

MiniMax M3 調査報告

エグゼクティブサマリー

MiniMax M3 は、MiniMax が 2026年6月に公開したオープンウェイトのネイティブ・マルチモーダル MoE モデルです。MiniMax の公式モデルページとブログ、Hugging Face 公式モデルカード、API ドキュメントを照合すると、M3 の確度が高い公開事実は次の通りです。約 428B 総パラメータ、約 23B 活性化パラメータ、1M コンテキスト、テキスト／画像／動画入力、OpenAI/Anthropic 互換 API、vLLM/SGLang/Transformers でのローカル実行対応です。なお、日本語記事で見かける「4280億」は 428 billion の意味であり、4.28T ではありません。4.28T なら日本語では通常「4.28兆」です。 ¹

アーキテクチャ面では、HF の `config.json` から、60層テキストバックボーン、64 attention heads、4 KV heads、128 local experts、token あたり 4 experts 選択、shared expert 1、最大位置長 1,048,576 が読み取れます。`moe_layer_freq` は最初の3層が dense、残り57層が MoEであることを示しており、MiniMax の「約 428B / 約 23B」という説明と整合的です。M3 の長文処理は MiniMax 独自の MSA (MiniMax Sparse Attention) で支えられ、公式説明では1M 文脈時に前世代比で 1 token あたり計算量を 1/20、prefill を 9 倍超、decode を 15倍超高速化したとされています。 ²

性能面では、MiniMax は公式ブログで SWE-Bench Pro 59.0%、Terminal-Bench 2.1 66.0%、SWE-fficiency 34.8%、KernelBench Hard 28.8%、MCP Atlas 74.2、BrowseComp 83.5 を公表しています。ただし、評価の多くは MiniMax 自社インフラと特定 scaffolding 上の結果であり、ブログ本文でもその旨が明記されています。したがって、「数値は強いが、第三者再現性はまだ確認途上」というのが妥当な読み方です。なお、ユーザーが挙げた Gemini 3.1 Pro の SWE-Bench Pro 54.2% は、今回確認した範囲では主に二次情報やソーシャル投稿由来で、Google の一次ベンチマークページでの裏取りはできませんでした。 ³

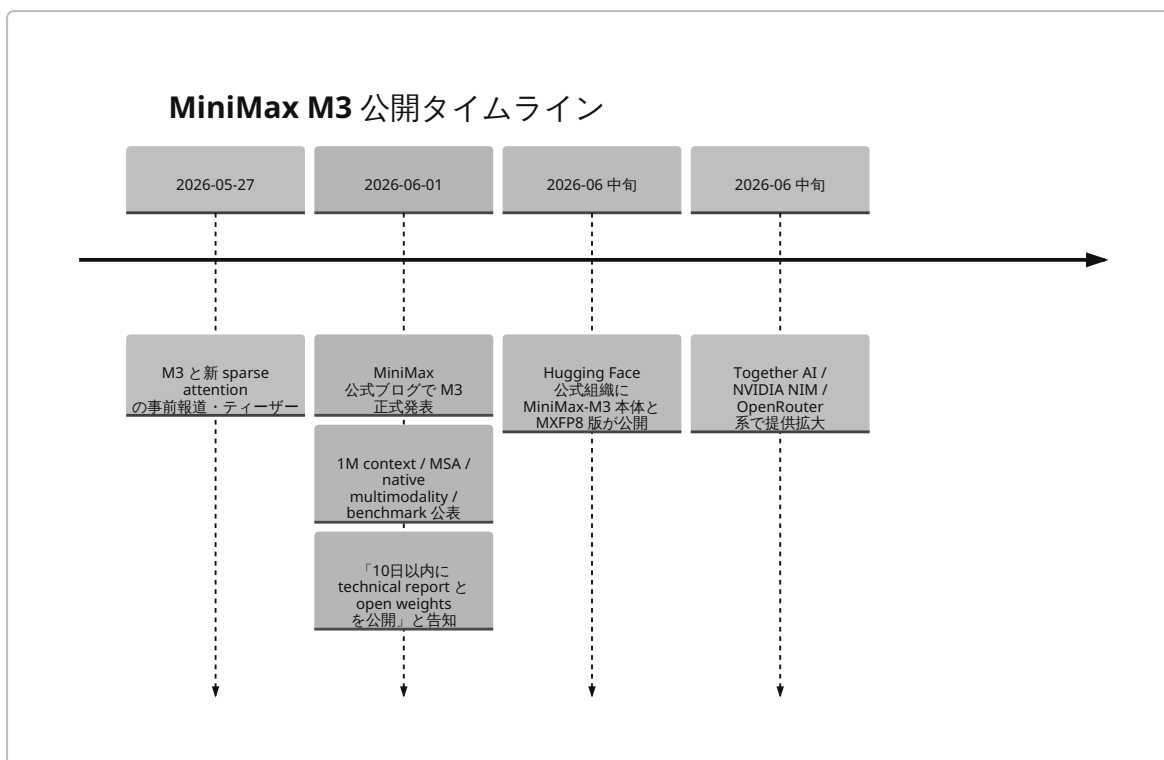
実務導入の観点では、M3 は知財ワークフローとの相性がかなり良いです。理由は、大規模な先行技術集合やファミリー単位の長文・長表・図面を一度に保持しやすいこと、画像／動画入力をネイティブに扱えること、オープンウェイトなのでオンプレや専有環境に寄せやすいことです。一方で、完全な M3 技術報告書、詳細な訓練コーパス内訳、MMLU/HumanEval の単独スコア、安定した独立ベンチマーク再現は現時点で不足しています。未公開発明の機密性を最重視するなら、API 直投げよりも HF 重みの専有環境運用を優先するのが安全です。 ⁴

