

Cloud Run ではじめる LLM/MCP サーバー運用と セキュリティ対策

新井 雅也

Syspective Inc.



Tokyo

Proprietary



新井 雅也

株式会社 Synspective
プリンシパル

GDE (Google Developer Experts)



本日本話すること

LLM や MCP サーバーを Cloud Run で運用する際の
アーキテクチャ例とセキュリティ対策のポイント

本日は話しないこと


- LLM や MCP サーバー、AI アプリケーション自体の実装に関連した内容
- AI アプリケーションに着目したセキュリティ対策
 - 一部関連する箇所のみ言及



みなさん、普段の業務や開発で
LLM や MCP サーバーを利用していますか？

まずは簡単に LLM と MCP のおさらいから

LLM（大規模言語モデル）とは




膨大なデータと深層学習により構築された言語モデル

- ラフに伝えるなら「プログラムがたくさんの言葉を学ぶことによって、人間のように文章を理解し作り出せるもの」

例) Gemini 2.5, GPT-4.5, Claude Sonnet 4

MCP とは




AI モデルが外部のツールを呼び出すための **標準化プロトコル**

- MCP ホスト、MCP クライアント、MCP サーバーで構成


LLM が学習した以外の情報に対して、「LLM の代わりに外部から情報を提供する」役割を担うのが **MCP サーバー**

LLM / MCP サーバーが利用された処理フロー


LLM / MCP サーバーが利用された処理フロー




LLM / MCP サーバーが利用された処理フロー




LLM / MCP サーバーが利用された処理フロー




LLM / MCP サーバーが利用された処理フロー




