



# 画像解析による電気設備診断システムの開発 —地上検査の車上化—

西日本旅客鉄道株式会社  
鉄道本部電気部電気技術室



執筆者 堀内 信吾

共同執筆者 日本信号株式会社 佐川 俊介 日本信号株式会社 遠藤 凌仁  
日本信号株式会社 丹羽 順一 日本信号株式会社 (当社から出向中) 舟茂 拓朗

## 01 はじめに

現在、鉄道分野における電気設備の検査の一つとして、現地にて設備の状態を人の目で確認する手法をとっています。電気設備は長距離にわたり設備が存在するため、日々多くの検査係員が線路内で検査を行っています。しかし近年、労働人口が減少している中で、これまでと同様の人手をかけて現地で検査をする手法を維持することが困難であることから安全・CSを維持し、検査

の省力化を実現出来る新たな検査手法の確立が必要で。そこで今回、総合検測車の更新に併せて、複数のカメラを搭載し、撮影された画像からAI技術を用いた画像解析を実施することで、設備検査の省力化を支援する「電気設備診断システム」を開発しています。本稿では、電気設備診断システムのうち、画像解析AIによる設備抽出と良否判定の開発成果について述べます。

## 02 システム概要

電気設備診断システムは画像を撮影し記録する「車上システム」と、撮影された画像から、画像解析により設備検査の省力化を支援する「地上システム」で構成されます。図1にシステム構成図を示します。

設備の撮り逃しが無いこと」、「1日8時間以上撮影できること」などを要件に、撮影周期、記録媒体の仕様を決定しました。車上システムの外観を図3、本装置で撮影した結果を図4に示します。

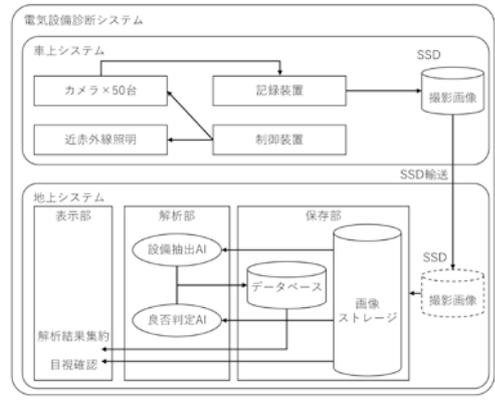


図1：システム構成図

表1：車上システムの主な仕様

項目	仕様	備考
カメラ台数	50台 (25台×前後2組)	上方カメラ×12 側方カメラ×8 がいのしカメラ×3 全景カメラ×2
解像度	4096×3000 pixel	4K
カメラ種別	近赤外線・白黒	全景カメラ前後各1台は可視光によるカラー撮影
撮影周期	3~10fps 走行速度時速 0~100km	最長 2.8m 進む毎に1回撮影できる周期に応じて変動
記録媒体	2TB SSD×10個	SSD 1個あたりカメラ5台分を記録
記録形式	静止画像	

### (1) 車上システム

総合検測車上に搭載する車上システムは車両屋根上のカメラと照明、車両内の制御装置と記録装置で構成されます。表1に車上システムの主な仕様、図2に撮影範囲を示します。車両屋根上のカメラと照明は、「電力設備と信号通信設備を同時に撮影できること」、「電気設備全般のひび欠けが判別できる分解能であること」、「設備の弱点箇所などを検査できるように設備の前後と架線設備の下面を撮影できること」、「夜間やトンネル内を検出できること」などを要件に、カメラ台数、解像度、カメラ種別の仕様を決定しました。制御装置と記録装置は、「時速100kmで走行しても

