

AIセキュリティ分科会 楽天グループにおけるAI Safety対策について

Oct 17th, 2025

Rakuten Group, Inc.

Global Chief Data Officer Office: Senior Manager Saito, Shinichi

Rakuten Institute of Technology: Vice General Manager Hirate, Yu



お答えする内容

楽天グループでは、生成AIを企業経営だけでなく、マーケットの変革や顧客体験の変革の基礎と捉えて、全社を挙げて利活用に取り組んでいる。

生成AIによるチャットボット型のサービスを楽天モバイルの既契約・未契約顧客向けをはじめ、汎用性の高いAI Agentを広く提供しており、消費体験の変革にも広く適用していく予定である。

AI開発段階における、AIシステムの機密性、完全性、可用性等を損なう脅威及びそれに対する対策として、リスクフレームワークを用いた事前評価プロセス等を適用してレビューを行っている。

LLM開発段階において、学習段階データに機微なデータが混在しないことは、他のデータ利活用プロセスと同様に、データコントロールプロセスの一環で厳しく制限している。現状では学習データにポイズニング攻撃（例 攻撃者によって不正な質問に応じるQAセットが仕込まれる）が仕掛けられるような開発過程を踏んでおらず、大きな懸念はない。一方で、冗長なオフラインレビューを行う事には課題感もある。

悪意のあるプロンプト（例 不法行為、機密情報等を含む文章を作成させることを意図した指示）に応答しないための対策として、ガードレール・モニタリング機能の実装を行っており、防御機能のチューニングを行うと共に、包括的なモニタリング体制を整備しているところ。

AI開発者の立ち位置では、基盤モデルに由来する潜在リスクについて他の事業者と共通の懸念を持っており、総務省のAIセキュリティガイドライン（仮称）及び政府の取組みに対しては、オープンソース等のモデルのサプライチェーンに起因する開発者のリスクの緩和策等に期待申し上げたい。

アジェンダ

AI Safety

1. 楽天グループにおける生成AIへの取組み

2. AI Safetyの全体観

3. AI Safety Platformのデモンストレーション Safety Guardrail & Gen EYE

4. Q&A

Rakuten AI


Augment **human creativity**
with the **power of AI**

Internet Revolution

Mobile Revolution


Englishnization

AI-nization



Rakuten AI Innovation Platform

Our operational model to accelerate AI development & deployment
with the highest levels of efficiency



Rakuten AI for Rakutenians

社員向け生成AI

Empowering our employees to work smarter, faster, and more efficiently

20,000+

Custom AI tools/templates created to date.
15,000+ employees using Rakuten AI every day.

~80%

Faster product time-to-market using AI-augmented software development for Rakuten AI for Rakutenians.



Coding



Content Creation



Data Analysis



Document Creation



Creative Design



CRM



Customer Support



Knowledge Retrieval



Sales Support



Learning & Development



Translation



Meeting Notes

Video to PRD in >30minutes

Prototypes developed >10 minutes

AI-driven unit test cases
& code maintenance

Rakuten AI

ビジネス顧客向け生成AI

Driving operational innovation across industries



楽天モバイルAIアシスタント2.0 (RMAA2.0) の概要

生成AIを活用したチャット形式のサブスクリプションサポートサービス

楽天モバイルの契約をご検討されている
お客様をチャット形式でサポート

お客様サポート機能：

- ・「楽天モバイルショップ」の来店予約
- ・「Rakuten最強プラン」の新規契約
- ・他社サービスとの料金比較


2024年12月18日（水）にリリース¹



1. 楽天モバイル、チャット形式のAIサポートサービス「楽天モバイルAIアシスタント2.0」の本格提供を開始,
https://corp.mobile.rakuten.co.jp/news/press/2024/1219_02/


システムアーキテクチャ：マルチエージェント

- マルチエージェントアーキテクチャを採用。
- 各エージェントは、必要に応じて楽天モバイルWebページを参照し応答を生成。（RAG）
- ガードレールを挟むことにより、安全性を確保。



品質向上を含むプロジェクトタイムライン


プロジェクト開始は2024年4月、プロダクトリリースは2024年12月。
プロダクションレベルの応答正答率を達成するために長期間格闘（後述）。



製品レベルのハルシネーション対策：ハルシネーションが起こる要因（2024年11月時点）

様々な要因で、エージェントが誤った回答を生成してしまう。

最も大きな要因は、Retrieval Error（RAGを適用する際に、誤ったページを検索してしまうエラー）




言語モデルの出力に基づく回答の正確性を向上させる仕組みとして、特許査定を取得（特開2025-75639）

<https://www.j-platpat.inpit.go.jp/c1801/PU/JP-2023-186944/10/ja>


製品レベルのハルシネーション対策：継続的なアノテーションデータ構築

実際に入力された質問、回答生成のための検索ページ、生成された応答を
マニュアルチェック。6か月間以上にわたり、学習用データセットを継続的に構築。

RMAA2.0リリース前




RMAA2.0リリース後



RMAA

製品レベルのハルシネーション対策：システム正答率の改善

当初正答率が70%弱だったものが、
2024年12月中旬にリリース基準である85%を超えるまでに改善



アジェンダ

AI Safety


1. 楽天グループにおける生成AIへの取組み

2. AI Safetyの全体観

3. AI Safety Platformのデモンストレーション Safety Guardrail & Gen EYE

4. Q&A


AI コンプライアンスプロセス



AI Review : Identify which area our gen AI 30 check points can assist

- Rakuten AI PJTs review template are a set of open questions.
(e.g. please describe countermeasure for harmfulness.)


