

より良いユーザー体験を  
提供するために。  
悪質コメントを検知する  
ソリューションを解説

Wonha Shin

Google Cloud Japan G.K.  
Customer Engineer



# スピーカー自己紹介



Wonha Shin

グーグル・クラウド・ジャパン合同会社  
カスタマーエンジニア

サービス企業でソフトウェア エンジニアとしてキャリアを始め、

- 開発共通基盤の構築・運用
- マイクロサービス設計
- CI/CD パイプラインの構築
- 社内クラウドや OSS を用いたプラットフォームの構築・運用

などの業務を担当していました。

現在はゲーム業界のお客様向けに Google Cloud の  
技術的な支援を行っています。



# 多様なユーザーが楽しめる ゲームを支える AI 技術



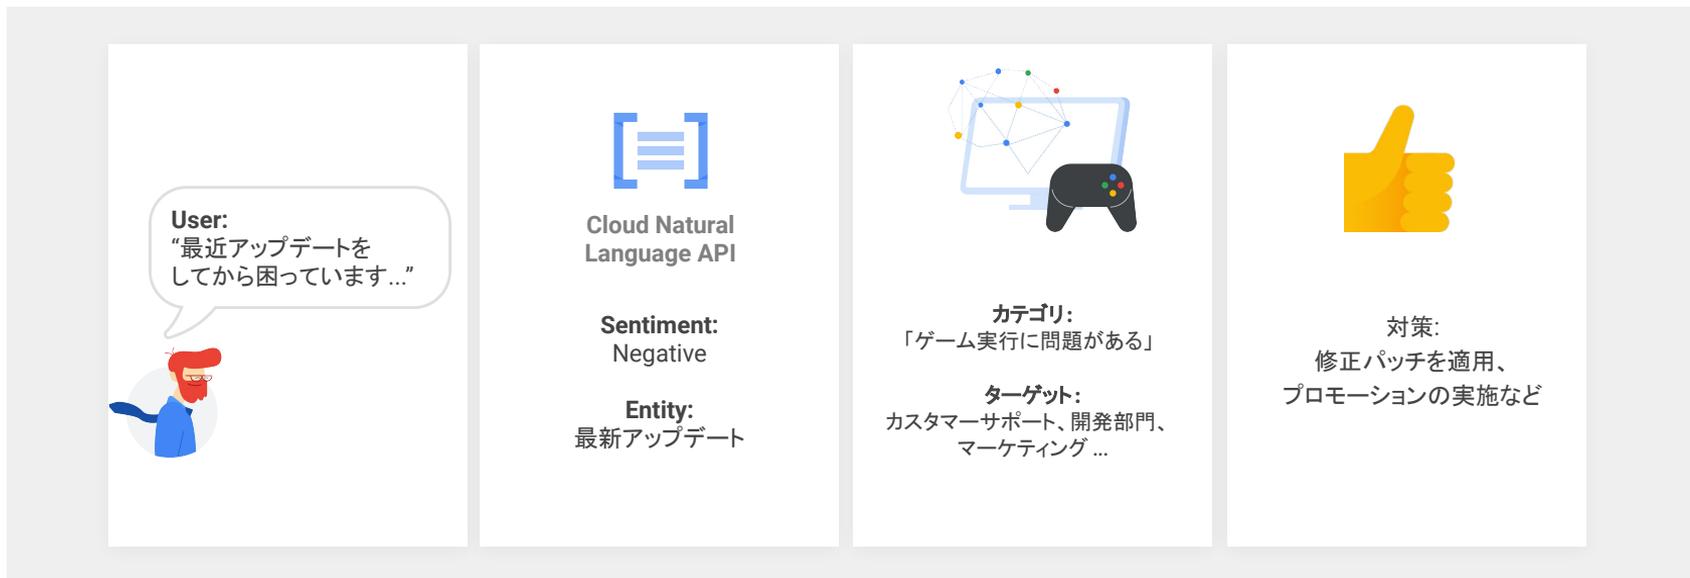
# 様々なユーザーの言語を自動翻訳

- Cloud Translation API
- 100+ の言語を検知・翻訳
- カスタム辞書でゲーム内の用語を登録
- AutoML Translation でモデルカスタマイズ