LLM / MCP サーバーが利用された処理フロー




LLM / MCP サーバーが利用された処理フロー




LLM / MCP サーバーが利用された処理フロー



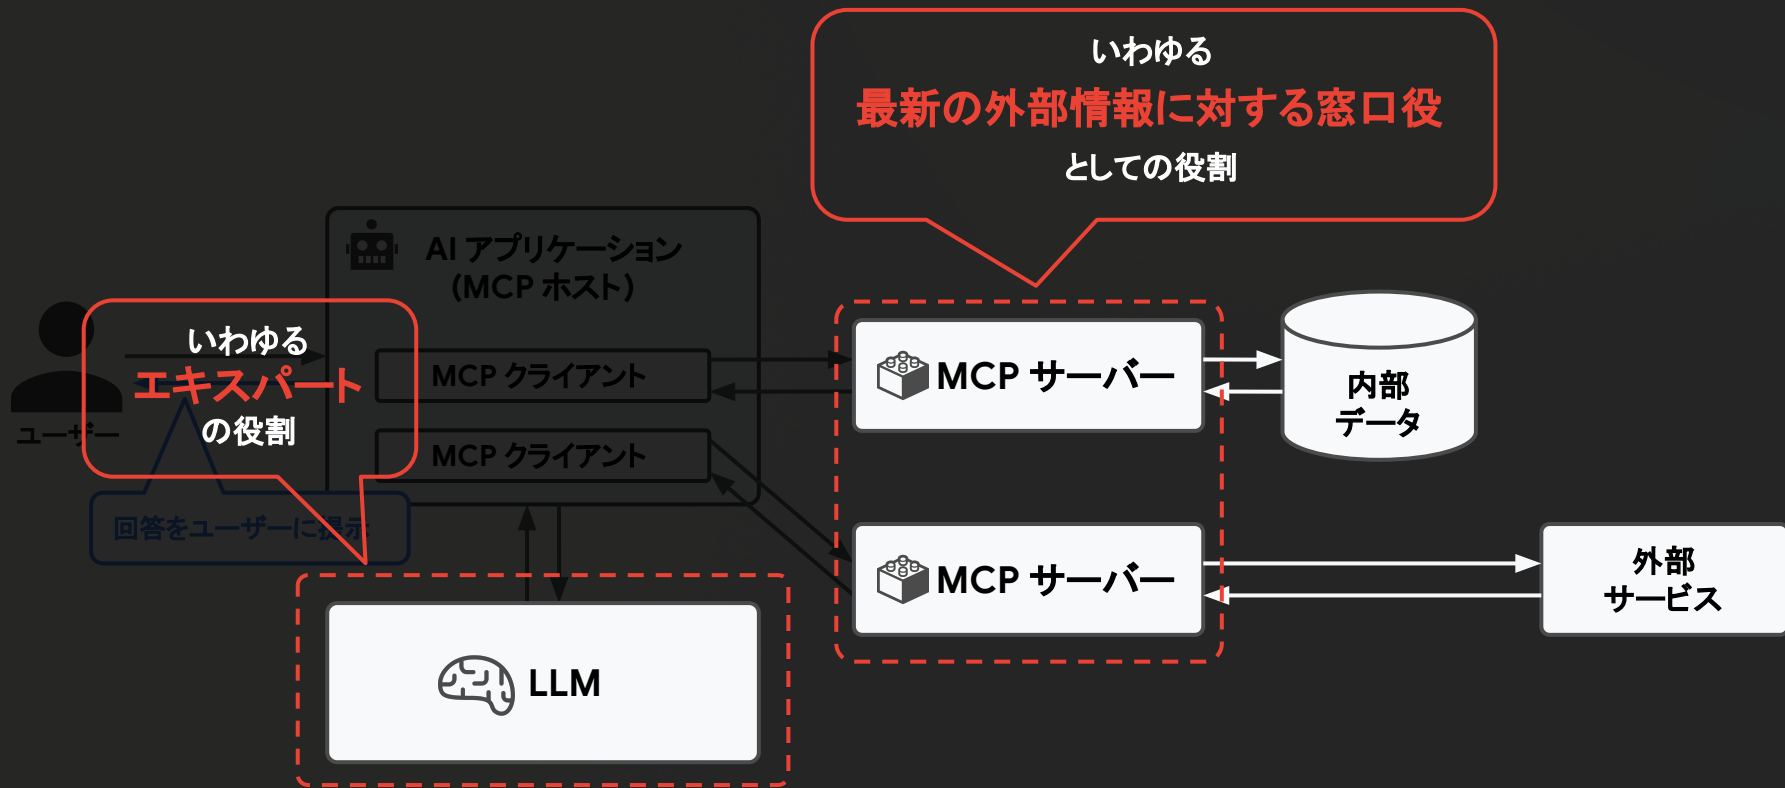
LLM / MCP サーバーが利用された処理フロー



LLM / MCP サーバーが利用された処理フロー



ここまでのまとめ



自前の


みなさん、普段の業務や開発で

LLM や MCP サーバーを利用していますか？

自前の

なぜ、LLM や MCP サーバーを
使う必要があるのでしょうか？

LLM を自前で用意するユースケース




ドメインに特化した モデルの利用やカスタマイズ

- 金融知識、法的知識

ガバナンス・コンプライアンス要件

- 特定地域外へのデータ転送・保存が制限される規制産業等

MCP サーバーを自前で用意するユースケース



ビジネスユースケースに特化した情報の参照

既存のシステム・内部 API による情報参照

- 公開 MCP サーバーでは提供されていない情報の取得

自前の

なぜ、LLM や MCP サーバーを
使う場合に Cloud Run を選択するのか？

一番のメリットは ゼロスケール



- 未利用時はインスタンス数を 0 にできる
 - アイドルコストが発生しない
 - 後述する GPU 利用時のコストを抑えられる
- 散発的な利用特性 と相性が良い
 - 課金は秒単位


LLM ワークロード向けに GPU が利用可能




- GPU のドライバーインストール等は不要
- 数～数十秒でデプロイ
- 初期利用時はクォーター増加が必要
- 残念ながら、本発表準備時点（2025 年 7 月 23 日）では東京・大阪リージョンでは未対応

コンプライアンス要件の観点では
今後に期待 ...

