



サービス資料

制御設計レビュー・制御条件ギャップチェック | 一般社団法人C³社会デザインセンター

AIにどこまで任せられるかを、 確かめた範囲で判断する。

人が決めた「任せる条件」と「止める条件」を基準に、実際の経路で確かめ、確かめた範囲と確かめていない範囲を分けて残します。

無料事前スクリーニング

制御設計レビュー

制御条件ギャップチェック

AIが外へ作用する前に、どこまで任せるかを決める



外部へ送る

メールや外部のAPIへ、情報を出す



データを書き換える

顧客情報や設定を更新する



ツールを実行する

社内外のツールを呼び出す



承認の後に動く

人の承認を受けて、実行に進む



「任せる条件」と「止めたい条件」は人が決めます。そのうえで、実装でもその境界が保たれているかを確かめる必要があります。

こんな場面で使われます

顧客への納品前

本番リリース前

監査・審査の前

金融・医療・公共など説明責任の重い業務

なぜ今か

AIの導入は進んだ。任せる段階は、これから

57.7%

生成AIを導入済みの企業

導入検討中を含めると76%

NRI 2025年

3.3%

生成AIを使う企業のうち、AIエージェントを利用中

導入検討中13.5%、情報収集中49.3%

矢野経済研究所 2026年

23%

AIガバナンスの中央組織を整えている企業

売上500億円以上。米国は63%

PwC Japan 2026年



PwCは、日米の差の本質は予算より、自律的に動くAIの統制を設計した経験と、ガバナンス基盤の遅れにあると分析しています。AIに任せる範囲を広げる案件、つまり制御が要る案件は、これから増えていくと考えています。

出典：野村総合研究所「ユーザー企業のIT活用実態調査（2025年）」、矢野経済研究所「国内生成AI/AIエージェントの利用実態に関する法人アンケート調査（2026年）」、PwC Japanグループ「生成AIに関する実態調査2026 春 6カ国比較」。調査ごとに対象と時期が異なります。

ゲートを入れても、要件どおりに止まるかは別

AIのツール呼び出しを、実行の前に止めるゲート製品が大手から出てきています。ゲートは許可か拒否かを返します。ただ、自社の要件どおりに止まるかどうかは、条件を変えて動かしてみるまで分かりません。



