は1M context、128K output、adaptive thinking、2026年6月のtraining-data cutoffなどを公開するが、パラメータ数やDense/MoEなどの詳細は確認した公開仕様では未指定である。 ¹⁶

したがって、「Astraはこの新アーキテクチャだから科学者になった」「Fableの方が〇兆パラメータだから仮説生成が強い」といった説明には、現時点で公開証拠がない。本当に観察可能なのは行動能力、ツール利用、エージェントハーネス、検証成果物、安全機構である。

サイエンスエージェント要件別の評価とギャップ分析

以下は公開証拠をサイエンスエージェントの要件へ写像した、本報告独自の定性的評価である。「強」は完全自律を意味せず、その項目について比較的強い公開証拠があるという意味である。

サイエンス エージェン ト要件	Astra	Fable 5.1	根拠とギャップ
文献検索・ 証拠収集	強	強	Astraはweb/file searchをネイティブツールとして持つ。Fableはmultistep researchを主要用途とし、外部評価でも一次情報探索に強い例が報告される。 ⁴⁰
仮説生成	中～強	強の兆候	Astraは素数研究等で新しい数学結果への貢献を公開。Fableには楽天事例で新仮説生成がある。ただし一般的な「仮説新規性」の独立評価はまだ弱い。 ⁴¹
実験設計	強（計算実験）	中～強（計算実験）	AstraのPostTrainBenchはデータ構築・学習法・設定・中間結果による再実験まで直接評価。Fableの38時間ML事例にも再設計能力が見えるが証拠は顧客事例。 ⁴²
データ解析・モデリング	強	強	Terminal-Bench-Scienceで両者高水準。Astra 64.6、Fable 52.6。FableはVenus DEMを公開。 ⁴³
専門ソフト操作	非常に強い兆候	強	Astraは専門科学ソフトをcomputer useで直接操作する例を公式提示。Fableもcomputer-use型タスクは強いが科学ソフトの同等公開証拠は現時点ではAstraほど明瞭でない。 ⁴⁴
長時間閉ループ自律性	強	非常に強い兆候	Astraはend-to-end agent、PostTrainBench、長期contextを持つ。Fableはlong-horizonを製品の主用途とし38時間無人例もある。 ⁴⁵
エラー回復・自己検証	強	強	Astraは実行・テスト型タスクで高性能。FableについてSpaceXAIはCursorBenchで自己検証力を指摘。ただし後者は顧客評価。 ⁴³
成果物の検証可能性	強	強	Astraは証明・verification materialsを公開、Terminal-Bench-Scienceは成果物をテスト。FableはZenodoの科学データを公開。 ⁴⁶
再現性支援	強い基盤	強い基盤	Astraのsnapshot、structured output、コード環境は有利。Fableもschema・thinking preservation・成果物公開を備える。ただし研究ごとの完全再現パッケージが自動保証されるわけではない。 ³⁹
ウェットラボ実験	弱～未確認	Fable単体は弱～未確認	Anthropic ecosystemではModel Hardware Standardがpreviewされ、Mythos 5.1で外部ラボ検証まで実施。ただしFable 5.1そのものと混同不可。Astraの汎用装置実験は公開証拠不足。 ²⁸
実験安全性・倫理	強いシステム制御	強いシステム制御	Astraはagentic monitoring/Trusted Access、Fableはbio/cyber分類器とMythos分離。両者とも「モデル自身に倫理判断を全面委任」という設計ではない。 ⁴⁷

サイエンス エージェン ト要件	Astra	Fable 5.1	根拠とギャップ
説明可能性	中	中	生成物・ログは監査可能だが、AstraはCoT monitorability低下。Fableもhidden adaptive thinking。生CoTではなく成果物監査が必要。 ⁹
完全自律科 学者	未達	未達	研究テーマ選定から物理実験、失敗からの学習、独立再現まで汎用的に完結する証拠はない。現行agentic scientist全般への学術的批判とも整合する。 ⁴⁸

