



電気設備に対する画像分類モデルの開発と 生成AIを活用した異常画像生成の取り組み

JEIS

株式会社JR東日本情報システム
イノベーティブソリューション本部
テクノロジー応用研究センター AIテクノロジーグループ

本日の内容

AWSを活用したメンテナンス業務の効率化に向けたAIモデル開発・研究 (株式会社JR東日本情報システム・東日本電気エンジニアリング株式会社の共同研究)

東日本電気エンジニアリング株式会社様が日々のメンテナンスの中で撮影・保存している
大量の鉄道設備画像の活用を目的とした2つの共同研究を実施

1. 電気設備に対する画像分類モデルの開発
2. 異常検知AIの開発に向けた異常画像生成の研究

自己紹介



方志 卓朗 (ほうし たくろう)

株式会社JR東日本情報システム
イノベティブソリューション本部
テクノロジー応用研究センター AIテクノロジーグループ

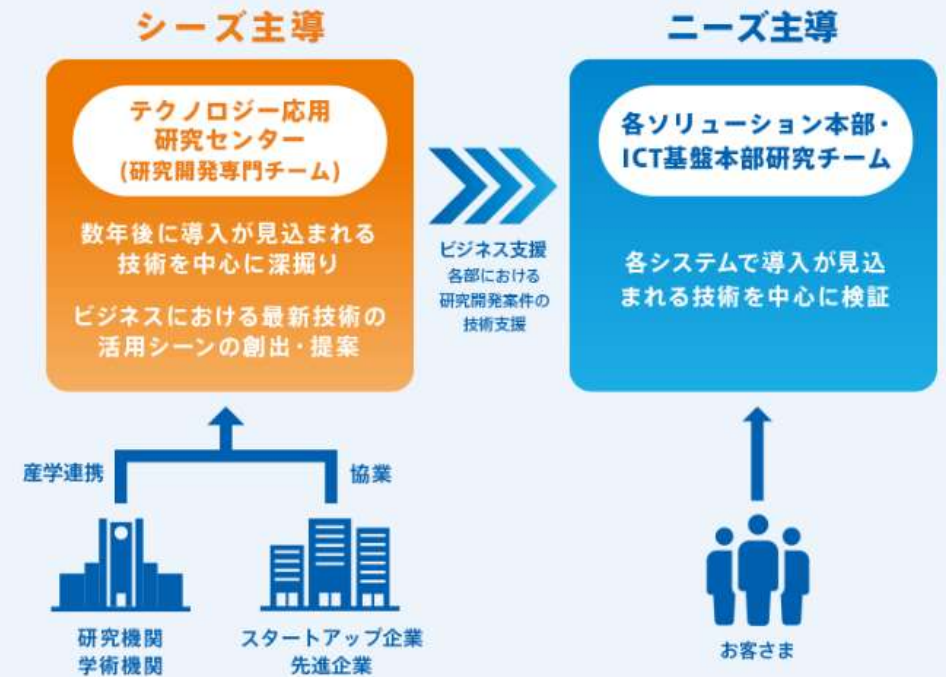
- 2008年 仙台支店 (駅収入管理の保守)
- 2010年 運行情報配信PJ (ATOS情報配信システムの開発・運用)
- 2012年 NEC情報システムズ出向 (下流工程全般)
- 2014年 運行情報配信PJ (列車在線位置の配信機能・APIの開発)
- 2018年 NRI ITSA Pacific Office出向 (研修生 / 深層学習の研究)
- 2022年 テクノロジー応用研究センター (鉄道設備の異常検知の研究)
- 2023年 Stanford University (客員研究員 / 生成AIの研究)

JR東日本情報システム(JEIS)・テクノロジー応用研究センター

研究開発

将来的に発展する技術などの検証、目的に応じた応用研究など、研究開発組織（テクノロジー応用研究センター）を中心に各箇所で取り組みを進めています。

数年先を見据えた先端ICTをいち早く取り入れるとともに、産学連携を含めて、よりオープンにグローバルな研究活動を推進しています。



AI・IoT・3D CGなど将来的に発展する技術の研究
数年先を見据えた先端ICTの取入れとともに、オープンでグローバルな研究活動を推進

東日本電気エンジニアリング株式会社 (TEMS)