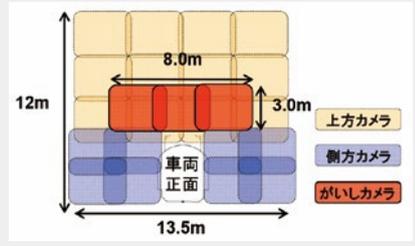


図2：撮影範囲



図3：車上システムの外観

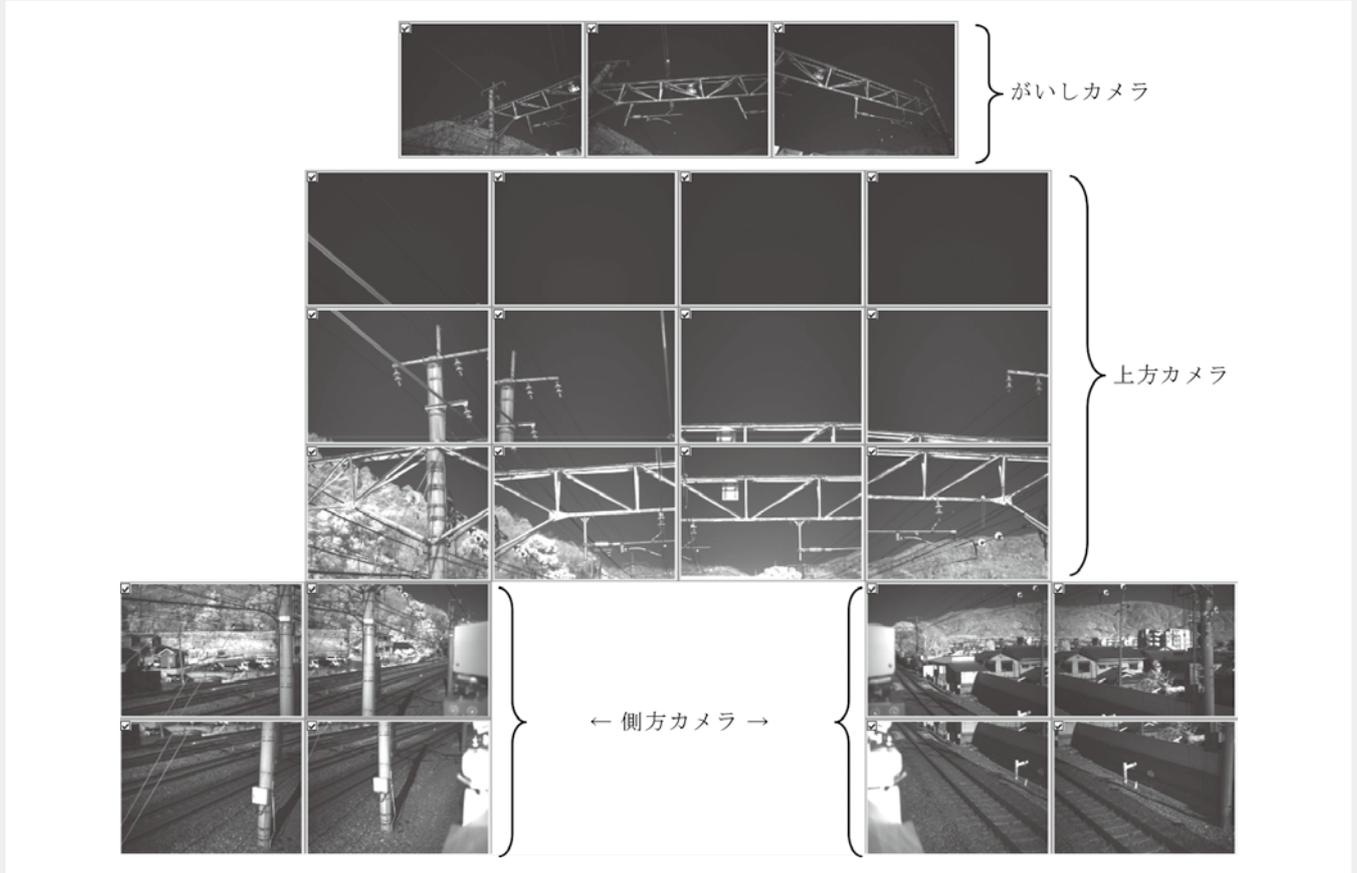


図4：撮影結果

(2) 地上システム

機器室に設置する地上システムは画像取込とデータ管理・保存を行う「保存部」と、画像解析を行う「解析部」、解析結果を集約して表示を行う「表示部」で構成されます。表2に地上システムの主な仕様を示します。

