



知財AIエージェント ハーネス設計の青写真

法務・知財・セキュリティを統合した、生成AIの安全な実装と統制層の構築




ターゲット：中堅企業 知財・法務・情報システム部門
準拠フレームワーク：JPO AIビジョン・NIST・OWASP

誤解：「弁理士レベルの賢い単一モデルを探し、
直接対話する」



真実：「モデルを信用しなくても事故が起きない
『実行・統制層 (ハーネス)』を構築する」



最重要結論：知財業務において「一度外部に漏れれば取り返しがつかない情報」と「誤実行が法的効果を生む行為」を守るため、LLMは判断主体ではなく「候補生成器」として封じ込める。

知財AIを取り巻く4つ巻く4つの法的境界線

弁理士法 (守秘義務)

Risk



業務上知り得た秘密の漏えい・盗用（第30条等）。特許事務所との連携時リスク。



Harness Design

NDA・顧客同意のシステムの検証。利用者本人の守秘義務とAIへの入力許可は別物として扱う制御。

個人情報保護法

Risk



安全管理措置（第23条）、外国第三者提供（第28条）、目的外の学習利用。



Harness Design

DLPによる検知。外国クラウド利用時のデータ所在地・アクセス権・サブプロセッサの分離確認。

営業秘密 (不競法)

Risk



秘密保持義務のないAIへの投入による「秘密管理性」の喪失。



Harness Design

秘密管理規程へのAI入力ポリシー組み込み。L3（極秘）データのログ複製制御と保存期間制限。

著作権法

Risk




第30条の4（非享受目的）の適用外利用。既存著作物との類似性。



Harness Design


Data Manifest（学習データ台帳）の保持。類似性チェックと出力ゲートウェイの設置。

知財データの4段階分類（L0～L3）と統制方針



物理的所在地（オンプレ/クラウド）ではなく、「実際のデータ処理者・保持期間・サブプロセッサ・監視」をデータフローで確認・統制する。

知財エージェントの推奨アーキテクチャ




ツール実行の分離とプロンプト・インジェクション対策

The Attack

Structural Separation

Tool Gateway Re-authorization



業務フェーズ別 リスクと必須統制マトリクス

知財業務フェーズ	AIの役割	主なリスク	必須統制	HITL (人間介入)
明細書・請求項作成	初稿、従属項候補	サポート欠如・範囲喪失	用語統一・diff表示	 【必須】
拒絶理由・審査対応	反論候補、補正案比較	法的論点の誤認	OA原文固定・補正前後比較	 【必須】
FTO・侵害予防調査	候補権利抽出	国別クレームの誤判断	公式DB照合・法域固定	 【必須】
先行技術調査	意味検索、ランキング	検索漏れ・架空公報	公報DB直接検索	重要案件で必須
契約・ライセンス管理	条項・期限抽出	ロイヤルティ等の機密漏洩	Deal-room隔離	 【必須】

Insight: 調査業務において「AIがそれらしい文献を出した」ことを完了条件にしない。
RetrievalとLegal Judgmentは別々に評価する。

Anatomy of an IP Prompt: プロンプトの構造化管理

ROLE:

あなたは日本特許実務の分析補助者。
最終法的判断・提出行為は行わない。

JURISDICTION:

JP

AS_OF_DATE:

2026-10-26

MATTER_ID:

PAT-2026-XXXX

AUTHORITATIVE_SOURCES:

1. 審査対象出願
2. 拒絶理由通知
3. 引用文献

RULES:



- 根拠のない法的主張は禁止。
- 公報番号、段落番号を必ず示す。

Variable Control: 法域や基準日はユーザー入力ではなくシステム変数として固定

Matter Isolation: 案件IDを明記し、案件間メモリの共用を完全に防止


Version Control: テンプレート自体に所有者・有効期限を持たせ、ユーザーの勝手な書き換えを無効化

Chain of Truth (証拠連鎖) と検証ループ




LLMに「正しいか再考せよ(Self-reflection)」と頼むのではなく、外部DBや決定論的ルールで検証する機構を構築する。

Bad UI: Rubber Stamping (形式的な承認)



人間が事実確認できず、盲目的に承認
ボタンを押してしまう危険な実装。

Good UI: Evidence-Based Decision



判断に必要な「差分」と「根拠」を並べて提示し、事実確認を強制する。


テレメトリ：品質・リスク・業務のKPIダッシュボード

Metric 1: 根拠品質 (Quality)



- KPI: Citation validity率（架空引用ゼロ）、根拠なし重要主張率

Metric 2: セキュリティ (Security)




- KPI: 権限外ツール実行の阻止数、DLP検出数、プロンプトインジェクション防御率

Metric 3: 運用・統制 (Operations)

0%

- KPI: 必須承認（HITL）ゲートの迂回率
Production Release Gate: 絶対条件

Metric 4: ビジネス効果 (Business)




- KPI: 調査時間削減、案件処理リードタイム

危険な自動化（権限逸脱・承認迂回）が高評価にならないよう、ユーティリティと堅牢性を同時に評価する。

ログの二層化とインシデント対応

ログの二層化 (Two-Tier Logging)




案件ID、実行者、モデル版、
承認記録、ハッシュ



L3の生プロンプト、全文回答。
第二の営業秘密DB化を防ぐ

インシデント対応フロー (Incident Response Flow)



導入前必須チェックリスト - The Deployment Gates

P0: 本番・機密データ利用前必須 (Critical Gates)

☐	L0～L3のデータ分類とモデル投入可否表の承認
☐	L3データが一般向けAIへ送信されない技術的制御
☐	AIベンダーの学習利用不可（オプトアウト）の契約/DPA確認
☐	外部送信・提出アクションに対するHITL（人間介入）の強制
☐	Agent Kill Switch（一括停止機構）の稼働テスト

P1: 本番展開前必須 (Production Gates)

☐	法令・審査基準等のSource Hierarchy（一次資料優先）設定
☐	間接的プロンプトインジェクションの防御テスト実施
☐	案件ID単位でのデータ分離テスト完了

中堅企業向け：段階的導入ロードマップ

Step 1: Read-Only (Public Data)

- ⚙️ 対象データ: L0 (公開情報)
- ⚙️ ユースケース: 公開公報要約、法令Q&A
- ⚙️ ハーネス要件: 承認済みクラウド、原資料への根拠リンク徹底

Step 2: Read-Only (Internal Data)

- ⚙️ 対象データ: L1/L2 (社内情報・機密)
- ⚙️ ユースケース: 契約レビュー、拒絶理由分析、発明インタビュー
- ⚙️ ハーネス要件: DLP実装、案件分離、No-training環境、監査ログ構築

Step 3: Write + Strict HITL (Execution)

- ⚙️ 対象データ: L1~L3
- ⚙️ ユースケース: 内部システムへのドラフト登録、外部提出準備
- ⚙️ ハーネス要件: Write権限の解放。ただし不可逆操作は【厳格な人間承認 (HITL)】下に固定

The Blueprint for IP AI



AIは弁理士や知財担当者の責任を肩代わりするものではない。

**膨大な情報を高速に処理しつつも、秘密を堅守し、明確な根拠を示し、
重要な法的判断を必ず適切な人間へと還元するシステム。
それこそが、あるべき『知財AIハーネス』である。**