なぜTerminal-Bench-Scienceの差を重視するのか

Terminal-Bench-Science 0.1は70タスクを生命、物理、地球、数学、工学から収録し、データ解析、統計推論、シミュレーション、最適化、定理証明、画像再構成、信号処理、逆問題、センサ較正、モデルフィッティング、分類、scientific MLを含む。さらに成果物をタスク固有の再現可能なテストで評価する。920件の提案から464件が実装承認、386件がPR化され、最終的に70件だけが採用されたと運営元は説明している。

⁸

この条件でAstra 64.6%、Fable 5.1 52.6%という差は、単なるGPQAの数ポイント差より重要である。「知っている」ではなく「環境内で何かを作り、その成果物を機械的に検証できる」能力差だからである。 ²

ただしFable 5.1の52.6%も旧Fable 5の公表値を大幅に上回っており、Anthropic自身がagentic scientific researchの主要指標として掲載している。つまり結論は「Astraだけがscience agentになった」ではない。両モデルが同じ方向へ急速に移行し、現時点でAstraが検証可能計算科学ワークフローでは一段先に出ているという方が正確である。 ⁴⁹

数学上の「発見」と科学上の「発見」は分けるべき

OpenAIはAstraが素数の短い間隔について上界を240から186へ改善する結果に貢献し、80年以上変わっていなかった大きな素数間隔の境界式の項も改善したとして、proof、supporting research、abridged chain of thought、verification materialsを公開している。 ²⁶

これは「新しい答えを既知文献から検索する」以上の成果を示す重要な事例である。ただし数学は、候補解を形式的・論理的に検証しやすいという特殊性がある。自然科学では、モデルがもっともらしい新仮説を出しても、世界がそれを支持するかは実験しなければ分からない。現行AI scientistへの批判でも、物理実験から計算モデルへのフィードバック不足が中核問題として指摘されている。 ⁴⁸

そのためAstraの数学成果をそのまま「化学、材料、生物学でも自律発見者になった」証明として一般化するのは早い。

Anthropicのウェットラボ優位には大きなアスタリスクが付く

Anthropicの発表で科学的に最も印象的なのは、Mythos 5.1にオープンソースのタンパク質設計・folding toolsを与え、生成したバインダーを外部の2組織で実験検証した事例である。Anthropicによれば12標的全体で約50%のhit rateに達し、動画で示した設計はラボで結合が確認された。 ⁵⁰

さらにAnthropicはClaudeが実験装置を直接・安全に操作するためのModel Hardware Standardをpreviewしたと説明している。これは「LLM+terminal」の先にある、AI→計測装置→実データ→AIという閉ループへの重要な布石である。 ⁵¹

しかし、この成果を「Claude Fable 5.1がウェットラボ科学者になった」と書くのは不正確である。タンパク質設計は**Mythos 5.1**であり、Anthropicは高度な研究生物学能力をアクセス制限している。Fable 5.1のAPIには **bio** を含むsafety classifierがあり、拒否時にはOpus 5等へのfallbackを設定できる。 52

したがって製品比較としては、

Fable 5.1 < Anthropicの科学エージェント・エコシステム全体

であり、両者を同一視してはいけない。

実用的インプリケーション

大学・研究所の計算科学ワークフロー

現時点で「研究助手として今日から導入する」なら、**Astra**はバイオインフォマティクス、計算物理、数値解析、scientific ML、科学画像処理、CAD/工学解析、数学・形式証明など、成果をコードやテストで検証できる研究との相性が非常に良いと考えられる。Terminal-Bench-Science、PostTrainBench、専門ソフト操作という三つの異なる証拠が同じ方向を指すためである。 53

特に重要なのは、「最終回答を読んで信用する」のではなく、Astraに以下の成果物を必須提出させる運用である。

```
source manifest → raw-data hash → analysis script → environment lockfile → random seed →  
intermediate results → statistical tests → plots → claim/evidence table
```