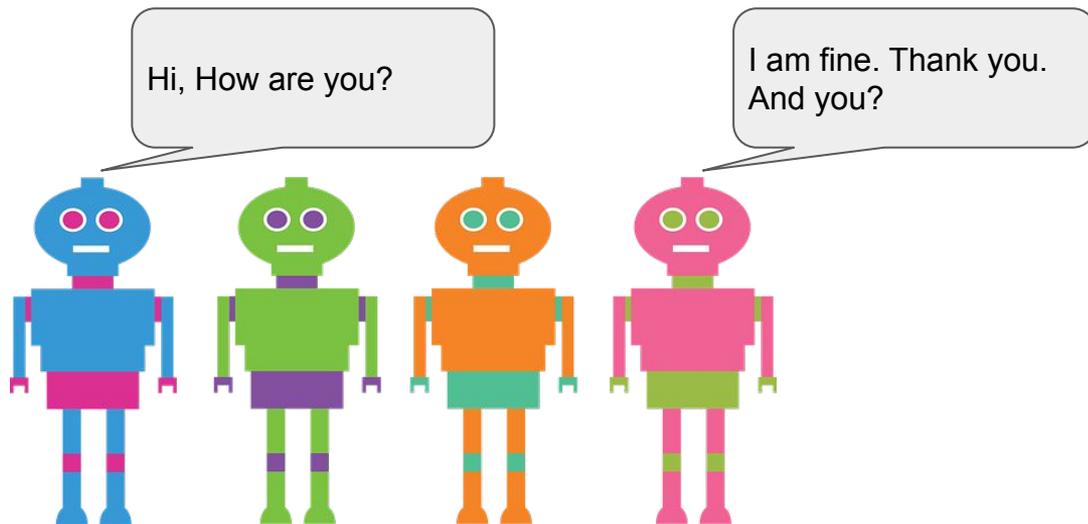
# ユーザーの感情分析

ゲーム内及びコミュニティ掲示板などのテキストから、ユーザーの感情を分析



# 会話ができる NPC を実現

Dialogflow で単純なロジックやスクリプトで話す以上の会話ができる NPC を実現




# ゲーム内のアイテムや広告をレコメンド

Recommendations AI で、ユーザーに合わせたアイテムや広告を提案



# マッチングのバランス調整

学習したモデルで、プレイヤー マッチングのバランスを調整(デッキ・アイテム・スキル など)



Vertex AI



AutoML

Source: [Leveraging Machine Learning for Game Development | Google AI Blog, 2021](#)