保存部は、「車上システムの SSD 10 台以上を同時に接続して画像の取り込みができること」、「1 年間分の画像データを蓄積できる容量を確保すること」、「5 年間分の解析結果などのデータベース蓄積ができること」などを要件に仕様を決定しました。

解析部は、「800km 走行分の撮影画像 約 2000 万枚を 10 日以内に画像解析できること」、「約 100 種類の設備に対応した複数の推論モデルによる AI 画像解析を並列で処理できること」などを要件に仕様を決定しました。

図5に地上システムの処理フローを示します。まず、地上システムに SSD を接続して、撮影画像などのデータ取り込みを行います。次に設備抽出 AI が画像を読み込んで、画像に写る 100 種類以上の電気設備を自動的に抽出・識別を行います。次に、抽出した設備は撮影時刻やキロ程を基に、設備台帳と照合を行います。設備台帳に設定された検査項目と、設備抽出した画像を基に設備のき裂や破損、さび・汚損などを良否判定します。最後に設備抽出結果、設備台帳リンク結果、良否判定結果を集約して、検査係員が確認できるように表

示します。これらの各処理は人の手を極力介さずに、膨大な量の画像を短期間で解析することが求められます。そのため、解析リソースを無駄なく競合なく使えるように、各段階で処理を自動で並行して実行するシステムを開発しました。また、設備抽出 AI と良否判定 AI は多種種類の設備を効率よく解析できるように、複数個の AI モデルを並列処理しています。

表2：地上システムの主な仕様

機器	項目	仕様
保存部	データ保存媒体	画像 : HDD データ : SSD
	データ保存容量	画像 : 500TB 以上 データ : 12TB 以上
	SSD 接続 I/F	USB3.1 Gen2×10 ポート
解析部	CPU	3.3GHz 48 コア×2CPU
	メモリ	512GB
	GPU	NVIDIA A100 40GB ×2 基以上

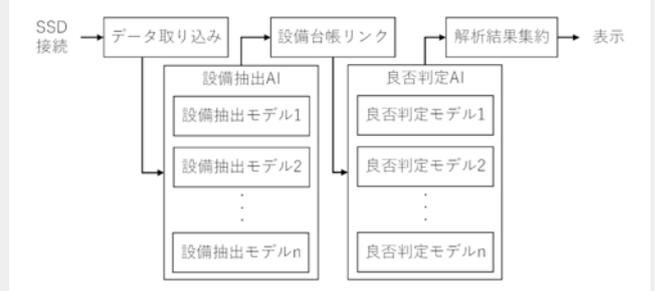


図5：処理フロー

## 03 設備抽出 AI の開発

### (1) 開発目標

設備抽出 AI は画像中のどの位置に何の設備が写っているかを自動で検出する物体検出の AI です。設備抽出 AI では、検査漏れの防止を最優先とした上で、検査労力の削減を目指します。そのために、設備台帳にない設備を抽出してしまう誤抽出と、設備を見逃してしまう未抽出に着目し、判定結果を分類しました。判定結果の分類を表3、開発目標を表4に示します。ここで未抽出率の方が目標を厳しくしているのは、設備の見逃しをなるべく減らすためです。

表3：判定結果の分類

		正解	
		設備 A がある	設備 A がない
判定結果	設備 A を抽出	真陽性 (TP)	偽陽性 (FP) (=誤抽出)
	設備 A を抽出しない	偽陰性 (FN) (=未抽出)	—

表4：開発目標

項目	割合	算出式
未抽出率	5%以下	未抽出率 = $100 \times \frac{FN}{TP + FN}$
誤抽出率	20%以下	誤抽出率 = $100 \times \frac{FP}{TP + FP}$

### (2) アルゴリズム概要

物体検出手法には機械学習と深層学習があり、前者は画像の特徴量と出力したいもの（位置・種類）の関係性を人があらかじめ定義してモデルに設定することで画像から物体の位置や種類を特定する方法です。後者はこの関係性を自動で求めて学習させることができます。