私たちは、「JR東日本のパートナー会社」として、
JR東日本全エリアを中心とした各鉄道事業者の
電気設備メンテナンス、設備管理、設備工事を行っています。

世界一の“平常”をつくる

あらゆる電気設備のメンテナンスを高い品質で担い、
今日も日本の鉄道の“平常”を作り続けています



公式マスコットキャラクター
匠くん

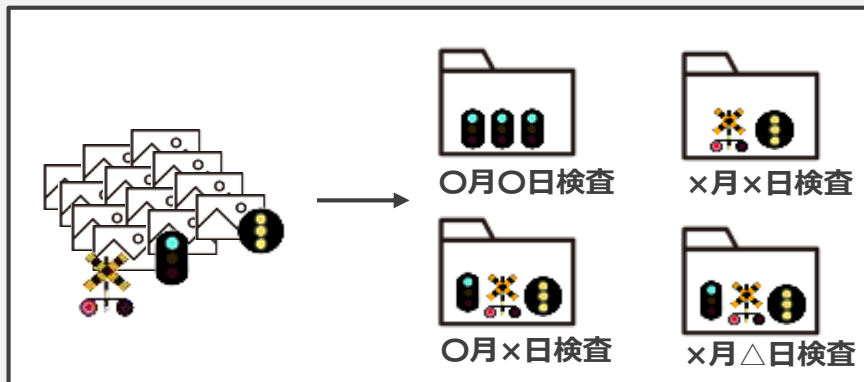


電気設備に対する画像分類モデルの開発

背景

現状

画像の保存



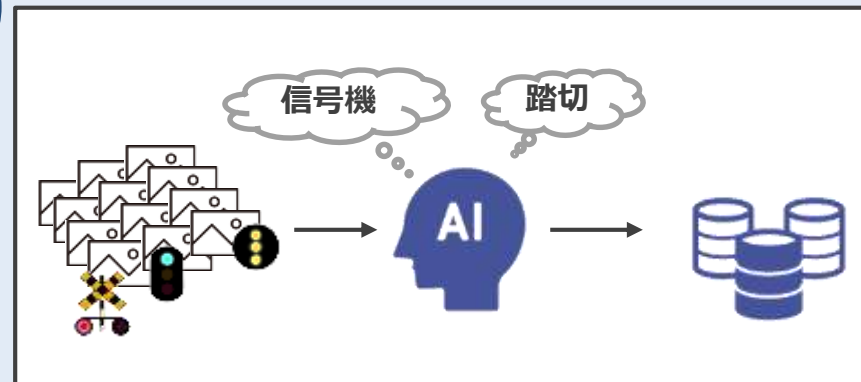
- 撮影した画像はそのままフォルダに保存
- フォルダは撮影日・撮影者ごとに存在