💡 止める仕組みを入れることと、それが実際に止まることを確かめることは、別の仕事です。弊会が担うのは後者です。

入口はひとつ。段階に合わせて選べます



無料・共通の入口

事前スクリーニング

面談なし。お送りいただいた資料から、重要な経路と確認候補を2～3点お示しします。条件が決まっていなければレビューへ、決まっていればギャップチェックへ進みます。



設計中・導入前

制御設計レビュー

実行検査	含まない
成果物	2ページのレビューシート
次の工程	設計・実装・QA、必要なら正式検査



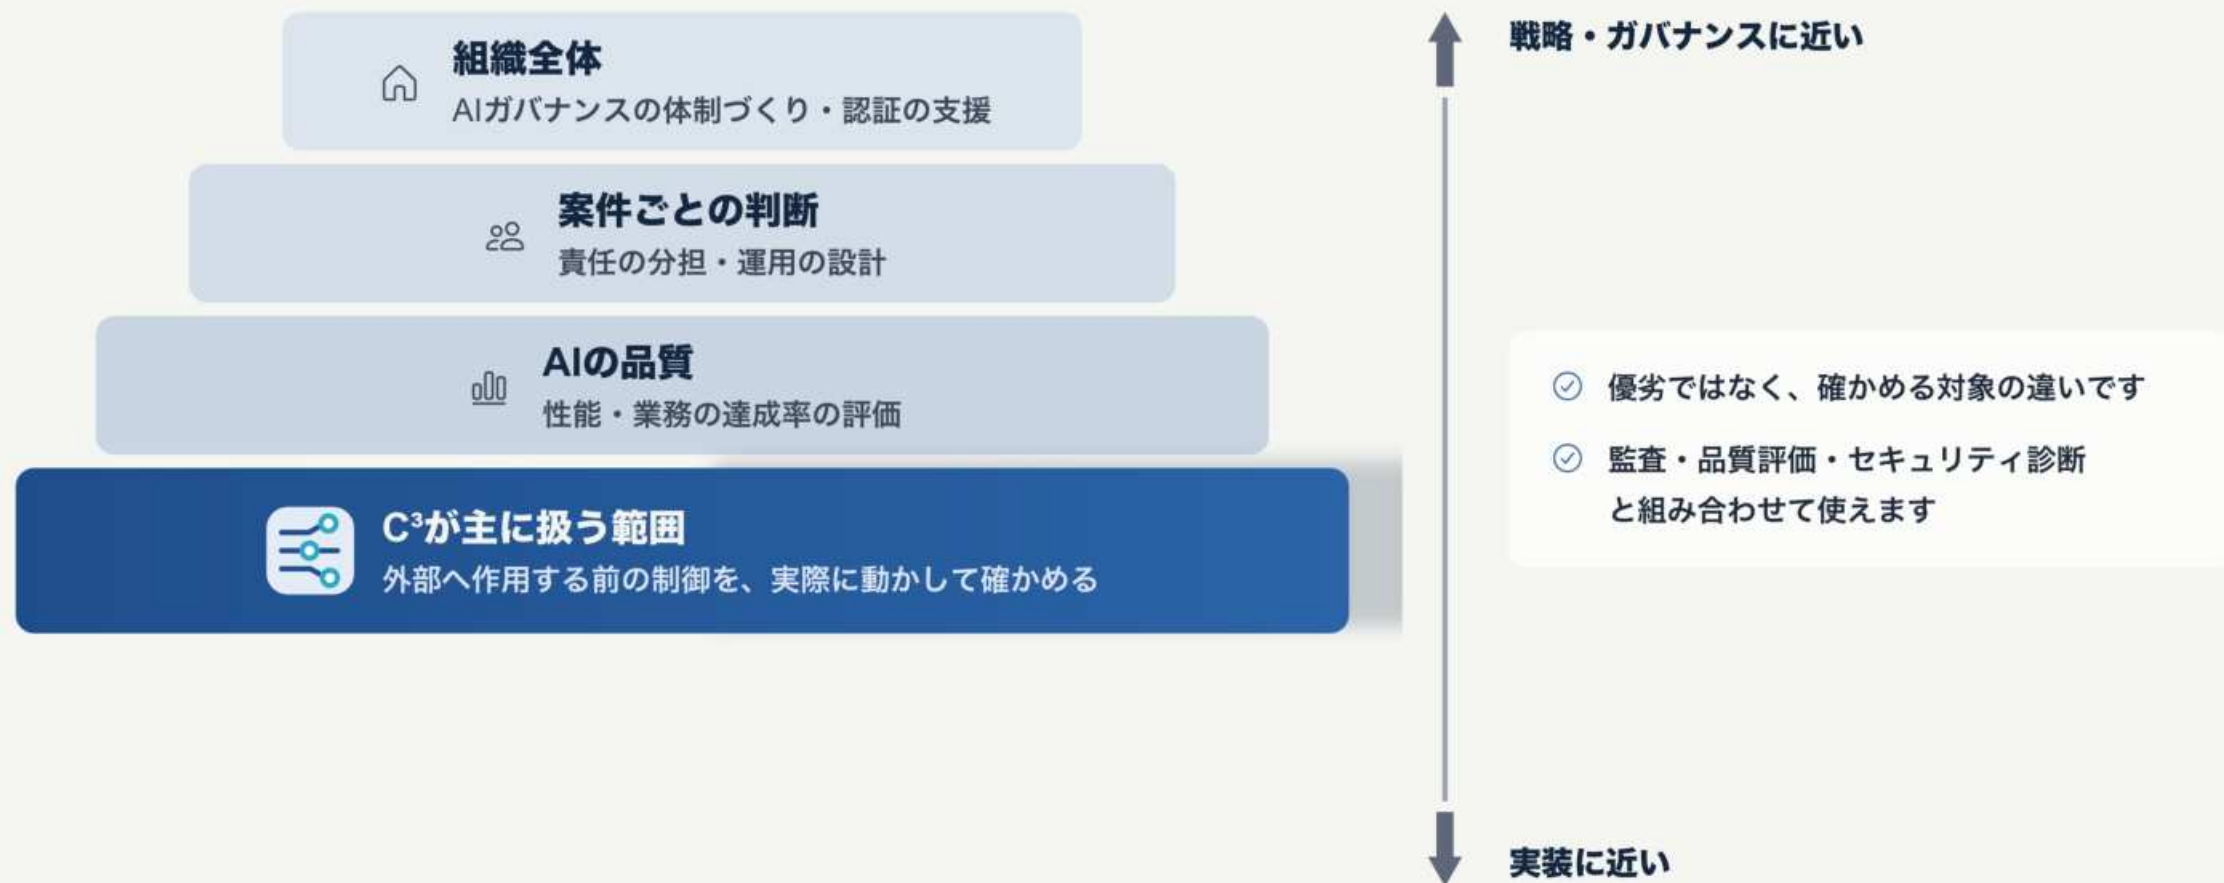
実装済み・運用の前後

制御条件ギャップチェック

実行検査	合意した範囲で実施
成果物	制御検証記録・証拠・未観測の範囲
第三者の確認	Verify IDとBYOVで、受け手が確かめ直せる

レビューだけ、ギャップチェックだけ、両方をつなぐ、のいずれも選べます。見つけた条件は、必要に応じて実行前の仕組み（Control API、評価・PoC段階）の設計へつなげます。

ほかの評価と重ならず、並べて使えます



候補を見つける仕事と、確かめる仕事は違います

比べる点	通常寄りの防御的なレビュー	制御条件ギャップチェック
主な問い	実装上、問題になりそうな箇所はあるか	宣言した制御は、条件を変えても保たれるか
出発点	ソース・設定・処理の流れ	守る条件・正常時の基準・比べる物差し
条件の変更	必須ではない	変える条件を先に宣言して比べる
未観測・証拠不足	レビューの記述の中で扱う	未観測・判定不能として結果から分ける
出てくるもの	指摘・懸念・修正の提案	再実行できる条件と、その観測結果