複雑な背景の下で、多様な写り方をする、多品種の設備を抽出する必要がある本システムでは、より少ない労力で必要な精度を得られる手法であると考え、深層学習方式を採用しました。設備抽出 AI には畳み込みニューラルネットワーク (Convolutional Neural Network: CNN) をベースとするモデルを使用しました。設備抽出 AI は、このモデルを複数個から構成し、さらにそれぞれのモデルで複数種類の設備を検出できるようにしました。これにより多数の設備の物体検出を実現します。以降複数のモデルのうちの1つを示すときは設備抽出モデルと表記します。設備抽出モデルの出力イメージを図6に示します。

図6のように設備の位置は矩形領域を座標で示し、その物体の種類（クラス）も同時に予測します。また、その物体らしさを示す指標である確信度（パーセンテージで示される）も出力されます。

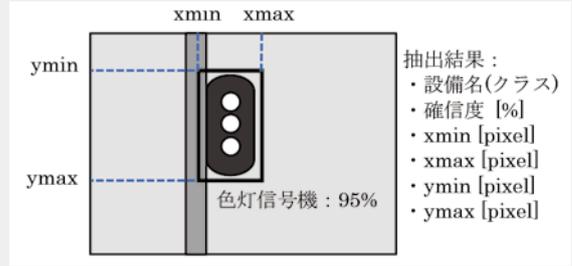


図6：設備抽出モデルの出力イメージ

### (3) 開発方法

設備抽出モデルの開発の流れを図7に示します。

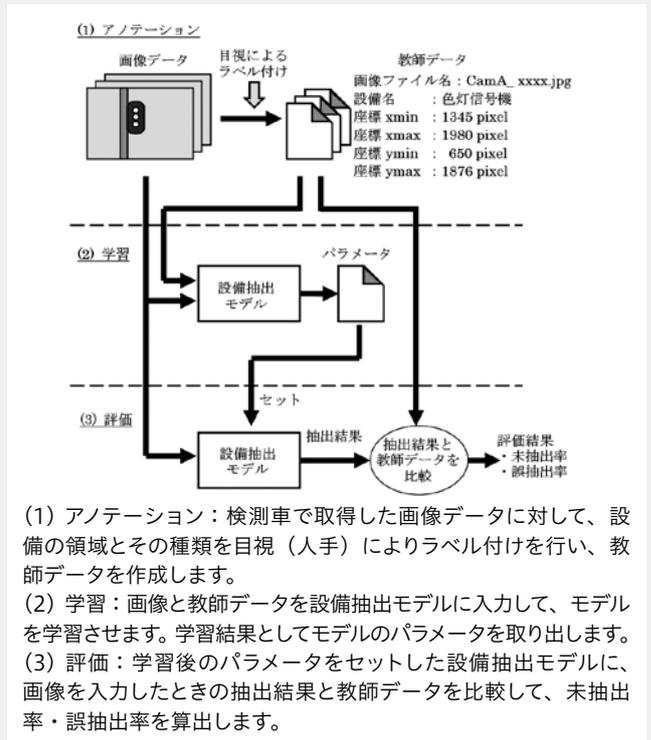


図7：設備抽出モデル開発の流れ

設備抽出 AI の開発では、主に以下の (a) ~ (c) を調整・試行を繰り返すことで開発目標に近づけていきます。

#### (a). 教師データの定義

画像に写っている設備は全てが検査用に適しているとは限りません。例えば画像に写ってはいますが、見切れ、ピンボケ、白飛び等が起きている場合は教師データとして適さない可能性があります。そのため、教師データ作成の基準を設備ごとに個別に設定しました。

#### (b). モデルの分け方

設備抽出 AI は複数のモデルから構成します。例えば設備 A ~ D の4種類を抽出させたい場合、1つのモデルで A ~ D を抽出させるように学習させることもできますが、モデル1は A と B を抽出させ、モデル2は C と D を抽出させるように2つに分けて学習させることもできます。モデルはなるべく設備ごとに分けた方が開発しやすいですが、地上システムにおける処理時間は増えてしまいます。そのため、まずは多くの設備を抽出できるモデルを作成し、目標精度に満たない設備のみ別のモデルに分けて精度を満たすことや、逆に2つ以上のモデルを1つのモデルに統合して処理時間の短縮を図ることを行いました。

