

# 画像認識 AI の学習における現場知見活用の実践的検証

## Verification of CNN trained based on plant operators' know-how

山川 泰司<sup>1</sup>

Taishi Yamakawa<sup>1</sup>

<sup>1</sup>東京電力ホールディングス株式会社 経営技術戦略研究所

<sup>1</sup>Tokyo Electric Power Company Holdings, Inc. TEPCO Research Institute

**Abstract:** For CNN training, abnormal bar images were made using plant operators' knowledge. Trained CNN distinguished normal bar and abnormal bar with high successful rate.

### 1. はじめに

近年の人工知能技術の発展は目覚ましく、囲碁や自動運転、顔認証や多言語翻訳といった複雑な諸課題への処理能力が人間を超えるまでになった。国や企業レベルの課題に対しても人工知能技術の戦略的活用が期待[1]されており、電力業界においてはことさら、自由化や需要減少、自然変動電源や分散化といった事業環境変化の課題に対して、例えば、IoTや人工知能技術を駆使して設備の自動化や最適化、保全の効率化や高度化を実現し、競争力をつけることが求められている[2]。

センサデータを用いた設備保全については身の周りでも広く浸透しており、従来の閾値による異常判定をはじめとして、非線形回帰、ニューラルネットワーク、ベイジアンネットワーク等の高度な異常判定手法も通信や金融、製造、セキュリティの分野において利用されつつある。これらの手法は、正常時のセンサデータ群の分布を機械学習で定式化してモニタリングし、分布より乖離したときに異常状態と判別する。

他方、画像データを用いた設備保全の手法についても急速な性能向上を見せており、特にディープラーニングによる画像認識は、特徴抽出をアルゴリズム内で行うことにより複雑かつ精度の高い判別を可能にしている。これらの技術は、オープンソースのアルゴリズムと並列計算環境の普及によって容易に活用できる環境が整ってきている。

実際の現場における設備保全はセンサデータを基準とする手法が主流であるものの、人間が外見の特徴を頼りに異常を判別している事例も多い。今回、画像認識による設備保全の検証を行う事例は、図1に示すような発電所の石炭回収コンベア設備における、運搬板の変形である。何らかの原因により運搬

板に変形が生じると、設備に過大な負荷が生じて不具合が拡大するリスクがあることから、定期的な監視によって運搬板の形状確認が行われている。実際の画像と運搬板が変形した事例を図2に示す。

コンベアには数十枚の運搬板が巡回しており、各運搬板に付随する石炭も多様な状態をもつ。そのような非定常的な観測環境においては、レーザセンサを用いた運搬板の形状計測や、従来型の画像パターン検出による異常判別は困難である。このような現場の課題に対して、ディープラーニングによる画像認識 AI を用いて運搬板の異常を判別させることが出来るか検証を行った。

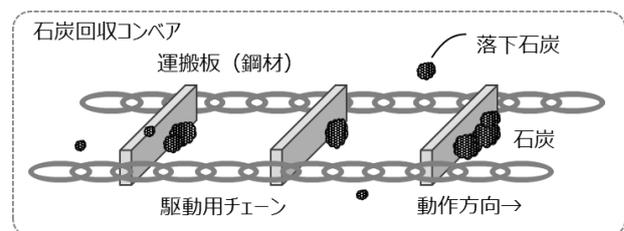


図1 石炭回収コンベア設備の概要

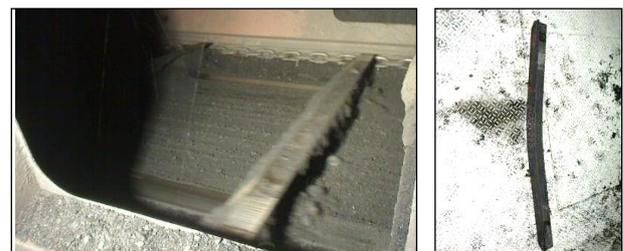


図2 稼働中の運搬板と過去の変形事例

## 2. 画像データを用いた異常判別

### 2.1 画像データの取得

ディープラーニングの学習に用いる画像を運転中の実設備より取得した。コンベアの点検窓の近傍に PC に接続したカメラを設置し、運搬板が収まるような画角にてインターバル撮影を行った。取得した画像から画像認識に必要な領域をトリミングし、グレースケール化、リサイズ処理を施して横 160 ピクセル、縦 100 ピクセルの画像データとした (図 3)。運搬板は左側から右側へ移動しているため、画像上の位置は一定ではない。