通常のレビューでも、問題の候補にはたどり着けます。ギャップチェックは、その候補を、条件を変えて反証できる実験に変えるものです。

単体・統合テスト、静的解析、脆弱性診断、コードレビューを置き換えるものではありません。発見率が高いといった性能の比較も主張しません。この比較は、弊会の内部の検証をもとに一般化したものです。

資料をお送りいただくだけで、確かめる候補を整理します

対象

1つの業務フロー

進め方

面談なし。お送りいただいた資料を、弊会で30分程度かけて確認します

お返しするもの

重要な経路と確認候補を2〜3点。必要に応じて最大8セルに分解

実行

動かしません。コードやログの提出は必須ではありません



1ページ目 | 条件のセル表

任せる条件と止める条件を、確かめられる単位に分けて並べます



2ページ目 | 次に決めること・正式検査の候補

決まっていない条件は、そのままお返しします。例えば、承認の有効期限、承認できる人、承認後に内容が変わったときの扱い



決まっていないことを、AIの推測で補うことはしません。何を決めれば確かめられるかを、はっきりさせるのがこの段階の役目です。

実装の前に、抜け道の候補と確かめる条件を決めます

-  **材料**
設計資料・構成図・業務ルール・QA方針など
-  **進め方**
面談なし。文章での確認は最大2往復
-  **標準範囲**
1フロー・制御条件1～2個（個別見積）

-  **1ページ目 | レビュー要約**
資料で確認できたこと、まだ決まっていないこと、必要な制御条件、改善の候補
-  **2ページ目 | 確認条件表**
実装した後に試すケース、期待する動き、残しておく証拠