# マルチプレイゲームにおける 嫌がらせの問題



## マルチプレイゲーマーが感じる 嫌がらせの増加

# 83%

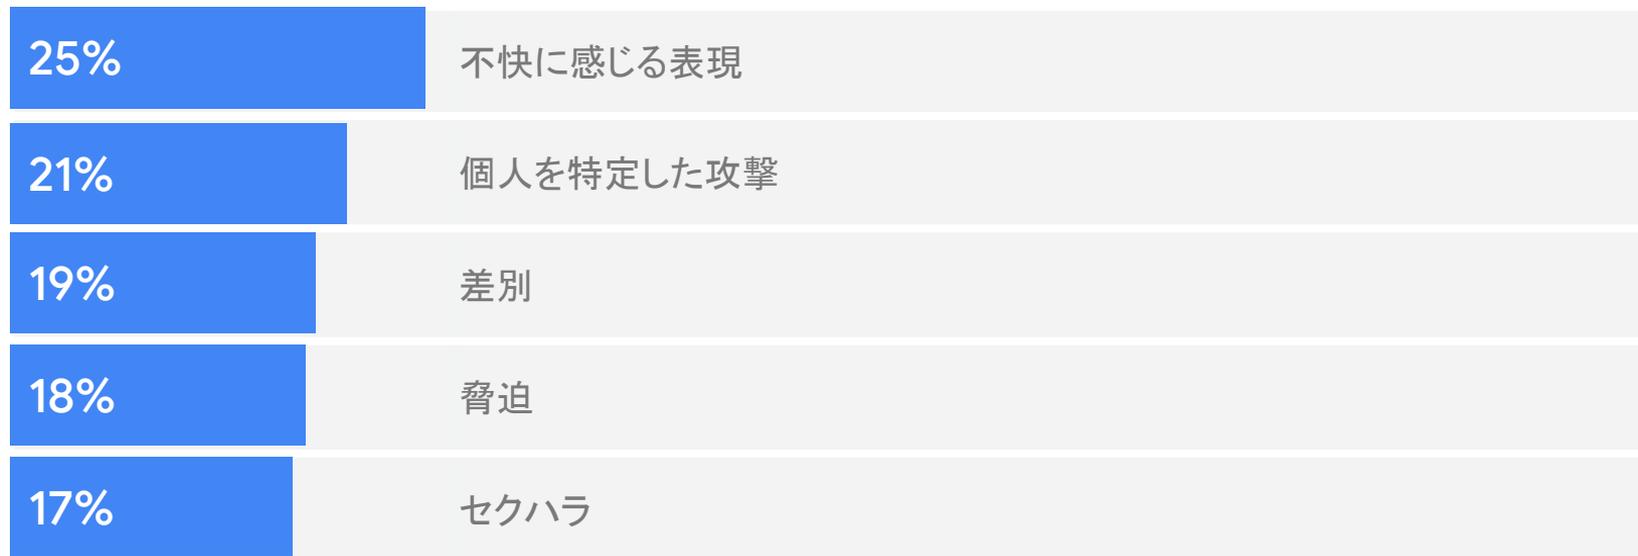
+10%  
y-o-y



Source: [Hate is No Game: Harassment and Positive Social Experiences in Online Games 2021](#)



# ゲーム内嫌がらせの種類



Source: [Google for Games Dev Summit 2021](#)



## ゲーム内の嫌がらせから自らを守るために...



Source: [Google for Games Dev Summit 2021](#)



# 悪質な発言によるユーザーの離脱



64%のゲーマーは悪質な発言  
がゲーム経験に悪影響を及ぼす  
と感じています



5人に1人以上は、嫌がらせ・悪質な発言を経験し、  
ゲームを辞めることがあります



Source: [Anti-Defamation League/NewZoo, 2020](#) -- Representative Survey (1,000 P18-45)



