



24時間信頼できるAIをあなたに

2023年2月3日 株式会社Citadel AI

AIの信頼性とガバナンスに関わる議論

EUがAI包括規制案



AIシステム版の“GDPR”

EUのみならず全世界の企業に適用



€30milか**全世界売上の6%**の制裁金
本年中に法制度化を目指す

高リスク

受容できないAI

安全な生活・権利に対する脅威
潜在意識への操作、弱者搾取
公的ソーシャルスコアリング等

原則使用禁止

ハイリスクAI

生体認証、産業機械
医療機器、重要インフラ
人事採用、与信審査

継続的な
品質マネジメント
モニタリング義務

透明性義務を
伴うAI

人と相互作用するシステム
感情推定、ディープフェイク
チャットボット等

AIが使われて
いることを明示

極小リスク
リスク無しAI

上記以外のAIシステム

必須義務なし

低リスク



NY市：自動採用決定ツールに対する 事前バイアス監査義務法 2021/144を本年から施行予定

AIの信頼性に関わる新たな課題を解決

2020年12月設立

Seed Funding:




Ex Google, Waymo, paidy, Toyota

1. Problem

我々が取り組む課題
「AIの信頼性」とは何か？


さまざまなローコードツール

```
import numpy as np
from tensorflow.keras.models import Sequential, model_from_json
from tensorflow.keras.layers import Dense, Dropout, Flatten,
Conv2D, MaxPooling2D
from tensorflow.keras.optimizers import RMSprop
from tensorflow.keras.datasets import cifar100
from tensorflow.keras.preprocessing.image import array_to_img,
img_to_array, load_img
from tensorflow.keras.utils import to_categorical
from sklearn.model_selection import train_test_split
import matplotlib.pyplot as plt
....
```



AIのモデル開発は容易に

隠れた **未学習領域** に残るリスク



再学習時に発生するトラブル

**New
Model ?**



**New
Data ?**

AIは**環境変化**に非常に脆弱



AIの間違いは、一体 誰がどうやって？



気づいた時には**手遅れ**に

人手作業には
膨大な
手間と時間



ビジネスリスク
セキュリティ
コンプライアンス

ポリシーと手順の
標準化・文書化

全ての組織の役割、責任、及びプロセスに対応する
「**ポリシーと手順を標準化し文書化**」することが重要

モデル監査
アルゴリズム監査

「**モデル監査やアルゴリズム監査**」は、説明責任の検討事項を評価し、文書化するために有効

継続的な
モニタリングシステム
の追加構築

問題を自動検出しアラートする「**モニタリングシステム**」
を追加構築することが重要

フィードバック
チャネル

エンドユーザーがエラーや損害に対する救済を求められる「**フィードバックチャネル**」があることが望ましい

ポリシーと手順の
標準化・文書化



モデル監査
アルゴリズム監査



継続的な
モニタリングシステム
の追加構築



フィードバック
チャネル



何をどこまで検証したら良いのか？

また、それをどのようにしたら

継続的に実行できるのか？

ポリシーと手順の
標準化・文書化



モデル監査
アルゴリズム監査



Citadel Lens

継続的な
モニタリングシステム
の追加構築



Citadel Radar

フィードバック
チャネル



2. Our Solution

我々のソリューション

2つの「自動化」を通じて解決

 Citadel Lens

 Citadel Radar



瞬時に自動検証


継続的に自動監視

開発

学習・検証

運用・保守

 Citadel Lens




 Citadel Radar



Citadel Lens : 検証時間を95%削減

網羅的テストを 自動かつ一瞬で

- ノイズ耐性テスト
- 未学習領域の自動検出
- ラベル間違い推定
- 公平性テスト
- 説明責任の可視化 etc.



Citadel Lens : PoC加速化と品質改善高速化

多様なモデルに
汎用的・横断的に




Score	Model Version	Description	Completed At	Details
92%	2022.04.30	150 trees, training dataset from 2022-04-30	2022-04-30 17:22:32	See Report >
88%	2022.04.24	150 trees, training dataset from 2022-04-24	2022-04-24 11:21:39	See Report >
83%	2022.04.21	150 trees, training dataset from 2022-04-21	2022-04-21 21:38:52	See Report >
90%	2022.04.18	125 trees, training dataset from 2022-04-18	2022-04-18 08:14:51	See Report >
85%	2022.04.17	125 trees, training dataset from 2022-04-17	2022-04-17 14:31:05	See Report >
88%	2022.04.16	125 trees, training dataset from 2022-04-16	2022-04-16 10:45:12	See Report >
91%	2022.04.11	100 trees, training dataset from 2022-04-11	2022-04-11 08:17:49	See Report >
84%	2022.04.04	100 trees, training dataset from 2022-04-04	2022-04-04 14:33:02	See Report >
84%	2022.04.02	100 trees, training dataset from 2022-04-02	2022-04-02 14:33:02	See Report >



Citadel Radar : 変動リスクを即時ブロック

複数のフィルターで 自動かつ**継続的に**

- モニタリング
- ファイアウォール
- 説明責任の可視化



Citadel Radar : 運用時のリスクを自動検知しブロック


運用中のAIの精度検査を行う場合
従来の方式では、**目視検査**による
ラベル付けが必要。
多くの手間と時間を要し **手遅れ**に。

Citadel Radarを使えば、ラベルに
頼ることなく**リアルタイムに異常を
検知・防御**。プロアクティブに
リスクに対処可能。



Suntoryのグループ横断品質管理ツールとして採用


<https://www.citadel.co.jp/news/citadel-ai-suntory>



日経クロステック 2022年11月24日記事: サントリーが製品出荷パレット回収予測に AI、精度劣化を回避する策


NTTデータと共同でCitadel Radarの検証を実施

従来のソフトウェアとは異なる特性を持つ、AIの継続的活用に向けCitadel AIとNTTデータは、金融系公開データを用いた共同検証を実施。Citadel Radarを活用することで、AIモデルのトラブルを検知し安定した運用に寄与できることを確認しました。




NTTデータ: 2022年7月22日 Data Insight

<https://www.nttdata.com/jp/ja/data-insight/2022/0722/>



さまざまなAIに汎用的に適用可能





24時間信頼できるAIをあなたに



企業URL <https://citadel.co.jp>

お問合せ
rick@citadel.co.jp
kenny@citadel.co.jp



Twitter <https://twitter.com/CitadelAI>

AIの疑問は **#AI豆知識**