(c). 確信度の閾値

設備抽出 AI が出力する確信度に閾値を設けることで、誤抽出率・未抽出率を調整できます。ただし、誤抽出率と未抽出率はトレードオフの関係にあります。例えば、誤抽出率を減らすためには確信度の閾値を上げればよいのですが、一方の未抽出率は増えてしまいます。本システムでは未抽出率の目標達成を優先して閾値調整を行いました。

(4) 開発結果

鉄道沿線上にある代表的な設備を対象とし、設備抽出モデルを評価した結果を表5に示します。コンクリート柱・可動ブラケット・曲線引装置・長幹がいしを正しく抽出した例を図8に示します。誤抽出の例を図9に示します。図中左の抽出結果は懸垂がいしを正しく抽出できています。図中右の抽出結果は懸垂がいし（ポリマー）を懸垂がいし（磁器）として誤抽出しています。この設備抽出モデルには懸垂がいし（ポリマー）を学習させていないため、懸垂がいし（磁器）と懸垂がいし（ポリマー）を正しく識別できていません。同一設備抽出モデルに似た形状のものを学習させることで設備の取り違えが少なくなると考えられます。

表5：設備抽出モデルの評価結果

設備名	未抽出率	誤抽出率
コンクリート柱	5%	28%
固定ビーム(V)	4%	8%
可動ブラケット	5%	34%
曲線引装置(可動ブラケット式)	4%	3%
懸垂がいし(磁器)	4%	66%
長幹がいし(磁器)	4%	22%

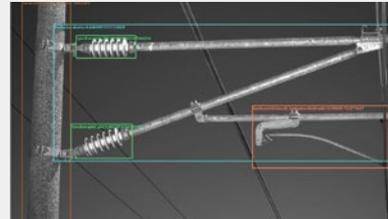


図8：正しく抽出した例

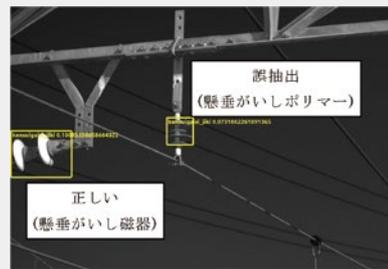


図9：誤抽出の例

04 良否判定 AI の開発

(1) 開発目標

良否判定 AI は、抽出した沿線設備の画像に対して、さびや汚損、き裂のような外観の不良の有無を自動的に判定する AI であります。良否判定 AI の開発目標を以下に決めました。

- ① 不良設備を誤って正常と判定する件数（偽陽性）が 0 件です。
- ② 良否判定 AI 全体の正解率が 80% 以上です。

$$\text{正解率} = \frac{TP + TN}{TP + FP + FN + TN}$$

正解率を求めるための判定結果の分類を表6に示します。

表6：判定結果の分類

	不良のない画像 (正常画像)	不良のある画像 (不良画像)
正常と判定	真陽性(TP)	偽陽性(FP)
不良と判定	偽陰性(FN)	真陰性(TN)

不良設備が見逃されることにならないように、偽陽性を 0 件となるように優先的に開発することにしました。偽陽性を 0 件にしようと AI を学習させると、正常な設備を誤って不良と判定する確率（偽陰性）が高まります。総合検測車は同一箇所を一年間に 3 回検測する運用になっているため、年間を通じた正解率が 99% になるように、検測 1 回あたりの正解率を 80% に設定しました。

(2) アルゴリズム概要

良否判定 AI も設備抽出 AI と同様に、パラメータの異なる複数の良否判定モデルから構成します。良否判定モデルのアルゴリズムの概要を図 10 に示します。良否判定モデルは、入力した検査対象画像に対して学習済みの CNN によって特徴量を算出します。この CNN は入力された画像が正常であれば正常画像の特徴群に、不良であれば不良画像の特徴群に近い特徴量を出力します。次に検査対象画像の特徴量と学習済みの特徴群との距離を求めます。次に正常の特徴群の異常度を 0、不良の特徴群の異常度を 1 と定義づけて、特徴量の距離を基に、検査対象画像の異常度を算出します。最後に異常度を閾値判定することで正常か不良かを判定します。