# ユーザーの離脱を防ぐための戦略

## 事前の予防

嫌がらせの発生率が低い  
健全なコミュニティを作る

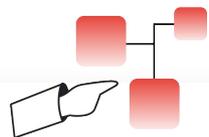


## 事後の対応

悪質な発言がもたらす  
影響を抑える  
&  
再発を防止する



# 嫌がらせ判定の難しさとその理由



## ユーザーからの通報

- システムが悪質な表現を通報するプレイヤーに依存
- 通報された内容を運営がレビューするための労力を要す



## 厳しすぎる規制

- 安全すぎる空間では楽しむ要素が減る
- ゲームを盛り上げる戦いや対立もある

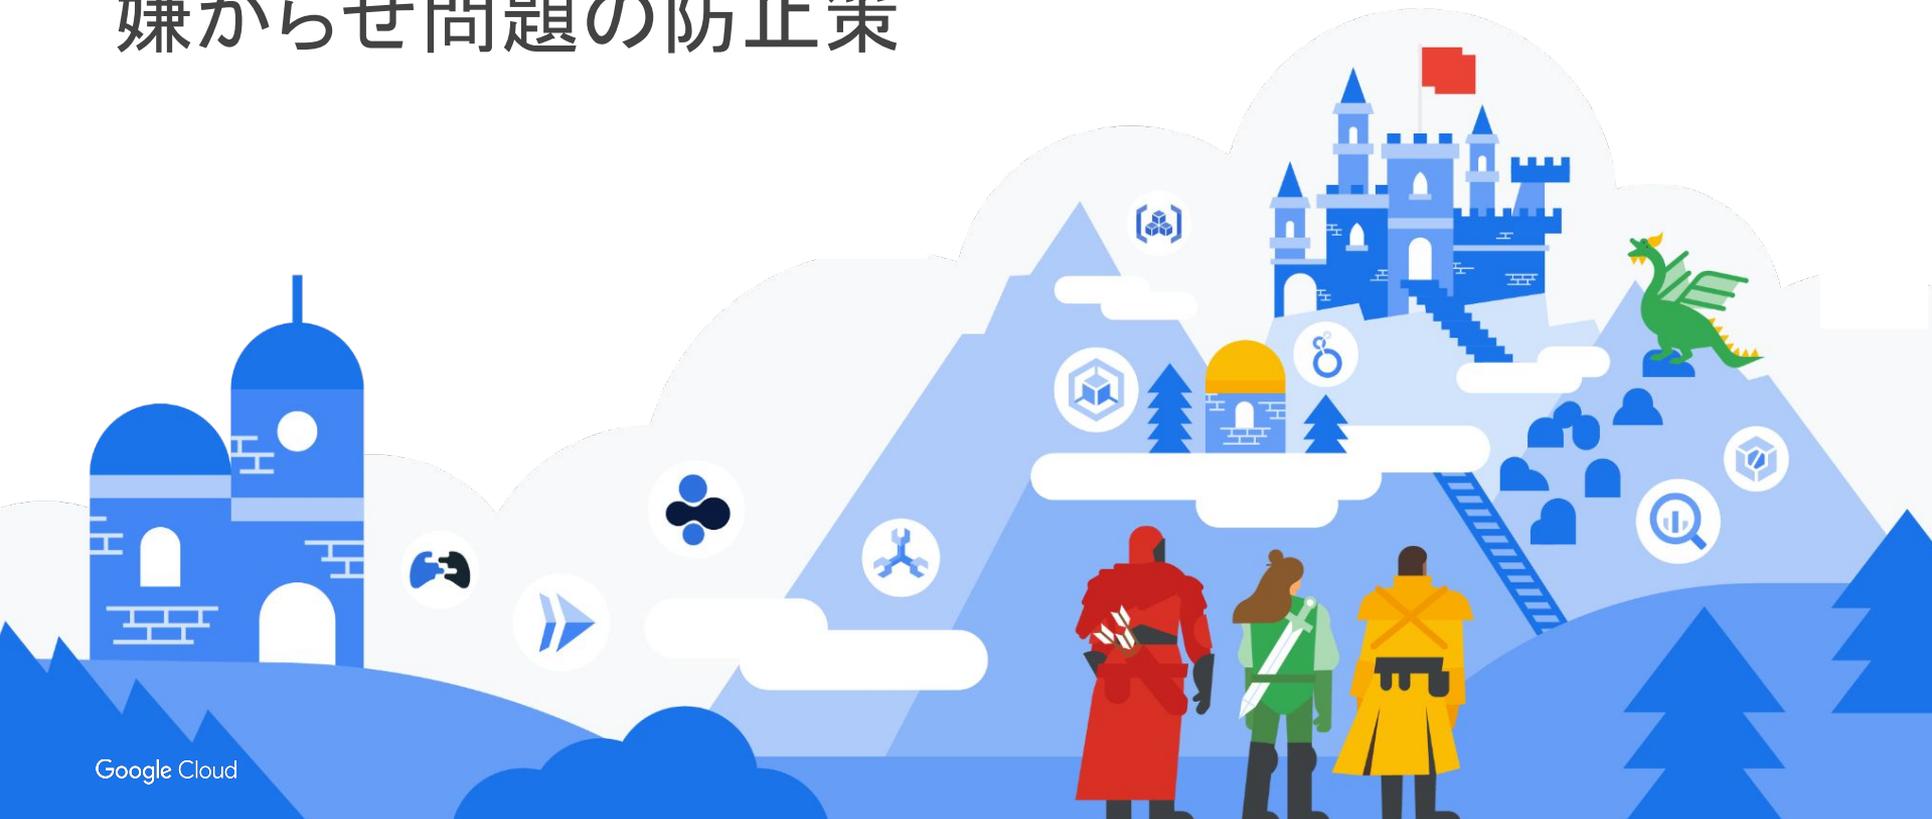


## ルールベースでの判定

- 文脈を考慮した分類ができない
- 言語の相違による受け取り方の違い



# 嫌がらせ問題の防止策



# ユーザーの離脱を防ぐための戦略

## 事前の予防

嫌がらせの発生率が低い  
健全なコミュニティを作る

 JIGSAW



## 事後の対応

悪質な発言がもたらす  
影響を抑える  
&  
再発を防止する

 clean chat



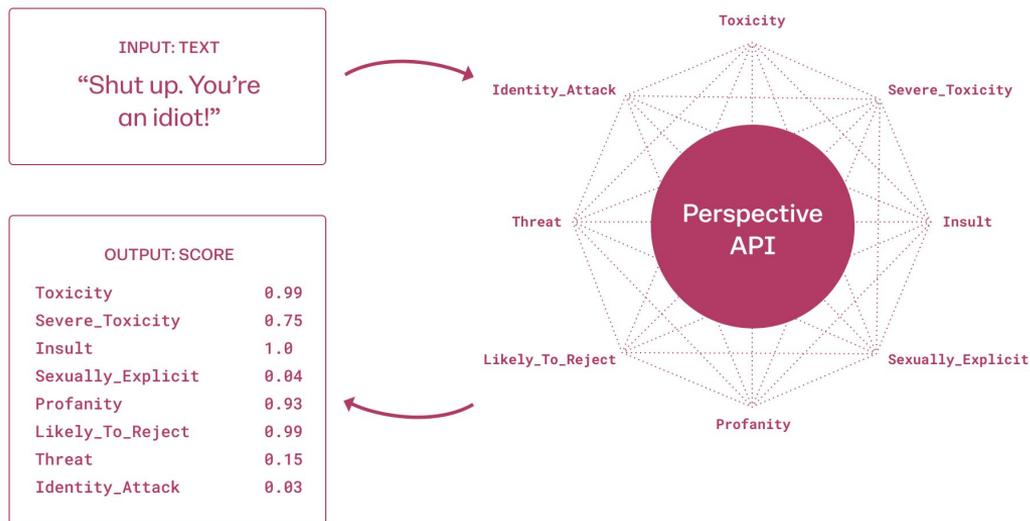