公式ソースと公開タイムライン

今回の調査で優先した一次ソースは、MiniMax 公式ブログ／公式モデルページ、MiniMax API Docs、MiniMax 公式 Hugging Face 組織、HF 上の `config.json` とライセンス、MSA の公式 GitHub リポジトリ、および MSA の arXiv 論文です。重要な注意点として、MiniMax の 2026-06-01 公式ブログは「今後10日で technical report と重みを公開する」と予告していますが、今回確認できた HF モデルカードがリンクしている arXiv 論文 2606.13392 は MSA カーネル／疎注意実装の論文であり、M3 全体の system card / technical report を代替するものではありません。従って、M3 のフル技術報告書は、今回確認した公式ソース群では未発見と整理するのが適切です。 ⁵

また、公開経路はかなり速く広がっています。公式ブログ公開後、Hugging Face に本体チェックポイントと MXFP8 量子化版がアップロードされ、MiniMax API、Together AI、NVIDIA NIM/NeMo、OpenRouter 系プロバイダなどの周辺エコシステムが短期間で対応しました。これは、M3 が「研究発表止まり」ではなく、配布と実装エコシステム形成までを同時に進めていることを示す良いシグナルです。 ⁶

MiniMax M3 の公開経緯を、今回確認できた範囲で簡潔に図示すると次の通りです。 7



アーキテクチャの整理

公開仕様のうち確定している点

以下は、公式モデルカードとHFの公開設定ファイルから確度高く言える仕様です。 8

項目	確認できた内容	根拠
総パラメータ	約 428B	HF 公式モデルカード 9
活性化パラメータ	約 23B	HF 公式モデルカード 9
最大コンテキスト	1,048,576 tokens	HF config.json 10
API での保証	1M 対応、保証下限 512K	公式モデルページ/API docs 11
テキスト層数	60	HF config.json 10
Attention heads	64	HF config.json 10
KV heads	4	HF config.json 10
Local experts	128	HF config.json 10
token あたり選択 expert 数	4	HF config.json 10
Shared expert	1	HF config.json 10

項目	確認できた内容	根拠
Routing	<code>sigmoid</code> scoring、routing bias 使用	HF <code>config.json</code> ¹⁰
Vision stack	CLIP系 ViT、32層、hidden 1280	HF <code>config.json</code> ¹⁰
画像解像度	336 ~ 2016 の dynamic resolution	HF <code>config.json</code> ¹⁰
モダリティ	text / image / video 入力、audio 入力は未対応	API docs ¹²

`moe_layer_freq` の配列は、最初の3層が dense、残り57層が MoEであることを示しています。これにより、M3 は「全体は巨大だが、各 token では 4 local experts + 1 shared expert だけを強く使う」設計であり、推論時コストを総パラメータに対してかなり圧縮する思想が見えます。これは MiniMax がモデルカードで掲げる「約 428B / 約 23B activated」と概念的に一致します。もっとも、23B の数え方に embeddings・vision projector・出力 head をどこまで含めるかは公式に明示されていません。 ¹³