例：人の承認を挟む外部送信なら、こうした条件を洗い出します

承認がない

承認の後に宛先が変わる

却下の後に再試行される

別のツールから呼ばれる

 レビューでは実際には動かしません。お返しするのは、実装の後に確かめるための条件です。

固定して、観測して、比べて、証拠に残す

 01

対象版を固定

リリース・版・経路を固定します

 02

守る条件を固定

承認・対象・作用などを明確にします

 03

正常時を実際に観測

仕様から推測せず、実際の処理を通します

 04

条件を意図的に変える

承認なし・期限切れ・別の経路など

 05

同じ基準で比較

先に決めた物差しで比べます

 06

未観測・判定不能を分ける

試していない範囲を合格に寄せません

 07

修正後に同じケースを再実行

結果の変化を同じ条件で確かめます

 08

証拠と検証記録IDを結ぶ

受け手が確かめ直せる形にします

🕒 標準の範囲は、1リリース・制御条件1〜2本です。見つけた食い違いは、修正の後に同じケースで確かめ直すところまでを含みます。

外れやすい条件を、意図的に変えて確かめます



権限

AUTHORITY

承認がない、権限のない人が承認する



時刻・期限

TIMING

承認の有効期限が切れている



対象

TARGET

承認した対象と、実行する対象が違う



再試行・復旧

RETRY_RECOVERY

却下の後に再試行する、途中で止まる



順序

SEQUENCE

確認と実行の順序が入れ替わる



制御の置き場所

ENFORCEMENT_PLACEMENT

制御を通らない経路から作用に届く



公開しているのはこの6軸です。実案件では、非公開の13軸の中から、対象の制御と経路に合う条件を選びます。すべてを総当たりするわけではありません。

7件中6件が一致でも、合格とは書きません

COUNTEREXAMPLE

反例あり

守る条件と、実際の動きの食い違いを観測した

修正の対象。直した後に、同じケースで確かめ直す

NO GAP OBSERVED

反例未観測

決めた範囲では、条件に反する動きは見られなかった

その範囲に限った結果。全体の安全は意味しない

UNDEFINED

判定不能

証拠が足りず、結論を出せない

合格にも不合格にも寄せない

UNOBSERVED

未観測

今回は試していない

安全・危険のどちらにも補わない

⚠ 7件のうち6件が一致し、1件が未観測なら、全体は「判定不能」です。試していない経路について、言えることはないからです。

止まることと、任せてよいことは分けて判断します



委任判断の材料になるのは、次の4つがそろったときだけです

- ✓ 任せる範囲を、人が方針として決めている
- ✓ 許可した側の動きが、想定どおりだった
- ✓ 同じ制御の禁止側で反例がなく、試していない経路も残っていない
- ✓ 確かめた版と、いま使う版が同じ

⚠️ ひとつでも欠けていれば、候補にはしません。制御が期待どおりに動いただけでは、任せる根拠になりません。

お渡しするもの

結論のPDFではなく、根拠までたどれる記録をお渡しします



受け取った方の使い方

本番前のリリース承認

対象版・確認条件・結果・未観測を、同じ記録から確かめる

顧客・取引先への説明

認証バッジではなく、対象版と証拠への道筋を共有する

監査・審査

結論だけでなく、固定した証拠と判定の手順までたどる

⚠ 検証記録ID (Verify ID) は認証バッジではありません。第三者による確かめ直しも、安全の保証や適合の認証を意味しません。

うまくいった例だけでなく、止まった研究も残しています

4

公開記録・方法論

4

概要を公開
証拠は
非公開

2

研究

記録	結果の要旨	公開の範囲
Browser Use 0.13.2 ライブ実証	反例4・維持1	公開証拠あり
Anthropic Sandbox Runtime 0.0.77	6件一致・1件未観測	要旨とハッシュを公開
公開検証記録 C3-CAV-2026-0002	公開時点の配備記録まで固定	公開証拠あり
n8n パイロット	却下・承認でのツール実行の差を観測	要旨のみ公開
比較研究（24の合成課題）	事前の基準に届かず、合格にせず終了	研究の記録