Cloud Run による LLM / MCP サーバーの アーキテクチャ例




Cloud Run による LLM / MCP サーバーの アーキテクチャ例



LLM や MCP サーバーを Cloud Run で運用する際、
必要なセキュリティ対策のアプローチ は？

想定するアーキテクチャ構造



LLM / MCP サーバーだろうと、
結局のところは **Web アプリケーション**

LLM / MCP サーバーだろうと、 結局のところは Web アプリケーション

- ・依然として、従来の Web アプリケーションに関するセキュリティ対策 は効果的
- ・加えて、AI アプリケーション特有の観点 も考慮

Web App セキュリティ × 生成 AI App セキュリティ

Web App セキュリティ × 生成 AI App セキュリティ

OWASP Top 10

Web アプリケーションにとって
最も重要なセキュリティリスク を
まとめたもの

※<https://owasp.org/Top10/>

OWASP Top 10 for AI Applications 2025

生成 AI アプリケーションにおける
主要な 10 のセキュリティリスク を
まとめたもの

※<https://genai.owasp.org/llm-top-10/>

Web App セキュリティ × 生成 AI App セキュリティ

OWASP Top 10

不適切な
アクセス制御

暗号化の失敗

インジェクション

セキュアでない
設計

セキュリティ設定の
不備

脆弱で古い
コンポーネント

識別と認証の
失敗

ソフトウェアと
データの整合性の失敗

セキュリティログと
モニタリングの失敗

SSRF

OWASP Top 10 for AI Applications 2025

プロンプト
インジェクション

機密情報の漏えい

サプライチェーン

データやモデルの
汚染

不適切な出力の
ハンドリング

過剰な
代理行為

システムプロンプト
の流出

ベクトル化と
埋め込みの脆弱性

不正確な情報

際限のない消費

LLM や MCP サーバーを Cloud Run で運用する際、
Google Cloud 観点の具体的な セキュリティ対策 は？

Web App セキュリティ × 生成 AI App セキュリティ

OWASP Top 10

不適切な
アクセス制御

暗号化の失敗

インジェクション

セキュアでない
設計

セキュリティ設定の
不備

脆弱で古い
コンポーネント

識別と認証の
失敗

ソフトウェアと