# 嫌がらせの検知

Perspective は、より安全な会話を補助するため、Google 親会社 Alphabet 傘下の Jigsaw が開発した API です。

入力テキストに対し、悪質な発言かどうかの判定を 0 から 1 のスコアで返します。

文脈と言語ごとの特徴を考慮して各属性ごとにスコアリングを行い、最終的な Toxicity スコアを算出します。

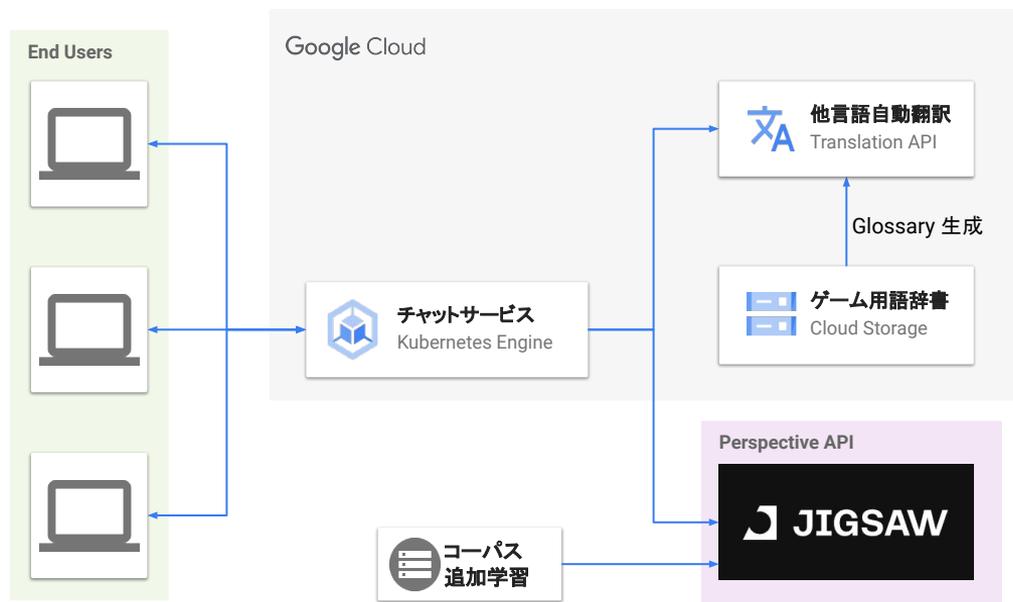
2021年6月の時点で、総合スコアを表す属性の Toxicity が日本語対応になっています。