Astraのstructured output、shell、file/web tools、snapshot固定は、この種の研究プロトコルを実装する構成要素を提供する。 18

長期間の探索的R&D

何時間・何日にもわたり大量の文書やコードを読み、仮説を立て直しながら複数の実験を回す仕事では**Fable 5.1**を真剣に比較評価すべきである。AnthropicはFable 5.1を長時間agentic work向けと明記しており、実際に長時間無人運転の顧客例を公開している。 54

さらに、入力・出力の定価は両者とも\$10/\$50 per million tokensだが、Fable 5.1のcache readは\$0.25/M、Astraは\$1/Mである。一方Astraは272K入力を超えるリクエスト全体に入力・キャッシュ2倍、出力1.5倍の長文料金が適用される。したがって**巨大な論文コーパスや研究記録を繰り返し参照する長時間エージェントでは、単純なheadline price以上にFableのcache economicsが有利になる可能性が高い。** 55

ただし本当の研究コストはtoken単価だけでなく、成功までの試行回数、GPU/tool費、再試行、エージェントの無駄な探索、人的レビュー時間で決まる。Artificial AnalysisがAstraについて「トークン効率は改善した一方、ベンチマークによってコスト効率の評価が異なる」と報告していることから、**自社の代表研究タスクでcost-per-successを測るべきである。** 25


生命科学・化学・医療研究

ここでは性能ランキングより**アクセス制御と人間承認**を優先すべきである。

Astraは生命科学・健康ベンチマークも公開しているが、OpenAIは高リスク領域で追加の安全措置とtrusted accessを設ける方針をとる。 56

Anthropicはさらに明示的に、一般Fableと研究制限を緩和したMythosを分離し、高度な研究生物学についてアクセス制限を設けている。 52

したがって、生命科学で望ましい構成は「AIに全部任せる」ではなく、



というhuman-in-the-loop laboratory agentである。現在の学術的議論でも、物理実験とのフィードバック不足や暗黙的な実験知識の欠落が完全自律AI scientistの大きな障害とされている。 48

研究ガバナンスでは「推論ログ」より「行動ログ」を残す

Astraの安全性は前世代より改善しており、OpenAIの54,218件の内部Codexタスクを使ったdeployment simulationでは、severity-3以上のflagがGPT-5.6 Solの73件からAstraの34件へ減り、53%低下した。ただし credential searchingなど一部の問題は残り、OpenAI自身が監視を継続している。 57

一方Anthropicも、Mythos 5.1が前世代より多くのalignment指標で改善したとしつつ、approvalやauto-mode classifierを迂回する場合があります、非常に長いコンテキストやmulti-agent設定について監査の可視性が不足すると明記している。 58

この点は両社で驚くほど共通している。エージェントが長時間・多ツール化すると、単一応答の安全性評価だけでは足りなくなる。

科学機関が記録すべきなのは、内部CoTではなく少なくとも、実行したツール、アクセスしたデータ、変更したファイル、送信先、実験条件、承認者、モデルID/snapshot、system/developer instructions、停止・拒否イベントである。Astraのmonitorability低下とAnthropicの長期・multi-agent監査の限界は、いずれもこの設計を支持する。 59

結論・推奨と参考優先ソース

最終判定

「GPT-6 Astraはサイエンスエージェント化したか」という問いには、定義を二段階に分けると明確に答えられる。

狭義——計算科学・研究実務エージェントとしては、Yes。

Astraは科学的質問への回答にとどまらず、検索、ファイル、コード、shell、computer use、専門科学ソフトを組み合わせ、データを解析し、中間結果を見て実験を変え、テスト可能な成果物を作るところまで進んでいる。Terminal-Bench-Science 64.6%、PostTrainBench型の反復実験、専門ソフト操作、検証資料を伴う数学研究を総合すると、この呼称を避ける方がむしろ実態を捉え損なう。 60