MSA と MoE の意味

MiniMax の公式説明では、M3 の長文スケーリングの本丸は MSA (MiniMax Sparse Attention) です。MSA は「すべての token に全 token を見せる」full attention の二乗コストを避けるため、KV を block 単位で選別し、query ごとに上位 block にだけ dense attention を張る方式です。HF の設定ファイルでも、block size 128、top-k blocks 16、index head 4、index dim 128 が設定されており、実装面の輪郭が見えます。MiniMax と Together AI の説明を合わせると、M3 の長文性能はモデル設計だけでなく、疎注意カーネル、paged attention、KV cache 管理まで含めたシステム最適化で成立しています。 ¹⁴

ここで重要なのは、M3 の「ネイティブ・マルチモーダル」主張です。MiniMax は公式に、multimodal training from step zero、interleaved data を大規模に作るためテキスト前学習パイプラインを再設計した、multimodality は superficial add-on ではないと述べています。したがって、ユーザーが言う「adapter-free claim」は、公式表現に引き寄せると、後付けアダプタで視覚を接いだのではなく、学習初期段階からテキスト・視覚の意味空間を統合したという主張として理解するのが最も正確です。なお、公式 API docs 上では画像・動画入力はサポートされるが、音声入力は現時点では未対応です。 ¹⁵

訓練データと事後学習で分かること・分からないこと

訓練データについて、公式ソースが公開しているのは「step zero からの mixed-modality training」「large volume of interleaved data」「テキスト前学習パイプラインの再設計」までです。総トークン量、言語別内訳、web / code / patent / video の比率、合成データ比率、フィルタリング手法、dedup 方針は、今回確認した公式ソースでは具体化されていません。ここは unknown と明記するのが適切です。 ¹⁶

事後学習については、公式ブログが interactive user simulator を使った multi-turn の coding / agent 学習を強調しており、単発コード生成ベンチだけでなく、要求補足、修正要求、継続的なセッション内協働に寄せた最適化が行われたと読めます。加えて API docs では thinking の on/off をサポートしており、複雑推論時の深い思考モードと、低遅延応答モードを使い分けられる設計です。 ¹⁷

性能、遅延、スループット、コスト

ベンチマークの読み方

MiniMax が公式に前面に出している M3 の主要スコアは次の通りです。これらは一次ソースで確認できた数値です。 ¹⁸

ベンチマーク	M3 の公表値	補足
SWE-Bench Pro	59.0%	公式ブログ公表値
Terminal-Bench 2.1	66.0%	公式ブログ公表値
SWE-fficiency	34.8%	公式ブログ公表値
KernelBench Hard	28.8%	公式ブログ公表値
MCP Atlas	74.2	公式ブログ公表値
BrowseComp	83.5	公式モデルページ公表値
PostTrainBench	0.37	公式ブログ公表値
Video-MME	84.6	512 frames 条件での記載
OSWorld-Verified	70.06%	Max Steps 200 の内部評価記載

一方で、**MMLU** や **HumanEval** の **standalone score** は、今回確認した **official page / HF card / API docs** では見当たりません。HumanEval は公式ブログ中で **PostTrainBench** の内部ターゲットの一部として言及されるのみで、単独スコアは出ていません。したがって、「MMLU は不明」「HumanEval 単独値は不明」が正確です。 ¹⁹

重ねて重要なのは**評価方法の非対称性**です。MiniMax 自身が方法論において、**SWE-Bench** や **Terminal-Bench** などを **internal infrastructure + 特定 scaffolding (Claude Code, Terminus 2, Mini-SWE-Agent など)** で評価し、外部モデルの一部スコアは**公式 leaderboard** や **labs.scale.com** から引用したと明記しています。つまり、「M3 単体の本質性能」ではなく、**モデル + agent harness + 実行環境の複合性能**として読むべきです。知財実務ではこの点が非常に重要で、**検索精度**や **claim drafting** 以上に“**再現性ある運用設計**”が成否を決めるからです。 ²⁰