画像の検索




- 画像がいくつものフォルダに分散
- 目的画像の検索に時間がかかる

AI活用



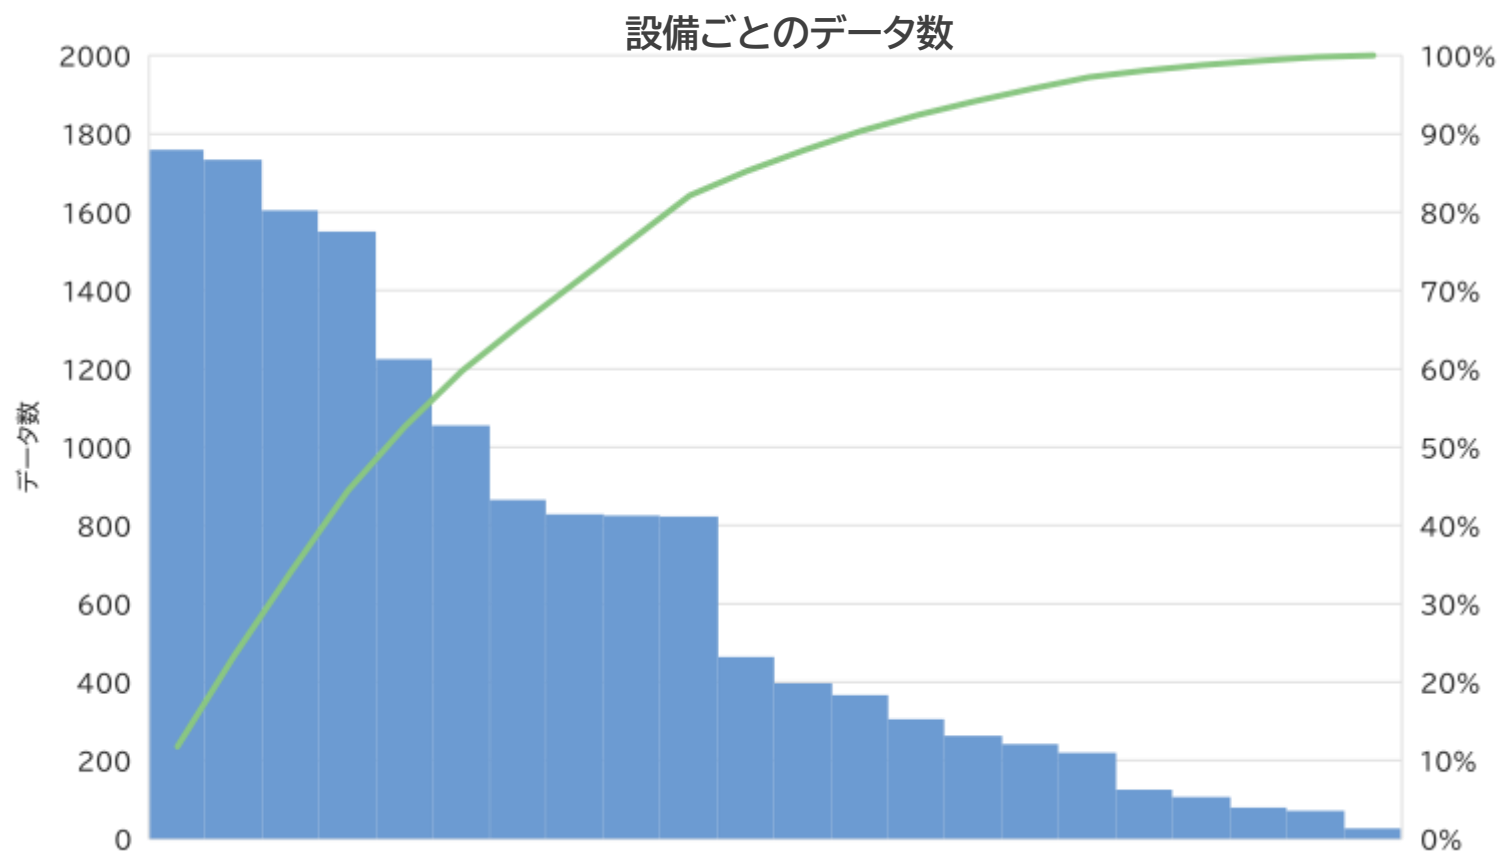
- AIが画像を分類し設備名のタグを付与
- 設備名のタグやExif情報をDBに登録




- 設備名、撮影日などで画像の検索が可能
- 目的画像の検索時間の短縮
- 将来的には異常検知への応用なども

TEMS様提供データ

- 外観検査で撮影された設備の一部(16の設備・16,000枚)の画像を受領



データ探索



それぞれ異なる配線箱の中身の例

AI設計
方針

配線箱の内部は特徴が似ているため、従来の教師あり学習では難しいのでは？
→ Amazon Rekognitionを使って素早く検証することにした

Amazon Rekognition 結果

- 1,138枚のテストデータのうち996枚の判定に成功し正解率は84%
- AWS Rekognitionは「配線箱の内部は特徴」は正しく学習している
- 設備Aの正解率が60%と他の設備と比較して極端に低い

設備名	テストデータ数	正解数	正解率
XXXXXX	61	59	0.97
XXXXXX	4	4	1.0
設備A	268	160	0.60
XXXXXX	26	26	1.0
XXXXXX	164	159	0.97
XXXXXX	60	53	0.88
XXXXXX	4	4	1.0
XXXXXX	19	18	0.95
XXXXXX	103	99	0.96
XXXXXX	33	32	0.97
XXXXXX	51	50	0.98
XXXXXX	13	13	1.0
XXXXXX	74	67	0.91
XXXXXX	37	34	0.92
XXXXXX	214	213	0.99
XXXXXX	7	5	0.71
総計	1138	996	0.84

108件の誤判定
(正解率60%)

Amazon Rekognition 結果

- 設備Aの判定結果を細かく確認したところ、108件の誤判定のうち大部分をある特定の設備Bと誤判定していることが判明

Amazon Rekognitionでの予測ラベル

正解ラベル

	××	××	設備A	××	設備B	××	××	××	××	××	××	××	××	××	××	××
設備A	0	0	160	0	100	0	0	0	0	0	0	2	0	0	6	0