Gen AI 30 check points



AI Review Process *	
Category	Check points
Model	• GenAI or Traditional ML model?
Design	• Hallucination / Harmfulness / Grounding / Prompt Injection
Training	• Specification / Quality / Privacy and copyright risk of Training Data • Computation cost for training
Inference	• Infrastructure / Cost for inference
QA	• AI specific test in QA
Security and Privacy	• AI Security Review Status / data

AI Safety & Security essential structure

AI Safety consists of real-time monitoring, and continuous basis response, which is what CAIDO would concerns.



Why AI Safety is so important?

AI Safety Guardrail & monitoring platform affect to AI-nization PIC's slowness and passivity.

Without Safety Guardrail & Monitoring platform..



Risk expose..

OR



Manual coding.. to protect AI service
Labor intensive .. monitoring process

WITH




No standard to lead AI producers



Affect to **Slowness of Passivity**

With Safety Guardrail & Monitoring platform..



Service Bottom line..

AND



Automation..

WITH



Standardized operation / development



Accelerate AI PJT

アジェンダ

AI Safety

1. 楽天グループにおける生成AIへの取組み


2. AI Safetyの全体観

3. AI Safety PlatformのデモンストレーションSafety Guardrail & GenEYE

4. Q&A

How AI Safety and GenEYE work

When a user asks any question, three types of AI Safety Guardrail are activated depending on the type of question. Guardrail's decisions are recorded in GenEYE's monitoring platform.



Safety Guardrail Demonstration

The screenshot displays the Rakuten Mobile AI Assistant interface in a web browser. The browser's address bar shows the URL `stg-ai-assistant.mobile.rakuten.co.jp`. The page header features the Rakuten Mobile logo and a chat icon. A disclaimer states: "This AI chat may be inaccurate. The information entered will be handled in accordance with the privacy policy. Please be sure to read the terms of use." The chat history shows the assistant's introduction: "Hello! This is Rakuten Mobile AI Assistant 2.0. Thank you for your interest in Rakuten Mobile! I am an AI that can converse like a human. I will answer any questions you may have about Rakuten Mobile, so please feel free to ask me. *This AI assistant is in beta version." Below this, there are four buttons: "I want to apply", "Compare prices with other companies", "View the application campaign", and "I want to know about pricing plans". A user input box contains the text "Please give me a quick summary of the Saikyo plan". The assistant's response, which is highlighted with a dashed border, provides details about the Saikyo plan's monthly fees and data usage. The response includes a "Reset" button and a "Read more" link.

Rakuten Mobile

This AI chat may be inaccurate. The information entered will be handled in accordance with the privacy policy. Please be sure to read the terms of use.

R Hello! This is Rakuten Mobile AI Assistant 2.0 🤖
Thank you for your interest in Rakuten Mobile!

I am an AI that can converse like a human.
I will answer any questions you may have about Rakuten Mobile, so please feel free to ask me.

*This AI assistant is in beta version.

[I want to apply](#) [Compare prices with other companies](#) [View the application campaign](#)
[I want to know about pricing plans](#)

Please give me a quick summary of the Saikyo plan

R ...

R What is Rakuten's strongest plan?
Reset

Rakuten Mobile

monthly fees:

- Up to 3GB: ¥968 (tax included)
- 3GB to 20GB: ¥2,068 (tax included)
- Over 20GB: ¥3,168 (tax included)

The plan also offers unlimited high-speed data usage.
* Call charges etc. not included * For unlimited high-speed data plans, speeds may be restricted during peak hours, etc., in order to provide a fair service.


Read more 📖

- Rakuten's Strongest Plan (Price Plan) | Rakuten Mobile
- Strongest Family Program (Family Discount) Save money if the whole family uses it! | Rakuten's Strongest Plan (Price Plan) | Rakuten Mobile
- Strongest Youth Program Save money until you turn 22! | Rakuten's Strongest Plan (Price Plan) | Rakuten Mobile

👍 🗨


❑ Gen AI can answer consumer's questions about Rakuten Mobile subscription

Safety Guardrail Demonstration



□ Safety guardrails protect PII exposure

Safety Guardrail Demonstration



- ❑ Safety guardrails protect against Prompt injection
- ❑ Safety guardrails protect against violence related content
- ❑ Monitoring platform reports AI safety detection results

アジェンダ

AI Safety

1. 楽天グループにおける生成AIへの取組み
2. AI Safetyの全体観
3. AI Safety Platformのデモンストレーション Safety Guardrail & Gen EYE

4. Q&A