遅延とスループット

速度について、MiniMax の一次ソースは**絶対速度の tokens/s** よりも、**前世代比の演算削減と高速化率**を強く打ち出しています。公式ブログでは、**1M 文脈で per-token compute が前世代の 1/20、prefill 9倍超、decode 15倍超**とされています。Together AI も、M3 の疎注意カーネル最適化により、一般的な **agentic traffic** で **81%~125% の throughput 改善**を達成したと述べています。 ²¹

絶対的な API 実測としては、Artificial Analysis のプロバイダ比較が参考になります。そこでは、**MiniMax 提供系で約 57.8 tokens/s、他社提供系で 52.0~58.6 tokens/s** の出力速度が観測されています。また、遅延は指標の取り方でかなり見え方が変わります。**TTFT (time to first token)** では **2.7~4.3秒程度**、一方で **thinking** を含む **“time to first answer token”** では **36.8~41.3秒程度**の値が示されています。知財で長い reasoning を使う場合は、後者の体感に近づきます。要するに、**M3 は“高スループットだが、深い思考込みでは即レス型ではない”**と理解するのが実務的です。 ²²

メモリ・計算資源

ローカル配備を検討するうえで非常に重要なのが、**重みそのもののサイズ**です。HF 公式ツリー上では、**本体が 854GB、MXFP8 量子化版が 444GB**と表示されています。これは「モデルが巨大である」という抽象論ではなく、**配備の最小構成をほぼ決めてしまう物理的な制約**です。 ²³

この数字を前提にすると、BF16 の本体版は**ワークステーションクラスではなく、GPU サーバ/クラスター前提**です。MXFP8 版でも、重みだけで 444GB あるため、**8×80GB クラス以上を現実的な計画値**として見るの

が無難です。BF16 本体版なら、**16×80GB クラスを計画値に置く**ほうが安全です。これは vendor の必須要件ではなく、**HF 上の重みサイズと通常の runtime overhead を前提にした実務上の目安**です。ローカル実行自体は、HF モデルカード上で **Transformers / vLLM / SGLang / Docker Model Runner** が案内されています。²⁴

推論コストと微調整コスト

MiniMax の pay-as-you-go 料金は、**512K 以下の入力**で **\$0.30 / M input tokens**、**\$1.20 / M output tokens**、**priority** はその 1.5 倍です。**512K 超の長文入力**は **\$0.60 / M input**、**\$2.40 / M output** に上がります。Token Plan では、**\$20 / 月**で約 **1.7B token**、**\$50 / 月**で約 **5.1B token**、**\$120 / 月**で約 **9.8B token** の M3 利用枠が案内されています。²⁵

知財ワークロードに寄せた概算は次の通りです。²⁶

例	トークン条件	料金モード	概算
1件の長文明細書レビュー	入力 200k、出力 4k	標準	約 \$0.0648
1件の FTO 予備分析	入力 300k、出力 8k	標準	約 \$0.0996
大規模ポートフォリオ一括読込	入力 1M、出力 8k	長文料金	約 \$0.6192
同条件の priority	入力 1M、出力 8k	priority	約 \$0.9288

微調整コストについては、**MiniMax 自身の fine-tuning 価格表は今回確認できませんでした**。ただし、NVIDIA NIM/NeMo は M3 向けに **full SFT レシピ**と **LoRA レシピ**を公開しており、LoRA 側の設定名に **8node** が入っています。これは少なくとも、**M3 の実用的な微調整が“単機 GPU で気軽に回す”クラスではなく、multi-node 前提の重い作業**であることを示唆します。したがって、知財向けの現実路線は**まず RAG + prompt engineering + small adapters 相当の軽微カスタマイズ**から始め、**full SFT は相応の事例価値が出るまで見送るのが合理的**です。²⁷

直接比較

製品属性の比較

ここでは、**一次ソースが比較的そろ**う項目に限って比較します。閉鎖モデルのパラメータ詳細は、公開されていないものが多いため、**そのまま unknown / undisclosed**としています。²⁸

モデル	公開形態	ライセンス / 商用条件	入力モダリティ	コンテキスト	パラメータ開示	提供形態
MiniMax M3	オープンウェイト	minimax-community 。商用利用時は表示義務、年商 2,000 万ドル超は事前許諾、それ以下は通知義務	text / image / video。audio input は未対応	1M、API で最低 512K 保証	~428B total / ~23B active	HF、公式 API、Token Plan、vLLM/SGLang/Transformers ²⁹