100件同じ設備に誤判定

Amazon Rekognition 結果

電気設備A



電気設備B



- どちらも線路に電気を流す装置だが、接続先の設備でラベルが異なる
- 画像単体では保守担当者でも判断することができない

形状は同じでも、用途の違いによりラベリングが異なる設備が存在

独自モデルの開発方針

前後に撮影された画像を参考にラベリング



AI設計 方針

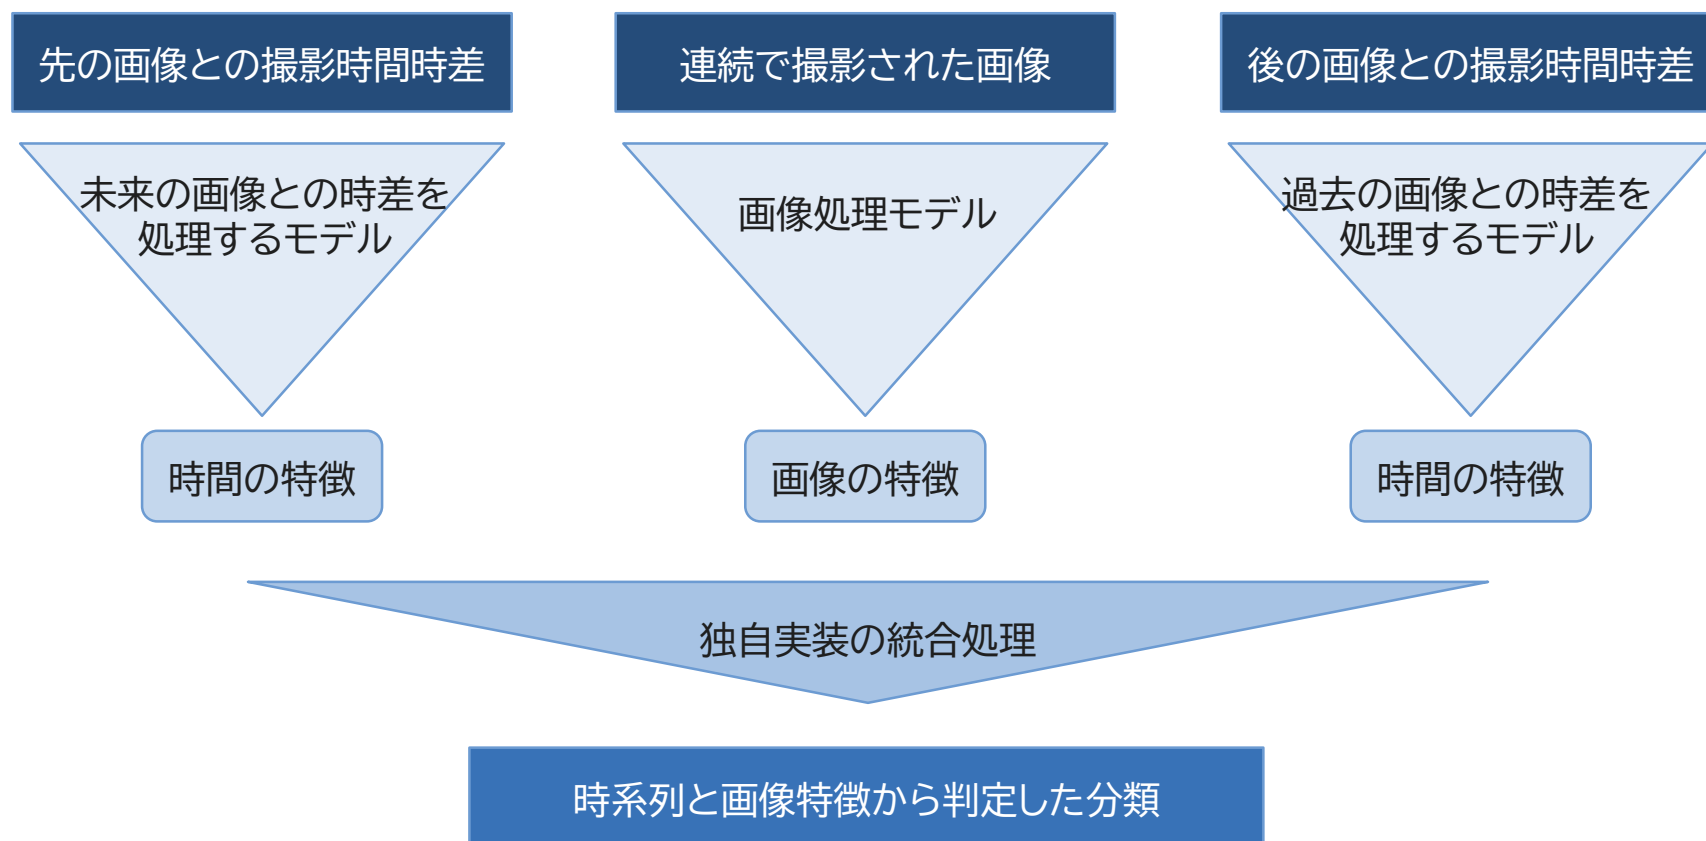
AIにも人と同様の情報を処理させる必要があると考え、前後に撮影された画像情報も取り入れることができるAIモデルを開発することにした