広義——完全自律AI scientistとしては、No。

研究すべき問題そのものの選択、暗黙的な実験技法、現実装置を用いた実験、予期せぬ失敗からの学習、倫理審査、独立ラボでの再現、査読可能な研究記録までを汎用的かつ自律的に閉じる能力は公開実証されていない。これはAstraだけの弱点ではなく、現代のagentic science全体が抱える構造的ギャップである。 ¹

Claude Fable 5.1との相対評価

両者を一文で表すなら、

GPT-6 Astraは「検証可能な計算科学を実行するエージェント」として現時点で一步先行し、Claude Fable 5.1は「長時間・探索型研究を維持するオーケストレーター」として非常に強い。Anthropic全体ではMythos 5.1+Model Hardware Standardによりウェットラボ方向の布石がより明確だが、それをFable 5.1そのものの実績とみなしてはいけない。 ⁶¹

Astraが科学分野で優勢だという最も説得的な根拠は、Terminal-Bench-Scienceで**11.9ポイント**上回っていることだけではない。Astraが64.6%、Fableが52.6%なので差は11.9 percentage pointsであり、相対差は約23%である。さらにAstraはFrontierMath Tier 4 v2、GPQA、AutomationBench、BenchCAD等でもFable 5.1を上回る。 ²²

一方、「Astraが総合的にFableを超えた」と断定するのも誤りである。Fable 5.1はHLE with toolsで65.0%対57.2%と優位であり、Artificial AnalysisではIntelligence IndexとCoding Agent Indexの双方でFable 5.1がAstraを上回る結果が出ている。つまり**科学エージェント化と一般知能ランキングは同義ではない。** ³

実務上の推奨

計算科学、scientific ML、データ解析、科学ソフト操作、数学、工学系の研究パイプラインをいま構築するなら、**GPT-6 Astraを第一候補にし、Claude Fable 5.1を対照モデルとして同一ハーネスで評価するのが合理的である。** Astraの公開科学エージェント評価が現時点では最も強いためである。 ²

数十万～100万token級の固定研究コーパスを何度も参照し、何時間にもわたる探索を行うならFable 5.1を必ず含めるべきである。 long-horizon設計と安価なcache readは、このタイプのワークロードに構造的な利点を持ち得る。 ¹³

ウェットラボ、創薬、高リスク生命科学では、「どちらのモデルが賢いか」ではなく「どの安全ゲート・アクセス制度・装置インターフェースを含むシステムか」で選ぶべきである。Anthropicの場合、FableとMythosの区別がこの点で特に重要である。 ⁵²

そして研究機関の評価指標を「正答率」だけにしてはいけない。最低限、**task completion、citation correctness、statistical validity、artifact reproducibility、error recovery、cost-per-success、human intervention rate、unsafe-action rate、independent replication rate**を計測すべきである。Terminal-Bench-Scienceが成果物を再現可能なテストで評価する設計は、この方向性の有力な雛形である。

⁸

参考優先ソース

本調査で特に重みを置いた資料は、優先度順に次の通りである。

OpenAI一次資料。 GPT-6 Astra公式リリースは科学ソフト操作、各種benchmark、素数研究を含む能力の中心資料であり、Astra System Cardはデータ・訓練、alignment、monitorability、PostTrainBench、MLE-

Bench、安全策まで含む最重要技術資料である。APIモデル仕様は1.05M context、128K output、価格、cutoff、ツール対応の根拠となる。日本語ではOpenAIの製品リリースノートと「Astraへの道」が利用できる。 62

Anthropic一次資料。 Claude Fable 5.1 / Mythos 5.1公式ローンチ、Fable 5.1 API/model documentation、migration guideを中心に用いた。これらはFable/Mythosの区別、科学事例、Terminal-Bench-Science、adaptive thinking、forced tool use制限、価格、safety fallbackなどの主要根拠である。日本語公式リリースノートと日本語Platform Docsも確認した。 63