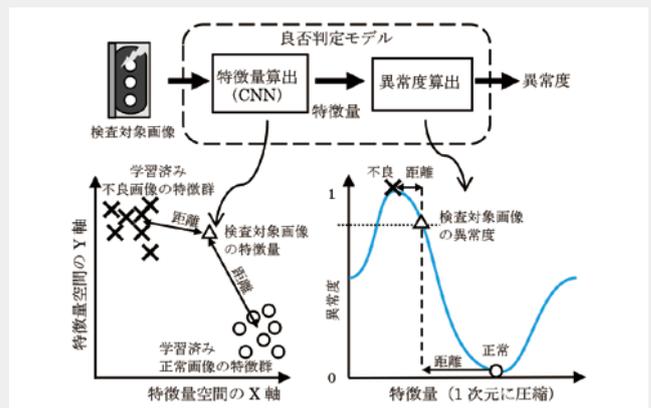


図10：良否判定モデルのアルゴリズムの概要

### (3) 開発方法

良否判定 AI の開発は学習・評価の2段階で行いました。学習では、正常画像と不良画像を入力して、04(2)節のアルゴリズムにより距離を算出する良否判定モデルを作成します。

評価では、作成した良否判定モデルに評価用の正常画像と不良画像（いずれも学習では未使用の画像）を入力して性能を評価し、判定基準を追加した実運用のための良否判定モデルを作成しました。

実運用では、設備抽出画像を入力して正常または不良を判定結果として出力します。

不良画像は実際の設備の不良・故障の画像を使用することが望ましいです。しかし、不良な設備が鉄道沿線で撮影できることは稀であるため、不良画像は正常画像と比べて極端に少なく学習が困難となります。そこで、正常な設備に不良を模して撮影した画像および正常画像に不良を合成した模擬不良画像を不良画像として定義しました。良否判定モデルは、正常画像の特徴と不良画像の特徴の違いを基に異常度を判定します。そのため、模擬不良画像で学習した場合でも、実際の設備の不良の画像を用いて学習した場合に近い判定ができると考えられます。学習に使用した不良画像の例を図 11 に示します。

### (4) 開発結果

外観の不良として、設備のき裂およびさび・汚損に対して評価を行いました。表 7 に主な設備の評価結果として、コンクリート柱のき裂、避雷器のき裂およびさび・汚損、看板のき裂およびさび・汚損についての評価結果を示します。

いずれの設備の不良についても、偽陽性を 0 件の条件を満たした上で正解率が 80% 以上と開発目標を達成しました。



図 11：学習に使用した不良画像の例

表 7：主な設備の評価結果

設備	不良	評価枚数	正解率
コンクリート柱	き裂	正常：50 枚	97.0%
		不良：50 枚	
避雷器	き裂	正常：58 枚	81.0%
		不良：58 枚	
避雷器	さび・汚損	正常：29 枚 不良：29 枚	82.8%
看板	き裂	正常：54 枚	82.5%
		不良：32 枚	
看板	さび・汚損	正常：20 枚 不良：20 枚	95.4%

## 05 まとめ

### (1) 開発成果

西日本旅客鉄道株式会社の新型総合検測車にて撮影した画像から自動的に設備を抽出し良否判定を行うシステムを開発しました。

設備抽出 AI は未抽出率については開発目標を達成しました。現在は誤抽出率を低減させるために、設備抽出モデルに学習させる教師データの増量と、設備種類の統合・分離などの改良を行っています。

良否判定 AI はき裂とさび・汚損について模擬不良画像を用いた学習で開発目標を達成することができました。現在は、良否判定できる設備種類を増やすための学習・評価を行っています。

### (2) 今後の展望

画像解析による検査の精度を向上するために、ピントや撮影深度を画像から自動判定することで、良否判定にふさわしい画像のみを選定する手法を開発中です。また、AI で自動判定できる不良状態の種類、例えば設備の取付角度、脱落、線条物の素線切れなどの不良も判定できるようになれば、検査係員の負担をさらに軽減することができます。

今後も電気設備診断システムの精度向上および機能改良を図り、2025 年度の本システムの運用開始を目指します。検査業務の省力化と安全性の維持向上を両立させて、鉄道サービスの持続的な提供を図りたいです。