独自モデルの処理フロー



Amazon SageMakerでの学習

- 一度に複数の画像とそれに紐づく時系列情報を学習させる必要がある
- 大きなマシンリソースが必要になるため、Amazon SageMakerを採用
- 数行のコードで分散学習も実行可能



独自モデル 結果

- 「設備A」の誤判定が大幅に低下し、正解率は60%から98%に向上
- 総計の正解率は84%から95%に向上

Amazon Rekognition カスタムラベル

設備名	テストデータ数	正解数	正解率
XXXXXX	61	59	0.97
XXXXXX	4	4	1.0
設備A	268	160	0.60
XXXXXX	26	26	
XXXXXX	164	159	
XXXXXX	60	53	
XXXXXX	4	4	1.0
XXXXXX	19	18	0.95
XXXXXX	103	99	0.96
XXXXXX	33	32	0.97
XXXXXX	51	50	0.98
XXXXXX	13	13	1.0
XXXXXX	74	67	0.91
XXXXXX	37	34	0.92
XXXXXX	214	213	0.99
XXXXXX	7	5	0.71
総計	1138	996	0.84

108件の誤判定
(正解率60%)



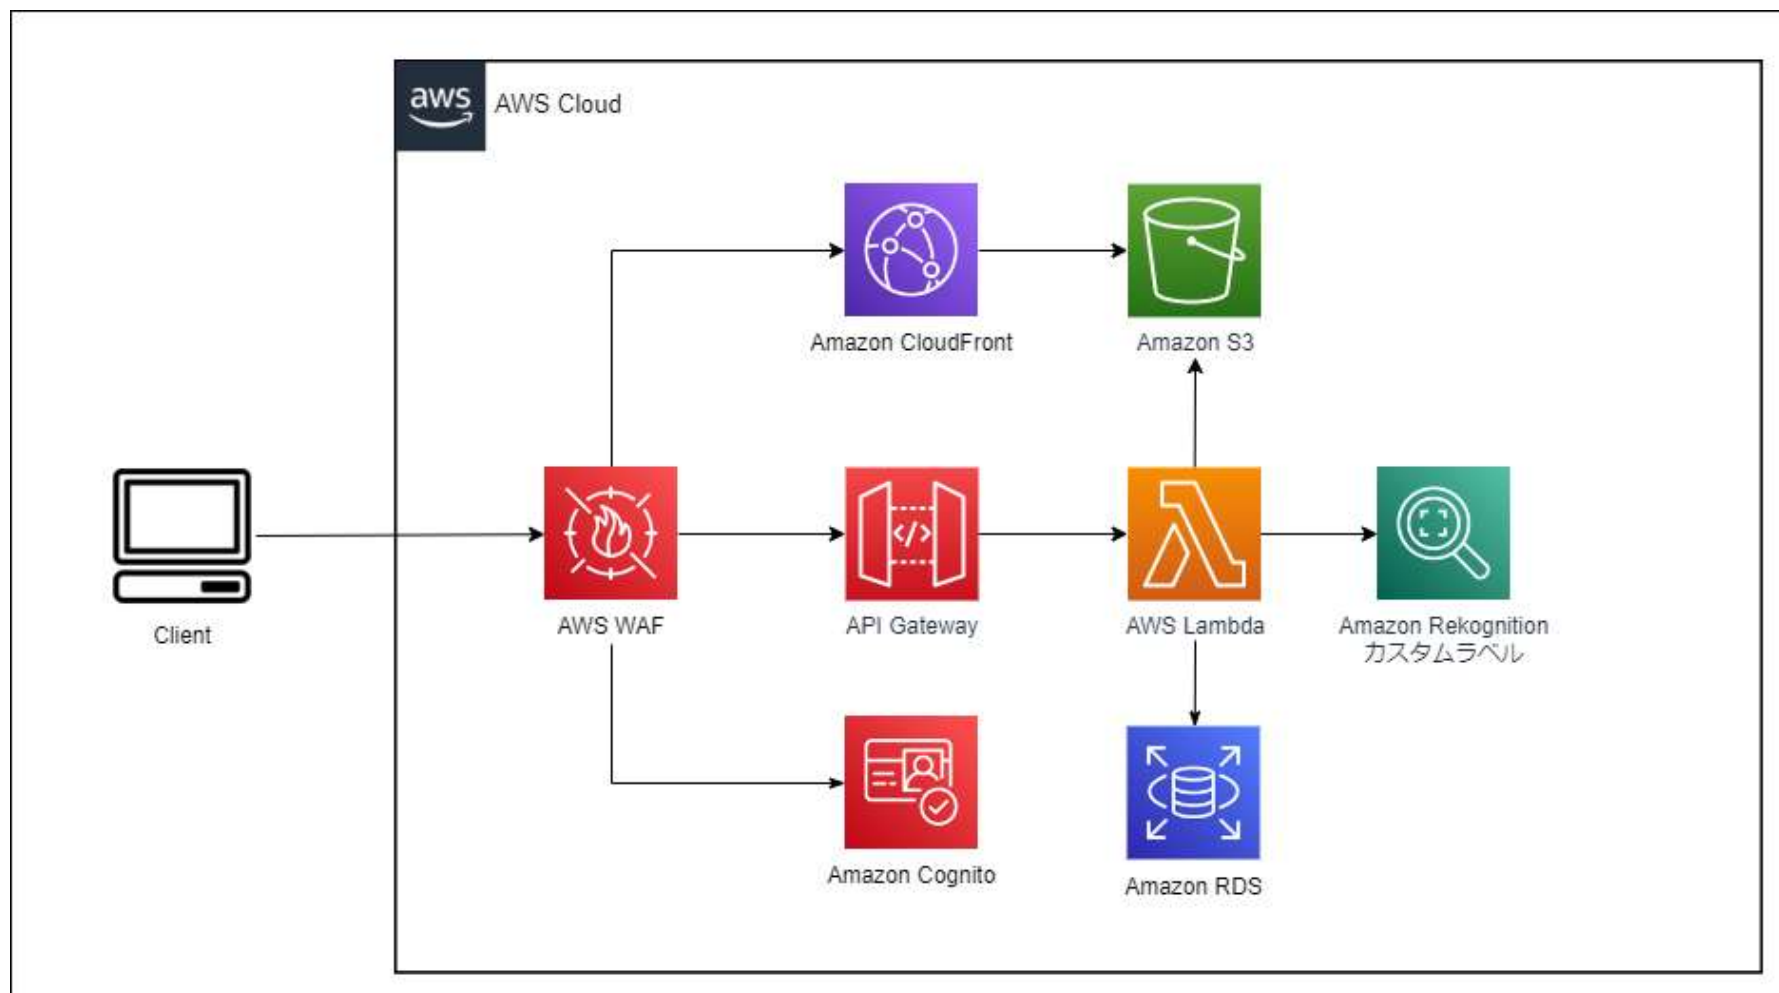
Amazon SageMakerで開発した独自モデル