⚠ 登録数は顧客案件の数ではありません。保留・未観測・基準未達を、合格へ読み替えません。

コードに書いてあることを、止まる根拠にはしません



3つの検査と結果

通信の検査1

ローカル通信を許しても、外への通信の制限は残るか

**判定不能
(1件未実行)**

通信の検査2

許可した名前でも、行き先が自ホストなら拒否されるか

反例未観測

ファイルの検査

書き込みを許した範囲でも、禁止したファイルは守られるか

反例未観測

外から見える結果で確かめる

許可リストにない宛先には、理由付きの拒否が返った。
禁止したファイルは、上書きが拒否され、中身も元のまま

安全に試せた6件は一致。それでも委任の候補は0件

任せる範囲をまだ人が決めていないため。ファイルはあと1つ、通信はあと3つ、確かめることが残っています

対象は anthropics/sandbox-runtime (コミット 6fa7313)。事前に決めた条件に限った結果で、製品全体の安全性や他の版を示すものではありません。

条件を1つだけ変えて、反例と維持を比べました

⚙️ 変えたのは1か所だけ。AIが開いたページから転送される先を、許可リストに入れるか、入れないか

許可リストに入れた

届いた（想定どおり）

1回中1回

許可リストに入れなかった

届いた（届かないはず）

4回中4回

🕒 開発元に報告済みで、回答を待っています。修正後の再確認は、まだ行っていません。

🔗 許可した側が想定どおりでも、関連する禁止側に反例があるため、任せる根拠にはしません。

Browser Use 0.13.2を組み込んだ弊会の検証環境での観測です。原因がBrowser Use本体にあるかは特定していません。一般的な脆弱性の有無を示すものではありません。

「承認が必要」は、動かすまで確かめられていなかった



🔍 承認の記録は、承認があったときのことしか残しません。承認がないまま通った操作は、記録を見返しても出てきません。実際に動かしたから見つかった例です。

公開記録：C3-CAV-2026-0001（修正 PR #127、旧形式の公開サンプル）。この承認なしのケースに限った結果です。

標準の範囲と費用、進め方



制御条件ギャップチェック

900,000円（税別）

対象	1リリース・制御条件1～2本
規模	最大24セル・最大72試行
期間	5～10営業日
含む	修正後の同一ケース再確認・報告会1回

その他の費用（税別）

🔍 事前スクリーニング	無料
📖 制御設計レビュー	30,000円／1フロー
⚙️ 制御条件の追加	300,000円～
▶️ 再検証	250,000～350,000円



対象と証拠の条件を確認して、見積を確定します。契約や情報の取り扱いの詳細は、個別に取り決めます。

確かめた範囲だけを、確かめた言葉でお伝えします

言えること

- ☑ 固定した版と条件で、何が起き、何が起きなかったか
- ☑ どこまで確かめ、どこが未観測か
- ☑ 修正の前後で、同じケースの結果がどう変わったか

言えないこと

- ⚠ システム全体の安全性・完全性・法令への適合
- ⚠ 第三者認証（検証記録IDは認証バッジではありません）
- ⚠ ほかのテストや診断の置き換え

設計に関わった対象を後から検査する場合は、その関与を記録に明示します。



サービス詳細

c3-anchor.jp/control-assurance



実証台帳

c3-anchor.jp/examples/verify



通常のレビューとの比較

GitHub 公開文書

▶ お問い合わせ info@c3-anchor.jp | まずは無料の事前スクリーニングから

判断の仕組みも、公開しています



Logos Protocol

実行前制御

公開・送信・操作などの外部作用を、構造・証拠・承認条件で、外に出る前に確かめる



ECHO-VERIFY

第三者再検証

根拠・仕様・実行記録・検証手順を束ね、受け取った側が自分の環境で追試できる形にする

論文 (SSRN) あり



Two-Rail

証拠の分離

公開してよい証拠と守るべき記録を分け、非公開を見せずに公開側だけで照合できる範囲を残す

論文 (SSRN) あり



Control API

実行前の仕組みへ

止める・理由を残す・範囲を見る・確かめ直す、を別々の役割として扱う

評価・PoC段階の実装を含みます



いずれも、安全性や正しさそのものを保証する仕組みではなく、第三者認証を意味するものでもありません。検証の道筋を、再現・反証できる形にするためのものです。