モデル	公開形態	ライセンス / 商用条件	入力モダリティ	コンテキスト	パラメータ開示	提供形態
Gemini 3.1 Pro	クローズド	proprietary	公式に「advanced reasoning across modalities」	1M級の長文利用が公式ドキュメントで案内	非開示	Gemini API、AI Studio、Code Assist、Gemini app ³⁰
GPT-5.5	クローズド	proprietary	公式に coding / research / document-heavy tasks を強調	公開ページでは長時間タスク継続性を強調	非開示	ChatGPT と OpenAI 製品群で提供 ³¹

ベンチマーク比較の実務的な読み方

以下は、**比較可能な範囲**だけを抜き出した表です。MiniMax の一次ソースで確認できる数値を優先し、競合値が一次で確認できないものは**二次情報**と明記しています。 ³²

指標	MiniMax M3	Gemini 3.1 Pro	GPT-5.5	コメント
SWE-Bench Pro	59.0%	54.2%	58.6%	M3 は公式。Gemini / GPT は今回レビューでは二次情報確認止まり ³²
PostTrainBench	0.37	不明	0.39	公式ブログに M3 と GPT-5.5、Opus 4.7 の比較あり ³³
BrowseComp	83.5	比較値未確認	比較値未確認	M3 のみ一次確認 ³⁴
Terminal-Bench 2.1	66.0	公開 leaderboard では 70 前後の agent-combo が確認可能	公開 leaderboard では 80 前後の agent-combo が確認可能	scaffold が違うため単純比較は危険 ³⁵

結論だけ言えば、M3 は「オープンでここまで来たのは強い」という位置です。ただし、Gemini 3.1 Pro や GPT-5.5 と比べたとき、勝ち筋は**絶対性能一本ではなく、長文・マルチモーダル・配備自由度・API 単価**の総合値にあります。特に知財用途では、**巨大文脈＋図面理解＋オンプレ前提**という条件が揃うと、M3 の価値は相対的に上がります。 ³⁶

評判、コミュニティ反応、リスクシグナル

リリース直後のコミュニティ温度感は、関心は高いが、実装はまだ荒いです。HF の M3 ページはレビュー時点で **411 likes**、**Community 10**、GitHub の `MiniMax-M3` リポジトリは **247 stars / 13 issues**、MSA リポジトリは **248 stars / 1 issue** でした。数そのものは悪くありませんが、内容を見ると「広く触られ始めた」「同時に初期の詰まりも多い」という典型的な初期公開フェーズです。 ³⁷

HF Discussions では、「改良されたライセンスへの謝意」という肯定的反応がある一方、公式低ビット QAT 版の要求、`model.safetensor.index.json` の欠落、2×RTX 6000 Pro で動くか、512K output は本当か、MTP 対応状況はどうかといった、実装・配備・量子化の課題が並んでいます。これは、モデルの魅力は高いが、企業実装に必要な“整っている感”はまだ閉鎖モデルに劣ることを示します。 ³⁸

非公式コミュニティでは評価が割れています。Reddit では、M3 を「新しいお気に入り」「かなり感動した」と評価する声がある一方、別スレッドでは「複雑長時間タスクは強いが、挙動が予測しにくい」という不満も見られます。つまり、初速の印象は良いが、長期間の安定運用に関するコンセンサスはまだ形成されていないと見るのが妥当です。 ³⁹

エンタープライズ面のシグナルとしては、MiniMax 会社全体で **214,000+ enterprise clients & developers** を掲げており、M3 自体も公式 API、HF、Together AI、NVIDIA NIM/NeMo、OpenRouter 系プロバイダへ速やかに展開されています。ただし、M3 を使った公開導入事例や大企業の正式ケーススタディは、今回確認した範囲ではまだ少ないです。よって、導入判断では「会社規模・配布網」は良いシグナルだが、「M3 固有の実績」はこれから、という評価が適切です。 ⁴⁰

法務・安全面では、ライセンス自体がかなり重要です。M3 の `minimax-community` は、商用利用時の“Built with MiniMax M3”表示義務、年商 2,000 万ドル超の事前許諾義務、それ未満でも一度の通知義務を課しています。また、軍事目的、違法用途、未成年者搾取、害意ある偽情報などの禁止も明記されています。これは OSS 的に見ればかなり「条件付き」です。知財部門が社内 PoC で使うだけなら比較的扱いやすい一方、対外サービス化・商用再配布・クライアント提供 SaaS には必ずライセンス確認が必要です。 ⁴¹