設備名	テストデータ数	正解数	正解率
XXXXXX	61	56	0.92
XXXXXX	4	3	0.75
設備A	268	263	0.98
XXXXXX	26	24	0.92
XXXXXX	164	153	
XXXXXX	60	56	
XXXXXX	4	3	0.75
XXXXXX	19	16	0.84
XXXXXX	103	93	0.90
XXXXXX	33	31	0.94
XXXXXX	51	48	0.94
XXXXXX	13	12	0.92
XXXXXX	74	67	0.91
XXXXXX	37	31	0.84
XXXXXX	214	214	1.0
XXXXXX	7	6	0.86
総計	1138	1076	0.95

5件の誤判定
(正解率98%)

簡易アプリの開発

- TEMS様にAIを活用した写真の保存・写真の検索のイメージを持っていただくために、AWSを活用して簡易アプリを開発



簡易アプリ画面

AI設備画像分類

+ アップロード ログアウト

440件

表示順 撮影日時が新しい

支社

- 八丁
- 秋本
- 大宮
- 千葉
- 厚野

設備


- バックアップ社上子
- 中継器
- 信号受信機
- 入線器
- 列車表示器
- 列車表示器組立(押しボタン)
- 軌間
- 安全保護装置取付装置
- 新式信号機
- 信号機
- 踏切遮断機
- 踏切遮断機
- 踏切遮断機
- 中央停止装置
- 車上装置
- 入線器

