



MiniMax「M3.1 Flash」の全貌と知財業務への戦略的影響

覆面モデル"Space Bunny"がもたらすエージェント経済性の転換点と、
必須となるガバナンス・アーキテクチャ

For IP Strategists, Patent Attorneys, and Corporate Legal Leadership

累計200兆トークンの処理実績を持つ覆面モデルの正体 正体

200T+

ステルス運用期間（Space Bunny）での累計処理量。
OpenRouterで10日連続首位
（56.7兆トークン処理）。

-70%


エージェントタスクの総利用
コスト削減率（前世代比）。

1.22s

初回トークン生成時間
（TTFT）。最適化により1.95
秒から38%短縮、エラー率は
0.7%へ半減。

単なる軽量モデルの追加ではない。自律型AIエージェントおよび長文脈推論における「能力とコストの非対称な破壊」の始まり。

コストと推論能力を両立させる「MoE × スパース化」の計算機機構



圧倒的な経済性

- 入力: \$0.15 / 1M tokens (約24円)
- プロンプトキャッシュ読取: \$0.015 / 1M tokens (約2円・90%割引)

フロンティアモデルとの仕様・経済性比較マトリックス


評価項目	MiniMax M3.1 Flash	前世代 M3	DeepSeek V4.1 Flash	Gemini 3.8 Flash
アーキテクチャ	MoE(総428B/活性23B)	MoE(総428B)	MoE(活性8-16B)	非公開
コンテキスト	1,000,000	1,000,000+	262K-1,000,000	1,000,000
推論制御	常時有効 (無効化不可・5段階)	有効/無効切替可	推論モード対応	推論モード対応
入力料金	\$0.15	\$0.60	\$0.15	\$0.75
キャッシュ読取	\$0.015 (90% Off)	\$0.12	対応	対応

圧倒的な低単価と「100万トークンの
キャッシュ読取」が、特許包袋や大量公報
の反復解析を実用化する。


性能のパラドックス：最高峰の実務遂行力と、未知に対する極端な脆弱性

圧倒的エージェント性能

BankerToolBench (金融文書・規程遵守)



DeepSWE v1.1 (自律コーディング)



- BankerToolBench (76.2) & DeepSWE (73.7%)。Claude Opus 5等と肩を並べる。
- Automation-Bench (62.2%)。7モデル中首位。

複数ドキュメント間の一貫性維持、コードベース改修、ツール連鎖呼び出しにおいてフロンティア級。

致命的弱点：ハルシネーション

未知の問いに対する挙動 (BEHAVIOR ON UNKNOWNNS)




AA-Omniscience 総合スコア「16」



未知の問いに対して『わからない』と留保せず、93%の確率で自信満々にハルシネーション（虚偽）を生成する

結論：内部記憶（パラメトリック知識）に頼る用途は厳禁。プロンプト内に全証拠を与えた上の「論理検証・照合エンジン」としての利用に限定すべきである。

常時有効型アダプティブ推論（Effort制御）の解剖



thinking.type="disabled" はシステムレベルで拒絶 (HTTP 400 / エラー 2013)。




思考プロセスがAPIレスポンス
内で完全に分離されるため、
事後監査が極めて容易。




特許調査・分析における経済性のパラダイムシフト

Before (従来の高推論AI)




After (M3.1 Flash 動的ルーティング)




総API費用を10分の1以下に抑制しつつ、フロンティア級の深い進歩性検証を実現。

JPO「AIビジョン」時代に対するマルチモーダル防衛策



戦略的対抗策：CJK（中英日）マルチリンガル処理と視覚解析を組み合わせ、
わずか数円のキャッシュ読取コストで自社内クリアランスを完結させる。

出願・権利化業務の革新：チャンキングの終焉と反復検証ループ



知財タスク別 適合性・リスク統制ダッシュボード

タスク分類	推奨 Effort	実務的メリット	必須ガードレール（リスク統制）
特許調査 （一次）	low～medium	高速・低コスト ノイズ除去	公開公報のみ入力。 未公開テーマは抽象化。
特許調査 （詳細）	high～max	多角的進歩性論理検証	架空の段落引用を防ぐため 入力テキストのみを根拠に制約。
中間処理 （権利化）	xhigh～max	包袋横断照合・ 禁反言回避	RAGで審査基準を注入。 公開前案件はAPI不可。
出願支援 （公開前）	high～max	図面符号の一貫性 自動検証	標準API直接利用厳禁（新規性 喪失リスク）。完全閉域網必須。