さらに、MiniMax という会社の reputational risk もゼロではありません。Reuters は 2026 年 2 月、Anthropic が MiniMax を含む中国 AI 企業に対して Claude の大規模無断抽出・蒸留を主張したと報じました。また Reuters は 2025 年 9 月、Disney / Universal / Warner Bros. Discovery が MiniMax の Hailuo AI を相手に著作権侵害訴訟を提起したとも報じています。これらは M3 単体の違法性を示すものではありませんが、ベンダー審査・調達・リスク委員会で必ず確認される論点です。 ⁴²

知財ワークフローへの適用

M3 が知財実務で面白いのは、長文、画像、動画、ツール利用、配備自由度が一つにまとまっている点です。JPO は AI 関連技術の審査事例を拡充しており、USPTO は AI ツール利用について既存ルールの順守とリスク緩和を求め、JPO と EPO は発明者を自然人に限定しています。したがって、M3 を知財実務に入れるときの基本線は、「調査・要約・比較・下書きは AI、最終法律判断・出願責任・発明者認定は人間」です。 ⁴³


推奨ユースケースと実装パターン

以下は、M3 の能力と各特許庁の AI 利用上の注意を前提にした、実務向けの推奨設計です。表の内容は運用提案であり、法的助言そのものではありません。 ⁴⁴

用途	M3 が向く理由	推奨プロンプト例	最低限の人手検証
先行技術調査	1M 文脈で複数公報・論文・製品資料をまとめて保持しやすい	「以下の公報群から、請求項1の全構成要件に対する開示箇所を 段落番号付き で claim chart 化してください。未充足要件は“未発見”と明示。」	段落番号・図番号・クレーム引用の原文照合
特許性分析	差分抽出と論点整理が速い	「主引用例Aと副引用例Bを前提に、想到容易性の論点を 肯定説/否定説 の両面から整理し、根拠箇所を引用。」	進歩性判断は必ず弁理士/弁護士がレビュー
クレームドラフティング	長い実施形態群から請求項候補を設計しやすい	「明細書本文から、独立請求項3案と従属請求項10案を作成。各要素のサポート箇所を付す。機能表現が広すぎる箇所は警告。」	サポート要件、明確性、実施可能要件の確認
FTO 予備評価	複数特許ファミリーの構成比較に向く	「対象製品仕様と引用特許の独立請求項を比較し、 侵害リスク高/中/低 を暫定評価。判断不能箇所は追加調査項目として列挙。」	最終 FTO は claim construction を含め弁理士主導
パテントランドスケープ	長文集約と分類整理に強い	「100件の要約から、技術クラスター、主要出願人、空白領域、最近の出願傾向を表形式で整理。」	母集団の偏り、検索式の妥当性を再確認
特許翻訳・和英整序	長い請求項の一貫性維持に有利	「以下の請求項を英訳。用語対応表を維持し、訳語が変わる箇所は一覧表示。」	key term glossary と原文対照
図面・画像先行技術	画像入力ネイティブ対応	「添付図面から構成要素を抽出し、クレーム用語候補と対応関係を表にしてください。」	図面番号・参照符号の人手確認
動画先行技術	動画入力対応。装置操作や UI 動作の証拠整理に使える	「添付動画の時系列イベントを抽出し、どの時点で請求項要件が満たされるかを時刻付きで整理。」	実証動画の真正性・時刻・操作条件の確認

推奨アーキテクチャ

未公開発明やクライアント資料を扱うなら、**オンプレまたは専有 VPC 配備**が第一候補です。M3 は HF 重みとして公開されているので、**特許 DB、社内 DMS、図面 OCR、社内用語集、出願テンプレート**を横に置いた **RAG + tool-calling + evidence-first prompt** の構成が取りやすいです。M3 単独で考えさせるより、**検索と証拠抽出は deterministic tooling、整理と草案は M3** に寄せたほうが、知財品質は安定します。 45



データ取扱い、機密保持、検証戦略

機密保持では、NIST AI RMF の考え方どおり、**Govern / Map / Measure / Manage** を小さく実装するのが有効です。具体的には、**matter 単位のアクセス制御、作業用コピーの作成、入力ログの最小化、出力の保存先分離、案件終了時の削除、API 利用時の DPA/契約確認**です。公開 API へ未公開発明をそのまま送る運用は、情報漏えいよりもむしろ**守秘・職責・調査再現性**の面で危険です。 46