撮影日

~

撮影者

すべて



< 1 2 3 4 5 6 ... 22 >

画像分類モデル開発 まとめ

実現した
こと

AWSをフル活用した画像分類モデルの開発・簡易アプリの開発

- Amazon Rekognition
 - 実運用に耐えられる性能を出せる
 - 素早く実行可能でAI開発のファーストステップに有効
- Amazon SageMaker
 - 数行のコードで分散学習が実行できる
 - 大規模なAI開発が可能
- アプリ作成で利用したAWSサービス
 - ドキュメントやオンライン研修が豊富
 - 効率的なプロトタイプ開発

本内容はAWSブログにも掲載していただいております！

(Amazon RekognitionとAmazon SageMakerを組み合わせた効率的なAI開発,
<https://aws.amazon.com/jp/blogs/news/efficient-ai-dev-rekognition-sagemaker/>)

異常検知AIの開発に向けた異常画像生成の研究

自己紹介



2020年 東日本旅客鉄道株式会社 入社
在来線車掌, 車両メンテナンス業務


2022年 株式会社JR東日本情報システム 出向
画像AIを用いた研究開発

稲森 真由 (いなもり まゆ)

株式会社JR東日本情報システム
イノベーティブソリューション本部
テクノロジー応用研究センター AIテクノロジーグループ

JEISとTEMSの新たな取り組み：異常検知AIの開発

検査した設備を撮影した大量の画像から異常を見つけ出す



異常検知AI



一例として、
ケーブルの異常（亀裂やひび割れ）を対象



現状

人間の注意力に依存する検査



AI
活用

人間とAIのダブルチェック

- 一見しただけではわかりにくい異常もAIで取りこぼさないように
- さらなる安全性の向上を目標

生成AIモデル使用の背景

課題

異常検知AIを開発・検証するための十分な異常画像を準備できない

- 鉄道設備において異常の発生率は非常に低い
- 異常箇所がアップで写っている画像は保存されているが、実際に判別したい設備全体が写っている状態の画像はほんのわずか

本来



- データが集まるまでに数年単位
- 環境を整備したとしてもAI開発に失敗する可能性がある

本研究



- 生成AIにより異常画像を生成し、異常検知AIの実現可能性の検証
- 今後の方向性の判断材料を得ることが目的

生成AI

- 画像生成AIとしてStable Diffusionを検証
- 指定した部分のみの書き換えに特化したInpaintingモデルを採用
 - 信号設備は、種類が多いことに加え、細部まで複雑な作りであるため1から画像を作成するのは困難
 - 元画像の一部分のみを修正することで異常画像⇔正常画像の書き換えを行う

異常画像生成のイメージ

Inpainting：(1)元画像、(2)マスク画像、(3)書き換え内容のプロンプトの3つをモデルに与えることで画像の一部を変更



- (3) “A photo of a cable with a crack”
“A photo of a cable exposed copper wires, cracked cover” など

生成画像を使用した異常検知AI開発の流れ

1

異常画像の生成

- 既存モデルの検証
- 独自データでの追加学習モデルの検証

2

生成した異常画像の検証

- 生成した異常部位が異常検知AIの学習データとして使えるものであるかの検証

3

異常画像の大量生成

- 異常検知AIの開発に向けて、異常画像生成フローを自動化

本発表の範囲

最終
目標

異常検知AIの開発

- 外観検査の画像から異常を検出するAIモデルの開発
- 異常検知AIの実現可能性を確認し、今後の判断材料とする

検証中


既存モデルでの異常画像生成

- Stability AI社が公開しているInpaintingモデルを使用してケーブルの一部に異常を生成
- 既存のモデルではリアルな異常を安定して生成することは困難であった

元画像



生成画像



* stabilityai/stable-diffusion-2-inpainting, <https://huggingface.co/stabilityai/stable-diffusion-2-inpainting> (閲覧 : 2023/07/18)

画像提供:東日本電気エンジニアリング株式会社様

独自モデルの作成

- リアルな異常画像を生成するため、TEMS様から提供いただいた実際の異常画像を学習
- ケーブルの亀裂や劣化のパターンは多様なため、異常のレベルを3段階に分け、それぞれについてモデルを作成

銅線完全露出



銅線露出カバー残



軽い亀裂




独自モデルでの異常画像生成

- 実際の異常画像を学習させることで、リアルかつ豊富な異常の生成に成功

元画像



生成画像



画像提供:東日本電気エンジニアリング株式会社様

生成した画像の有用性の検証

- 生成した異常画像が見た目がリアルなだけでなく、AIの学習データとして有用なものであるかを確認するために、Amazon Rekognition カスタムラベルを使用して簡易的な検証を実施
- 生成した異常画像のみで異常を学習したモデルで、テスト時に実際の異常画像を判別することができれば、生成した異常画像は異常検知AIを作成する際の学習データとして問題ないと想定