越えなければならない法と倫理の「3つの壁」

IP Practice (知財実務)

善管注意義務 (Duty of Care)

民法第644条 /
JPAAガイドライン。

Risk :
93%のハルシネーション
率による過誤 (架空の引
例や効果の捏造) を検証
せず出願に反映すれば、
権利無効化の致命的リ
スクとなる。

新規性喪失と営業秘密 (Loss of Novelty)

特許法第29条第1項。


Risk :
クラウドAPI (ゼロ
データリテンションの
不透明性) への出願
前発明の入力は公知
化リスクに直結。

守秘義務と同意 (Confidentiality)

弁理士法上の守秘義務。


Risk : 個人データの国
外第三者提供における
体制確認と同意取得
の壁。

戦略的実装：法的リスクを無力化する「デュアルトラック・アーキテクチャ」



オープンウェイト公開（10/23）とオンプレミス実装の「重い現実」

完全閉域網でのローカル稼働は新規性喪失リスクをゼロにするが、2つの巨大な障壁が存在する。



Hurdle 1: VRAM（GPUメモリ）の壁

- 総VRAM要求量: 約405 GB必須。⚠
- 内訳: 重み(Q4量子化) 約240GB + 1M KVキャッシュ(FP16) 約129GB + オーバーヘッド 約37GB。
- 現実: コンシューマGPU不可。ハイエンドデータセンターGPUクラス (年間数千件規模の大手知財部向け投資)。

Hurdle 2: ライセンスの壁

- 過去モデル(M2.7)での「Modified-MIT」への変更履歴。
- 現実: 社内業務の商用セルフホストにも⚠
「MiniMaxからの事前書面許諾」と帰属表示が要求されるリスクの精査。

ハルシネーションを無力化する「決定論的検証ハーネス」




Mechanism 1: RAG Context Lock




システムプロンプトによる強制：「提供された文書外の事項についての推測を一切禁ず。該当なしと出力せよ」



Mechanism 2: 思考プロセスの分離監査



APIから独立して返却される reasoning_content を抽出。



Mechanism 3: 決定論的プログラム照合 (The Core Guardrail)



思考プロセス内で参照された「段落番号」「請求項番号」「図面符号」を正規表現で抽出。PythonスクリプトやWordマクロを使用し、入力テキスト内にその符号が実在するかを完全一致 (Exact Match) で自動照合する。人間 (弁理士) の目視前の機械的フィルタリング。



日本企業の知財部門・特許事務所が「今」採るべき3つの行動

Phase 1: 即時 (Now) – デュアルトラック運用ルール の制定

- ☐ 未公開情報の標準API入力厳禁（社内規定の即時アップデート）。
- ☐ 調査業務における、キャッシュ読取・effort制御を用いた大量公報の高速スクリーニングテスト開始。

Phase 2: 短期（10月23日以降） - 基盤とライセンスの検証

- ☐ オープンウェイト公開に伴う商用利用ライセンス（事前許諾要否）の法務精査。
- ☐ 閉域GPUインスタンス（405GB VRAM確保）の費用対効果算定と導入検討。

Phase 3: 中長期(2026年度中) - 決定論的ガバナンスとマルチモーダル防衛

- ☐ RAGコンテキストロックと段落番号照合スクリプト（検証ハーネス）の標準実装。
- ☐ JPO AIビジョンに対抗する、中国語/英語公報と図面を含めたAI事前クリアランス体制の構築。