

生成AIを「確信」に変える: Claudeテスト実践ガイド

「なんとなく」の信頼から、プロの「検証ループ」へ

「魔法の箱
じゃない。
信頼できる
相棒にする
すんだ！」

Dial of Trust

MAX

AI Testing

「これが『アーティファクト効果』だ。
AIの出力が洗練されているほど、
人間の批判的思考はマヒして
マヒしてしまうんだ。」

Cognitive
Gauge

プレーンテキスト

美しいアーティファクト

推論への疑問:
-3.1 ポイント

事実確認:
-3.7 ポイント

欠落コンテキストの
特定: -5.2 ポイント



コンテキストウィンドウ
作業メモリの限界。長い会話の「中間部分」にある重要な指示を忘れてしまう。



操作可能性
おもねり。真実を語るより、ユーザーの好みに合わせた「過度に謙虚になること」を優先する。




次トークン予測
高度な自動補完。事実ではなく「最も確率の高い次の言葉」を紡ぐため、ハルシネーション（作話）が起きる。



知識の限界
学習データはカットオフ時点で固定。最新ニュースやニッチな情報には「知識のムラ」がある。





信頼は「状況に応じて
微調整するダイヤル」である



0か1かのスイッチは捨てる

今日から実践する3つのテスト段階：【1. 対話型】【2. 性能型】【3. 仕組み型】



根拠(推論プロセス)を問う
結論だけでなく、論理の連鎖
($A \rightarrow B \rightarrow C$)の飛躍を暴く。

反復により
目標明確化が
+23.6 pt
向上!

反復チャレンジ
「懐疑的な投資家の視点から反
対意見を述べて」と制約を与え、
おもねり(Sycophancy)を打破する。

セルフ・ファクトチェックの依頼
「ハルシネーションの可能性がある
具体的な数値を3つ挙げて」と
弱点を告白させる。



```
> /effort [===== ]
```

簡単な作業と
複雑なタスクで、
Claudeの『頑張り具合
(リソース消費量)』を
を使い分けるのか！

エフォートレベルの黄金律

- **Low:** 結果が一目で確認でき、修正が容易なタスク
- **Max:** 自分で検証するのが難しく、絶対にミスが許されない複雑な検証

Engine Room

低
(Low)




最大
(Max)




作業スタイル

指示通りにコードを書き、即座に終了。




コードを書き、実際に実行し、テストデータで検証を繰り返す。




二重チェック

ほとんど行わない。




推論ミスを修正するため複数ターンの思考を費やす。




ツール呼び出し

最小限（ファイルの書き出しのみ等）。




多数（読み込み、実行、ログ確認、再修正）。



信頼性の質

人間による入念なコードレビューが必要。



動作が確認済みであり、そのまま実戦投入できるレベル。





採点基準

- 1点: 誤情報あり・指示無視
- 3点: 情報は正確だがトーン不適切・冗長
- 5点: 正確・簡潔・次のアクションが明確

テストデータの投入

AI作業者

テストデータの投入

AI作業者

AI採点者

コードベースの
自動判定

```
JSON
{
  "json": {
    "date": "OK",
    "name": {
      "name": "JSON OK"
    }
  }
}
```


デューデリジェンス声明

1. AI支援内容: 構成案策定・要約
2. 使用ツール: Claude 3.7 Sonnet
3. レビュー方法: 元データとの照合による
ファクトチェック
4. 修正箇所: 専門的知見に基づく大幅な修正
5. 責任の所在: 最終的な内容の正確性は
人間(自分)が全責任を負う

透明性が信頼を生む。「AIが書きました」ではなく、
「どう人間がテストしたか」を明示せよ。

信頼のマスターボード：いつ、どのテストを回すべきか

高リスク / システムプロンプト

中リスク / 複雑な実行

低リスク / 日常タスク

信頼のダイヤルレベル

仕組みテスト: 評価データセットと
AI採点者による自動化

性能テスト: エフォートレベル
(/effort) の調整

対話型テスト: 3ステップループ (推論、
ファクトチェック、反対意見)

High

タスクの複雑さとリスク

Low Gemini Notebook

今すぐ試せる 「本日のアクション」

コピーペスタプロンプト

「この回答内容について、私が一次資料で事実確認すべき具体的なポイントを3つ挙げてください。
また、結論の『前提条件』の中で、私の文脈に合わない可能性があれば指摘してください。」

この小さなテストが、
あなたのAI活用を「確信」へと変える。