データの整合性の失敗

セキュリティログと
モニタリングの失敗

SSRF

OWASP Top 10 for AI Applications 2025

プロンプト
インジェクション

機密情報の漏えい

サプライチェーン

データやモデルの
汚染

不適切な出力の
ハンドリング

過剰な
代理行為

システムプロンプト
の流出

ベクトル化と
埋め込みの脆弱性

不正確な情報

際限のない消費

本発表にて割愛する項目

OWASP Top 10

開発プロセスや
アプリケーション側実装に依存する観点

インジェクション

セキュアでない
設計

脆弱で古い
コンポーネント

識別と認証の
失敗

ソフトウェアと
データの整合性の失敗

SSRF

OWASP Top 10 for AI Applications 2025

LLM 出力や挙動の妥当性に関する観点

システムプロンプト
の流出

ベクトル化と
埋め込みの脆弱性

不正確な情報

Web App セキュリティ × 生成 AI App セキュリティ

OWASP Top 10

不適切な
アクセス制御

暗号化の失敗

インジェクション

セキュアでない
設計

セキュリティ設定の
不備

脆弱で古い
コンポーネント

識別と認証の
失敗

ソフトウェアと
データの整合性の失敗

セキュリティログと
モニタリングの失敗

SSRF

OWASP Top 10 for AI Applications 2025

プロンプト
インジェクション

機密情報の漏えい

サプライチェーン

データやモデルの
汚染

不適切な出力の
ハンドリング

過剰な
代理行為

システムプロンプト
の流出

ベクトル化と
埋め込みの脆弱性

不正確な情報

際限のない消費

Cloud Run のIAM 権限に関連した対策

OWASP Top 10

不適切な
アクセス制御

セキュリティ設定の
不備

OWASP Top 10 for AI Applications 2025

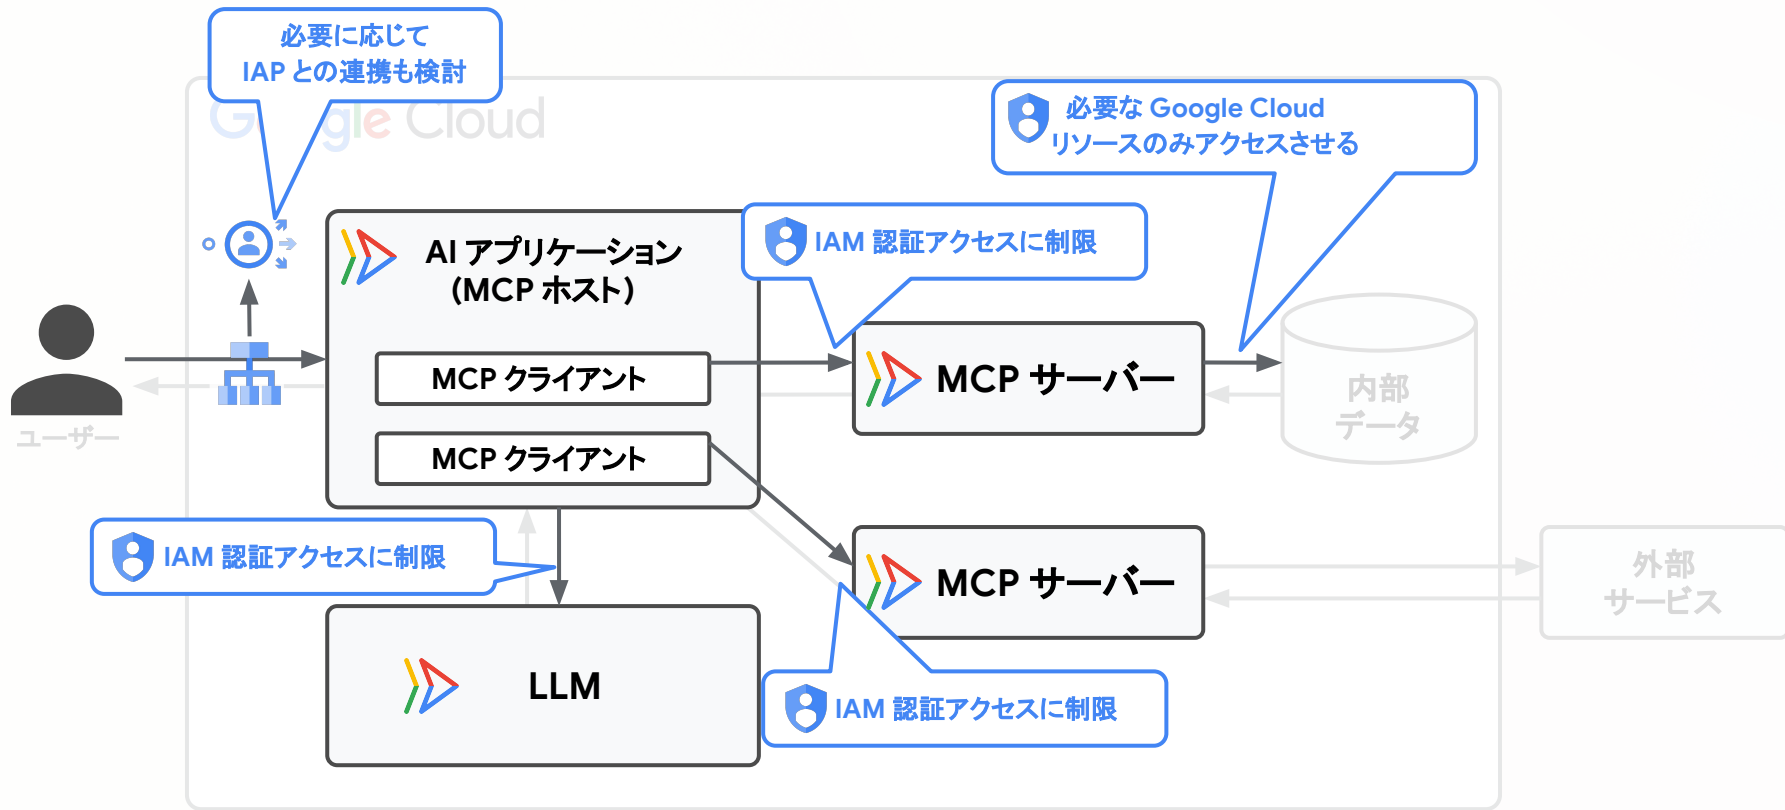
プロンプト
インジェクション

意図しないLLMの
挙動に対する考慮が必要

機密情報の漏えい

意図しない機密データの
出力への対策が必要

IAM による Cloud Run 実行とその他アクセスを制御



通信・データの暗号化に関連した対策

OWASP Top 10

暗号化の失敗

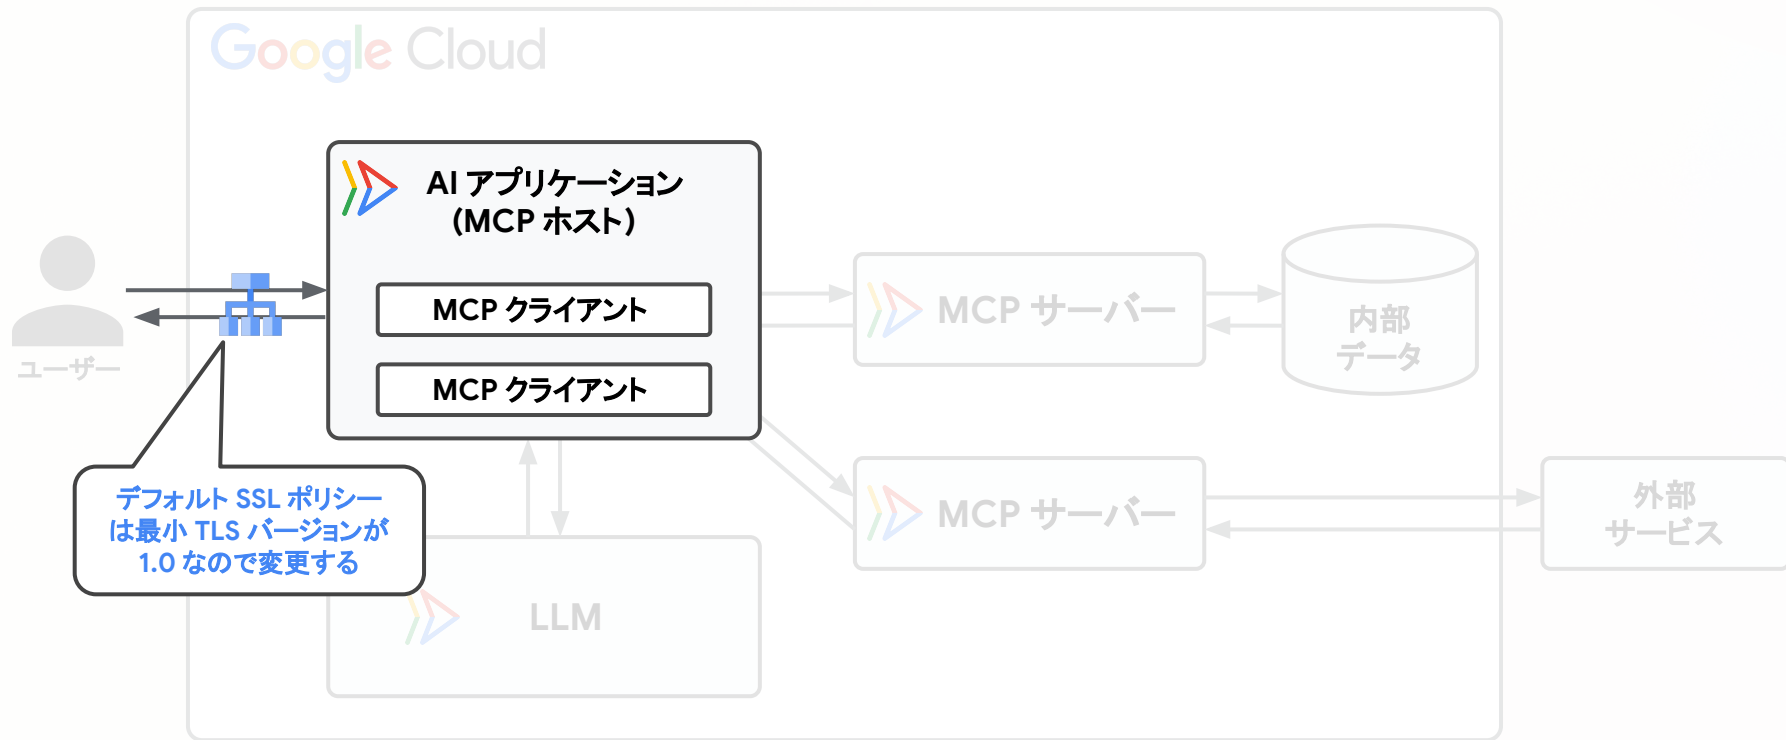
脆弱な暗号化アルゴリズム
の利用に対する考慮

セキュリティ設定の
不備