精度・妥当性の担保は、プロンプトよりも**検証フロー設計**が重要です。知財用途では、少なくとも次の四つを標準化すべきです。

第一に、**根拠のない断定を禁止し、出典不明なら“不明”**と言わせること。

第二に、**すべての重要結論に公報番号・段落番号・請求項番号・図番号・動画時刻を付ける**こと。

第三に、**構成要件ごとの claim chart を mandatory output にする**こと。

第四に、**別モデルまたは rule-based checker による cross-check**を行うことです。USPTO の AI ツール利用ガイダンスが強調するのも、結局は**既存の責任と規律は AI を使っても免れない**という点です。 47

特許庁ルールとの整合

人間が最後に責任を持つ、という点は各庁で共通しています。JPO は**発明者欄に AI を記載できない**と明示し、EPO も**inventor は human でなければならない**としています。USPTO も 2025年改訂ガイダンスで、**inventor は natural person**であり、**AI は人間発明者の道具**だと再確認しています。したがって、M3 は**発明者候補の列挙、寄与整理、先行技術とのマッピング補助**には使えても、**AI を発明者として扱う運用や、AI 出力を無検証で出願書類へ流し込む運用**は避けるべきです。 48

実務提言とパイロットチェックリスト

M3 を選ぶべき場面は明確です。**長大コンテキスト、図面・動画入力、コード／ツール利用、オンプレ志向、API 単価の低さ、オープンウェイトの柔軟性**が必要なら、M3 はかなり魅力的です。逆に、**第三者検証の厚さ、完成された企業サポート、より予測可能な managed service、法務・調達部門が好むベンダー安定性**を重視するなら、Gemini 3.1 Pro や GPT-5.5 などの閉鎖モデルのほうが通しやすい局面があります。 49

実務上のおすすめは、**いきなり全社導入ではなく、知財部門限定のパイロット**です。PoC の成功条件は「モデルが賢いか」ではなく、**claim chart の再現率、引用の正確性、レビュー時間削減、誤引用率、未公開案件の秘密保持適合、監査ログ整備**で測るべきです。特に M3 はライセンス条件があるため、**内向き業務ツールなのか、外向きクライアント提供なのか**を最初に分けておくべきです。 50

パイロットの最小チェックリスト

観点	推奨
対象業務	先行技術調査、claim chart、特許性メモ、翻訳から始める
対象データ	公開公報 + 社内で開示許可済み案件だけに限定
配備	まずは専有環境。未公開発明は公開 API を避ける
指標	根拠引用率、誤引用率、レビュー時間、再実行再現性
ガバナンス	matter 別アクセス制御、出力ログ、削除ルール、担当者責任
ライセンス	<code>minimax-community</code> の表示義務・通知/許諾条件を確認
品質保証	evidence-first prompt、二重チェック、最終 human sign-off

開かれた論点と限界

今回のレビューで、次の点は未確定または未公開でした。

完全な M3 technical report、訓練コーパスの比率と総量、MMLU/HumanEval 単独スコア、独立再現済みの包括ベンチマーク、公式の fine-tuning 価格表、M3 固有の公開 system card / safety card です。これらは、特に企業調達・法務審査・社内セキュリティ委員会では追加確認対象になります。 ⁵¹

主要ソース

公式・一次ソース

- [MiniMax 公式モデルページ](#)
- [MiniMax 公式ローンチ記事](#)
- [Hugging Face 公式モデルカード](#)
- [Hugging Face config.json](#)
- [MiniMax API Docs: Chat Completions](#)
- [MiniMax API Docs: Anthropic-compatible Messages](#)
- [MiniMax API 料金](#)
- [MSA GitHub リポジトリ](#)
- [MSA arXiv](#)

比較・周辺一次ソース

- [Gemini 3 系列の公式開発者ドキュメント](#)
- [Gemini 3.1 Pro Preview 公式ページ](#)
- [OpenAI GPT-5.5 公式発表](#)