検証内容

外観検査画像からケーブル部分をアップで切り出した画像での正常・異常分類

正常



異常



データ数

【学習 60枚】

異常: 30枚 (生成画像)

正常: 30枚 (実画像)

【テスト 40枚】

異常: 20枚 (実画像)

正常: 20枚 (実画像)

※ 画像生成AIの追加学習に使用した異常画像はテストデータに含まない

生成した画像の有用性の検証

- 生成画像のみで異常を学習したモデルでも実際の異常画像を検知可能

予測

		予測	
		正常	異常
正解	正常	14	6
	異常	0	20

閾値0.5で分類した結果

- 作成した異常画像は異常検知AIの学習データとして活用できることを確認
- 異常画像生成のフローを自動化し、大量の異常画像を用意

AWS環境による効率的な開発

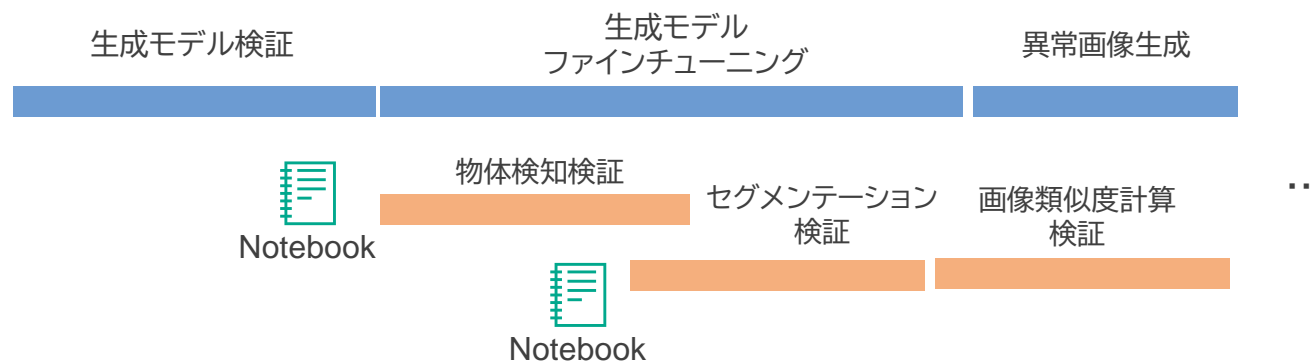
- Amazon SageMakerの利用により、効率的な開発を実現
 - 異常画像生成のフローを自動化するために、複数のモデルの検証が必要
 - ローカル環境のみでは、計算リソース不足により並列での検証は不可能
 - SageMaker Studio ノートブックを並列で使用



ローカルのみ



Amazon SageMaker



異常画像生成 まとめ

実現した
こと

異常検知AIの開発・検証に向けた、十分な異常画像の準備

- 実際の異常画像を学習させることで、リアルで多様な異常画像を生成
- Amazon Rekognitionでの簡易検証により、生成した異常画像の品質を確認
- 画像生成のフローを自動化することで、低コストで大量の画像を生成
- Amazon SageMakerの利用により効率的な開発

生成画像を用いた異常検知AIの検証も引き続きAWSを使用して実施中

JEISの研究開発事例

JEISの研究開発事例

- JEISでは、今回のTEMS様との共同研究以外にも、2018年から鉄道設備の異常検知をはじめとする様々なAIの研究開発を行っています
 - CycleGANによる合成データを使用した線路の異常検知
 - Railway Anomaly detection model using synthetic defect images generated by CycleGAN (<https://arxiv.org/abs/2102.12595>)
 - GANと3DCGを活用した車両外観の異常検知
 - Supervised Anomaly Detection Method Combining Generative Adversarial Networks and Three-Dimensional Data in Vehicle Inspections (<https://arxiv.org/abs/2212.11507>)
 - CNNとVision Transformerを組み合わせた線路ボンドの異常検知
 - T. Hoshi, S. Shibayama, X. Jiang, Employing a hybrid model based on texture-biased convolutional neural networks and edge-biased vision transformers for anomaly detection of signal bonds, *J. Electron. Imaging*, 2023, 32, 023039 (<https://doi.org/10.1117/1.JEI.32.2.023039>)

最後に

現場の業務変革の実現に向けて、
両社はこれからも
AI・データ活用に取り組み続けていきます