Source: <https://developers.perspectiveapi.com/s/about-the-api>



# 嫌がらせを多言語対応で予防 - 実装例



## 検証時のポイント

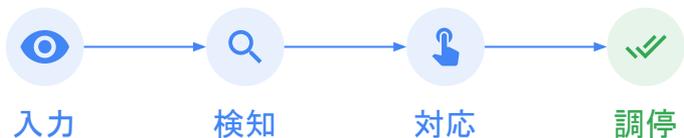
- リアルタイム性
- 翻訳の精度
- 嫌がらせ検出の精度
- 負荷耐久性



# 嫌がらせに対する事後の対応 - Clean Chat



**Clean Chat** は、すべてのユーザーにとってゲームをより楽しく安全にするための分析フレームワークです。  
Google Cloud のプロダクトと組み合わせたパイプライン実装例が OSS として公開されています。



<https://github.com/googleforgames/clean-chat>

## Clean Chat の特徴

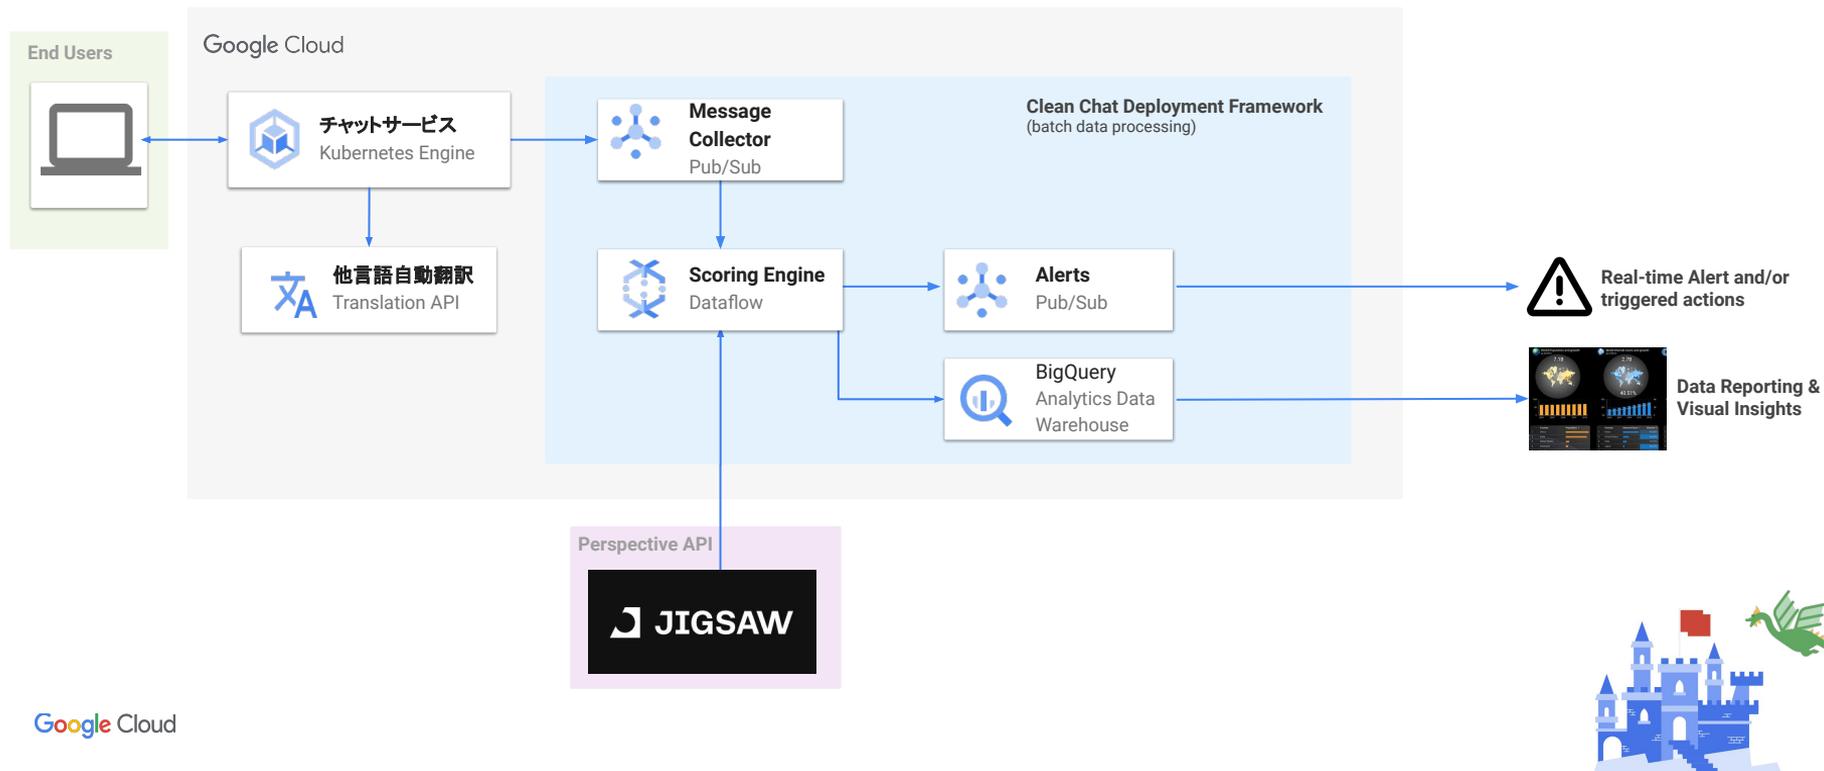
- Model training と deployment framework
- イベントドリブンのアーキテクチャ
- Google Cloud のインフラストラクチャ