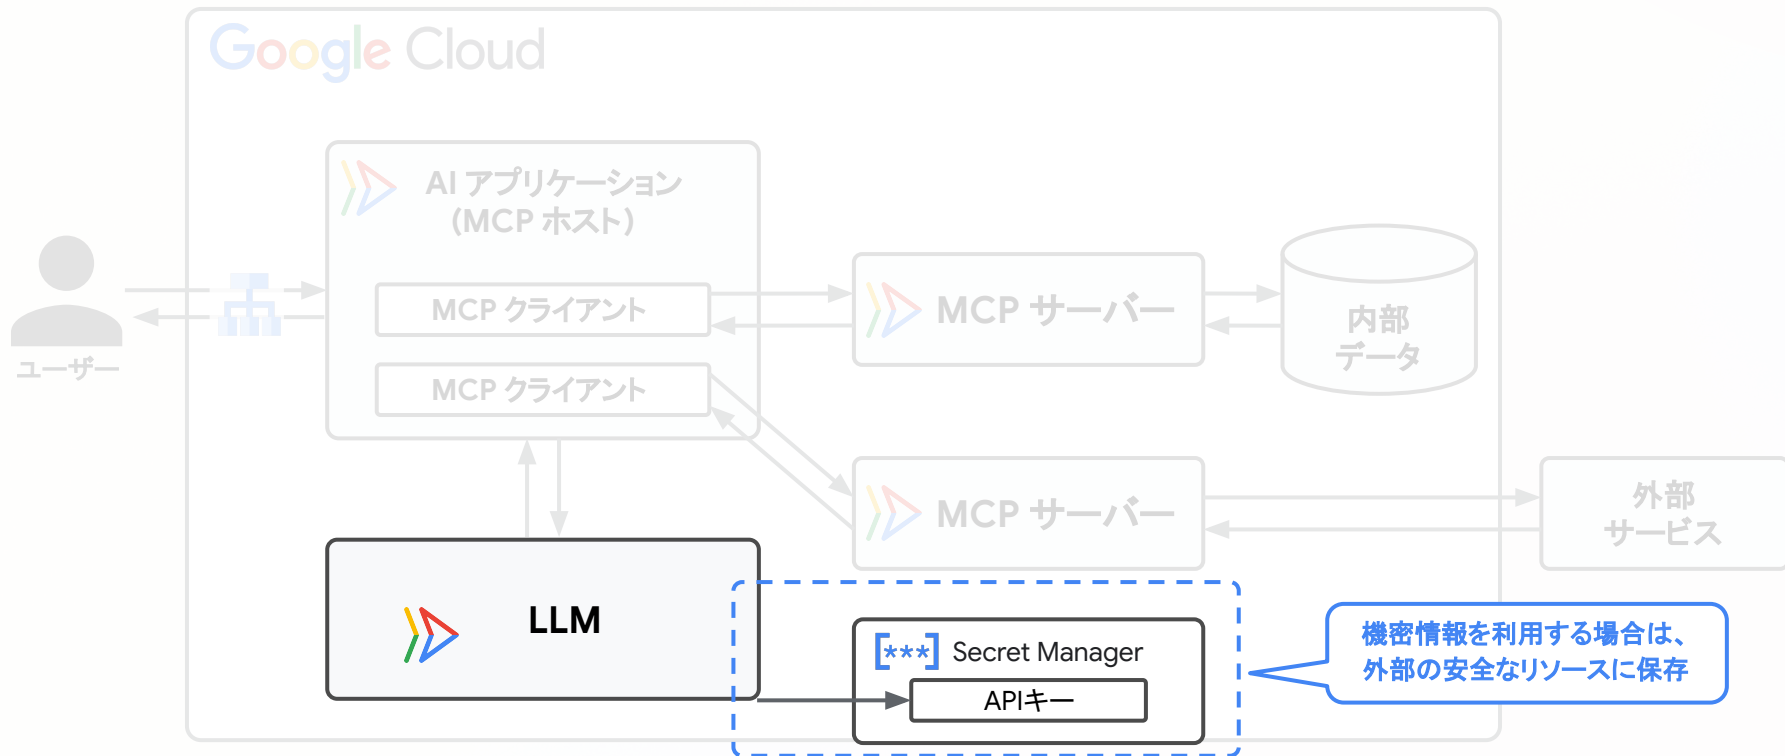
デフォルト値の利用や
適切な機密情報の管理

OWASP Top 10 for AI Applications 2025

インターネットアクセスに External ALB を 利用している場合は ポリシーの設定に注意



Secret Manager による機密情報の外部受け渡し



意図しないデータアクセス制御に関連した対策

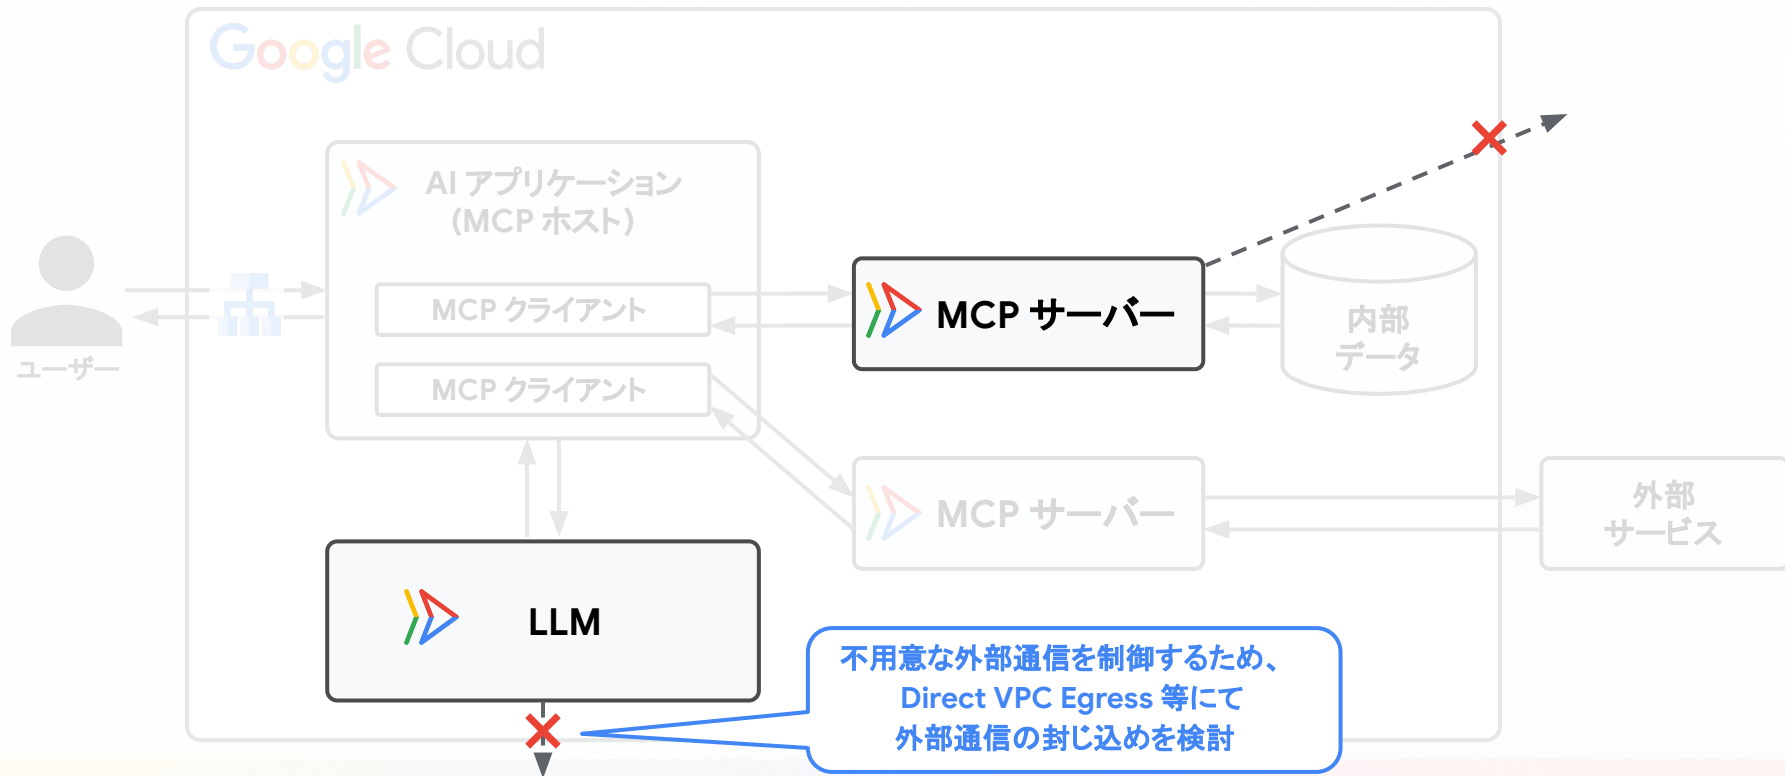
OWASP Top 10

OWASP Top 10
for AI Applications 2025

データやモデルの
汚染

意図しないデータや
リソースに対するアクセスの考慮

外部通信が不要な場合は制御



異常な振る舞いに対するロギング観点の対策

OWASP Top 10


セキュリティログと
モニタリングの失敗

OWASP Top 10 for AI Applications 2025


不適切な出力の
ハンドリング

異常なパターンを検出できるよう、ロギ
ングや監視を検討

Cloud Logging に異常パターンが記録されるように留意



参考) 不適切な入出力のブロックやフィルタリングは アプリケーション実装やモデル選定で対処



コスト消費を考慮したリソース制御に対する対策


OWASP Top 10

OWASP Top 10
for AI Applications 2025

想定外のクラウドコスト発生に
対する考慮

際限のない消費

需要に合わせた GPU のクォータとインスタンス数の制御



セキュリティ対策に関するまとめ

- IAM 認証による Cloud Run アクセス制御
- IAP を利用した認証
- External ALB における デフォルト SSL ポリシーの変更
- Secret Manager を利用した機密データの管理
- Direct VPC Egress 等による パブリックアクセスの制御
- 異常パターンのロギング
- インスタンス数やクォータ制御 による想定外コスト発生を抑止

まとめ

本発表のまとめ



- LLM と MCP の概要
- 自前 LLM と MCP サーバー運用のユースケース
- LLM と MCP を Cloud Run で運用する利点とアーキテクチャ例
- OWASP Top 10 & OWASP Top 10 for AI Applications 2025
- Cloud Run 上のセキュリティ対策のポイント

ご清聴いただき、
ありがとうございました。

