


GLM-5.3-Flash 徹底解剖：市場を揺るがす新モデルの光と影

技術的ブレイクスルーの正体と、エンタープライズ
導入における現実的リスク評価

調査基準日：2026年8月27日



規模と形態

320B / 18B

総パラメータ約320B、アクティブ18BのMoE構成。100万（1M）トークン文脈。ネイティブマルチモーダル（テキスト＋画像）。



出自

Ox Alpha

発表前にOpenRouter/OpenCode上でテストされ話題を呼んだ匿名モデルの正体。



ライセンス

MIT License

オープンウェイト。商用利用・改変・再配布が可能。




衝撃の価格

\$0.15 / \$0.50

入力100万トークンあたり0.15ドル、出力0.50ドル。本体（GLM-5.3）の約10分の1の価格。

系譜と進化：蒸留という誤解



既存基盤の後訓練スケーリングではなく、注意機構を刷新して新規に学習（約30Tトークン）された別システムの基盤モデルである。

アーキテクチャ解剖：圧倒的低コストのエンジン

The Massive Base

総パラメータ 320B (約321B) /
288個の Routed Experts

The Efficient Output


アクティブ・パラメータ 18B /
選択されるExpertは8個

The Hybrid Filter

DSA (疎注意: NoPE sparse MLA) と
KDA (線形注意) のハイブリッド /
インデクサ圧縮 (IndexPool)

注意計算量を約3.01倍、
KVキャッシュを約4.44倍削減

価格と知能のマトリックス：新たな下限の定義



Claude Opus 4.8 (57点水準) に匹敵する知能を、GPT-5.4 Miniをはるかに下回る価格で提供。同規模オープンウェイトモデルの中央値 (27点) を圧倒。

現実の評価：神話（Hype）と現実（Reality）

公称値 (Myth)	第三者評価 (Reality)
DeepSWEスコア 80%の衝撃	58.4～63% に収束 (10問サブセットに基づく誤解。 フルセット113問での独立検証結果)
Claude Opus 4.8と 全方位で同等	コーディング/エージェント系の 一部指標のみ成立 (視覚性能はGemini 3.7 Flashに劣後)
再現可能な 圧倒的ベンチマーク	自社harness依存 (Z.ai Code Benchは非公開で 外部監査が不可能)

コストの代償：速度と冗長性

出力速度: 48.7 トークン/秒



TTFT: 1.52秒

(同クラス中央値の67より明確に遅い)

中央値

中央値: 1億1,000万トークン

GLM-5.3-Flash

冗長性: 1億5,000万トークンを生成

「著しく遅く、非常に冗長」

この特性により、リアルタイムの対話UI（チャットボット）よりも、夜間バッチ処理や長時間稼働のエージェントタスク（Browser/Computer Use）に適している。

データ主権とコンプライアンス：エンドポイントのリスク評価

Z.ai 公式 API リスク (高)

- ・シンガポール運用であっても、中国法域 (2017年国家情報法、データ安全法等) の適用可能性が論点に。
- ・規制業種や機密データの直接送信は回避すべき。

自己ホスト (低)

- ・MITライセンスは最も寛容。収益閾値や用途制限なし。
- ・エンドポイントを自社インフラ内に留めることでデータ越境問題を根本から回避可能。

キーメッセージ: リスクは「モデルそのもの」ではなく「エンドポイント」に存在する。

安全性とアライメント：二重用途性への警戒



サイバー能力の強化: 脆弱性2,436件の発見能力を公式が主張。

アライメントの欠如: 先行モデル時点で「攻撃的セキュリティおよび生物系のタスクを一切拒否しなかった」（対照的にOpus 4.7は徹底拒否）。

検閲バイアス: 政治的話題における高い拒否率や不正確な応答。

「能力のフロンティアは、必ずしもリスク管理のフロンティアではない。**二重用途性（Dual-use）への強い警戒が必要。**」

The Engine 統合評価：4つの戦略的柱

1. 新規基盤 (New Foundation)

- GLM-5.3の使い回しではない、ゼロからの最適化。

2. ハイブリッド注意 (Hybrid Attention)


- DSA(疎注意)とKDA(線形注意)の融合による計算量削減。中国勢の技術的収斂。

3. 国産チップ (Domestic Silicon)


- 米国エンティティリスト下での10万枚超の国産AIチップ集群とSGLangベースの自社エンジンによる端到端3倍高速化。

4. MITライセンス (MIT License)

- 制限のない完全なオープンウェイト戦略による市場シェア獲得。



エンタープライズ・ルーティング・フローチャート




自己ホスト (Self-Hosting) インフラ要件

Hardware Requirements (ハードウェア要件)

- Hopper世代以降のGPUが必須。
- 目安：8基のGPUノード（またはGB200のTP4）。
- メモリ要件：FP8量子化で約306GiB（BF16の場合はその約2倍）。

Software Stack (ソフトウェア要件)

- 推論エンジン：SGLang または vLLM。
- 依存関係：FlashInfer 0.6.17 以降。
- Hugging Face提供：zai-org/GLM-5.3-Flash



戦略的ネクストステップ (Action Plan)

Step 1: 割引期間中のAPI PoC検証 (～9/9 UTC+8)

半額（入力0.075/出力0.25ドル）期間を利用し、
非機密データでの高
頻度ワークロード
（夜間バッチ、自動化
タスク）を検証。

Step 2: 自社タスクでの ベンチマーク再構築

自社harnessに依存
する公称値ではなく、
社内評価（特に
日本語性能）と
SWE-bench
Verified等への正式
掲載を待つ。

Step 3: 採用閾値（ゲート） の定義

GGUF/MLXの安定版
提供の確認。
検閲・安全性に関する
独立監査をクリアした
場合のみ、本番環境
への導入を前進させる。

「フロンティア級の知能を、民生的な電力価格で。」

GLM-5.3-Flashは、AIの価格破壊とオープン化の新たな基準を打ち立てました。しかし、真の勝者はこのモデルを「盲信」する企業ではなく、技術的制約（速度・冗長性）と地政学的リスク（データ主権（データ主権・検閲）を理解し、自社のルーティング・ルーティング・アーキテクチャの中に適切に「隔離・統合」できる企業です。