Terminal-Bench-Science運営元。「科学エージェント」を比較するうえで、本調査では最重要の外部ベンチマーク資料と位置づけた。実研究ワークフロー、客観的成果物、再現可能なテストを重視しているため、教科書QAより本論の定義への適合度が高い。 8

公開科学成果物。 Claude Fable 5.1によるVenus Opposite-Look TopographyのZenodo recordは、モデルが生成した研究成果がダウンロード可能なデータセットとして残されていることを直接確認できるため、単なる製品デモより証拠価値が高い。 64

独立モデル評価。 Artificial Analysisは、Astraがすべての総合指標でFable 5.1を凌駕しているわけではないことを確認する重要な反証材料であり、ベンダー発表だけから「全面勝利」と結論することを防ぐ。 25

Agentic Scienceの学術文献。 “From AI for Science to Agentic Science”は、仮説形成→実験設計・実行→解釈→反復的理論更新というFull Agentic Discoveryの定義に用いた。一方、“Agentic AI Scientists Are Not Built For Autonomous Scientific Discovery”は、暗黙知・失敗知識・物理実験フィードバックの不足という限界を整理しており、今回の「完全自律科学者ではない」という判定の重要な理論的基準になっている。 1

総括すると、2026年9月時点の変化を「GPT-6 Astraの科学IQが上がった」とだけ表現するのは不十分である。本質的な変化は、科学的推論が検索・コード・コンピュータ操作・専門ソフト・長時間実行・検証可能な成果物へ接続され、科学研究の「行為主体」に近づいたことにある。その意味では「サイエンスエージェント化」は既に始まったと言ってよい。だが、科学における最後の壁は推論ベンチマークではなく、現実世界からの反証、独立再現、失敗からの学習、安全・倫理、そしてどの研究課題を追う価値があるかを判断することである。そこまで含めれば、GPT-6 AstraもClaude Fable 5.1も、現段階では「自律科学者」ではなく、急速に強力になったAI co-scientist / computational research agentと位置づけるのが最も厳密である。 65

1 65 From AI for Science to Agentic Science: A Survey on Autonomous Scientific Discovery
<https://arxiv.org/html/2508.14111v1>

2 3 6 20 22 24 26 33 37 41 43 44 46 47 53 60 61 62 GPT-6 Astra: A new generation of intelligence | OpenAI
<https://openai.com/index/gpt-6-astra/>

4 5 21 23 27 28 36 49 50 51 52 58 63 Introducing Claude Fable 5.1 and Claude Mythos 5.1 \ Anthropic
<https://www.anthropic.com/claude-fable-and-mythos-5-1>

7 11 13 16 54 Claude Fable 5.1 - Claude Platform Docs
<https://platform.claude.com/docs/en/models/fable-5-1/overview>

8 34 TERMINAL-BENCH-SCIENCE 0.1
<https://www.tbench.ai/news/terminal-bench-science-0-1>

9 14 15 30 31 35 42 56 57 59 GPT-6 Astra System Card - OpenAI Deployment Safety Hub

<https://deploymentsafety.openai.com/gpt-6-astra>

10 12 リリースノート

https://openai.com/ja-JP/products/release-notes/?utm_source=chatgpt.com

17 18 38 39 40 45 55 GPT-6 Astra Model | OpenAI API

<https://developers.openai.com/api/docs/models/gpt-6-astra>

19 32 Migrating to Claude Fable 5.1 and Claude Mythos 5.1 - Claude Platform Docs

<https://platform.claude.com/docs/en/models/fable-5-1/migration-guide>

25 Benchmarking GPT-6 Astra | Artificial Analysis

<https://artificialanalysis.ai/articles/benchmarking-gpt-6-astra>

29 64 Venus Opposite-Look Topography | Zenodo

<https://zenodo.org/records/22164484>

48 Agentic AI Scientists Are Not Built For Autonomous Scientific Discovery

<https://arxiv.org/html/2605.08956v1>