Google Cloud

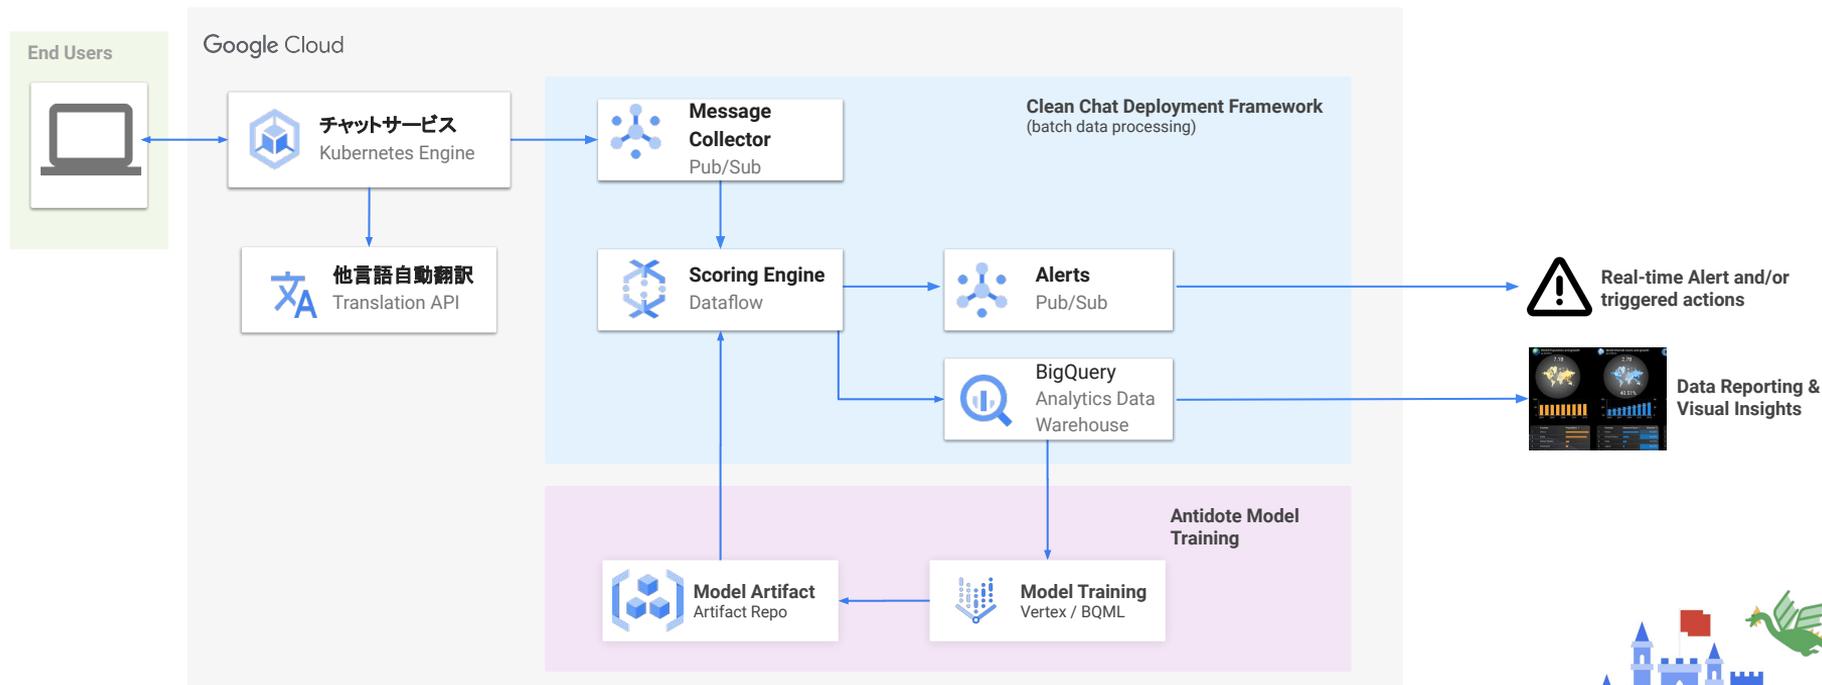
Players



# 嫌がらせに対する事後の対応 - Clean Chat



# 嫌がらせに対する事後の対応 - Clean Chat



# まとめ



嫌がらせによりユーザーの離脱



ユーザー離脱を防ぐための  
事前の予防・事後の対応



ベンダー ロックインのない  
Google Cloud のソリューション



Google Cloud では多様な目的に  
合わせた ML ソリューションを  
提供しています。

目的に合わせたソリューションの導入  
で、ビジネスをアジャイルに展開できま  
す。



# Thank you