知財・ガバナンス一次ソース

- [USPTO: AI tools guidance](#)
- [USPTO: revised inventorship guidance for AI-assisted inventions](#)
- [JPO: 発明者等の表示について](#)
- [JPO: AI関連技術に関する特許審査の事例](#)
- [EPO: AI cannot be named as inventor](#)
- [NIST AI Risk Management Framework](#)
- [WIPO AI and IP overview](#)

日本語カバレッジ

- [GIGAZINE の MiniMax M3 紹介記事](#)
- [WEEL の MiniMax M3 解説](#)

¹ ⁸ ⁹ ²⁸ ²⁹ <https://huggingface.co/MiniMaxAI/MiniMax-M3>

<https://huggingface.co/MiniMaxAI/MiniMax-M3>

² ¹⁰ ¹³ ¹⁴ <https://huggingface.co/MiniMaxAI/MiniMax-M3/raw/main/config.json>

<https://huggingface.co/MiniMaxAI/MiniMax-M3/raw/main/config.json>

- 3 4 5 16 17 18 19 20 21 32 33 35 51 <https://www.minimax.io/blog/minimax-m3>
<https://www.minimax.io/blog/minimax-m3>
- 6 23 24 45 <https://huggingface.co/MiniMaxAI/MiniMax-M3/tree/main>
<https://huggingface.co/MiniMaxAI/MiniMax-M3/tree/main>
- 7 <https://venturebeat.com/technology/minimax-teases-upcoming-m3-model-with-new-sparse-attention-mechanism-and-15-6x-response-speed-boost>
<https://venturebeat.com/technology/minimax-teases-upcoming-m3-model-with-new-sparse-attention-mechanism-and-15-6x-response-speed-boost>
- 11 15 34 44 <https://www.minimax.io/models/text/m3>
<https://www.minimax.io/models/text/m3>
- 12 <https://platform.minimax.io/docs/api-reference/text-openai-api>
<https://platform.minimax.io/docs/api-reference/text-openai-api>
- 22 <https://artificialanalysis.ai/models/minimax-m3/providers>
<https://artificialanalysis.ai/models/minimax-m3/providers>
- 25 26 36 49 <https://platform.minimax.io/docs/guides/pricing-paygo>
<https://platform.minimax.io/docs/guides/pricing-paygo>
- 27 <https://build.nvidia.com/minimaxai/minimax-m3/fine-tune>
<https://build.nvidia.com/minimaxai/minimax-m3/fine-tune>
- 30 <https://ai.google.dev/gemini-api/docs/gemini-3>
<https://ai.google.dev/gemini-api/docs/gemini-3>
- 31 <https://openai.com/index/introducing-gpt-5-5/>
<https://openai.com/index/introducing-gpt-5-5/>
- 37 38 <https://huggingface.co/MiniMaxAI/MiniMax-M3/discussions>
<https://huggingface.co/MiniMaxAI/MiniMax-M3/discussions>
- 39 https://www.reddit.com/r/opensource/comments/1u07f55/extremely_impressed_with_minimax_m3/?tl=ja
https://www.reddit.com/r/opensource/comments/1u07f55/extremely_impressed_with_minimax_m3/?tl=ja
- 40 <https://www.minimax.io/>
<https://www.minimax.io/>
- 41 50 <https://huggingface.co/MiniMaxAI/MiniMax-M3/raw/main/LICENSE>
<https://huggingface.co/MiniMaxAI/MiniMax-M3/raw/main/LICENSE>
- 42 <https://www.reuters.com/world/china/chinese-companies-used-claude-improve-own-models-anthropic-says-2026-02-23/>
<https://www.reuters.com/world/china/chinese-companies-used-claude-improve-own-models-anthropic-says-2026-02-23/>
- 43 https://www.jpo.go.jp/system/laws/rule/guideline/patent/ai_jirei.html
https://www.jpo.go.jp/system/laws/rule/guideline/patent/ai_jirei.html
- 46 <https://www.nist.gov/itl/ai-risk-management-framework>
<https://www.nist.gov/itl/ai-risk-management-framework>
- 47 <https://www.uspto.gov/about-us/news-updates/uspto-issues-guidance-concerning-use-ai-tools-parties-and-practitioners>
<https://www.uspto.gov/about-us/news-updates/uspto-issues-guidance-concerning-use-ai-tools-parties-and-practitioners>

48 <https://www.jpo.go.jp/system/process/shutugan/hatsumei.html>
<https://www.jpo.go.jp/system/process/shutugan/hatsumei.html>