取得した画像 (約 8,000 枚) のうち、運搬板の異常判別が可能な範囲が写った画像は半数程度で、残りの半数程度は照明の影や外枠に重なり異常の判別が難しい無効画像であった (図 4)。

### 2.2 学習用画像の生成

ディープラーニングによるクラス分類 (本研究では正常と異常の判別) では、各クラスの特徴は学習用のデータから抽出される。ところが、現実の設備では、異常の頻度が小さく、異常データ (画像) が十分に存在しないことがある。学習用の異常データが無くては異常のクラス分類をすることが出来ない。例えば、正常のみを学習し、乖離度合を異常の基準とする方法では、異常とは関係の無い背景の変化を正しく判別することができない。

そこで、本研究では、正常クラスの画像から模擬的に生成した異常画像を異常クラスとして学習させた。具体的には、運搬板が有効に写った正常画像に対し運搬板の領域のみ歪ませる加工を行い、運搬板が変形した状態の画像を生成した。変形量は現場の見知に整合する大きさとし、画像の連続性に不自然さが生じないようにした。同様の加工をすべての正常画像に対して行った (図 5)。

加えて、画像データの多様化を図った。具体的には、まず正常クラスの画像に対して鮮明化、平滑化、ノイズ付加の画像処理を施した画像を新たに生成した。その後、生成した画像群に対して前述と同様に歪ませる加工を行い、正常画像群に対応する異常画像群を生成した。これらの方法により、学習と検証に用いる画像は正常クラス、異常クラスとも 15,672 枚ずつを準備した。学習に用いる画像数を多様化させて増加させたことにより、原画像に含まれる局所的な特徴に起因する過学習の緩和と、多様な画像パターンに適応可能な汎化性の獲得が期待される。

なお、これら画像ファイルの編集は、火力現場の

知見に基づいて加工プロセスをマクロ化し、市販の画像編集ソフトウェアの一括バッチ処理によって実行している。

### 2.3 分析環境、体制の構築

ディープラーニングの構築は Python 及び Tensor Flow を用いて行い、GPU を搭載したデスクトップ PC にて学習及び試験を行った。画像データの取得、画像の処理、学習計算、分析検証を一貫して行えるように体制を整え、カメラや PC の現場設置、設備見知のヒアリング、電源や通信網に関しても現場の協力を得て進めた。

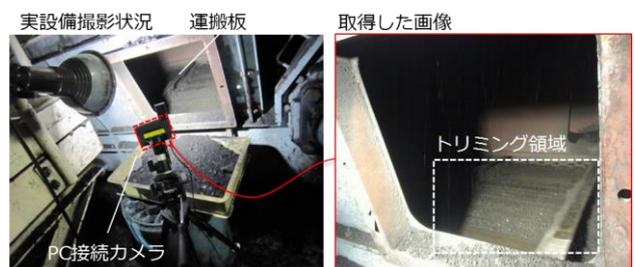


図 3 画像データの取得概要

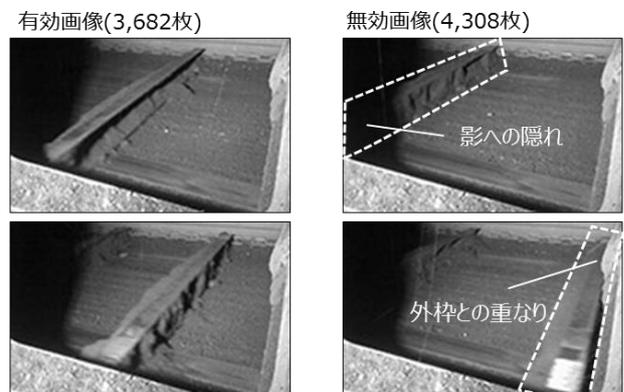


図 4 有効画像と無効画像の例

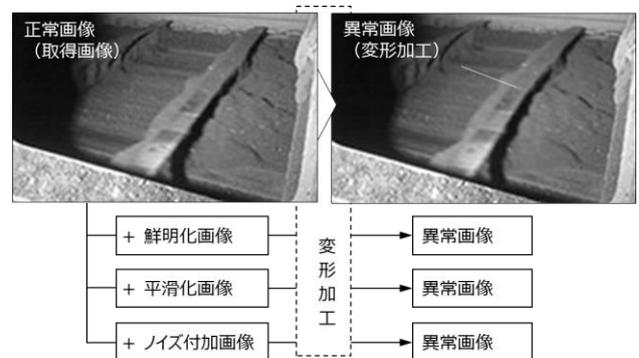


図 5 異常画像の生成

## 2.4 ディープラーニングの構成

構築した異常判別ネットワークの概要を図 6 に示す。畳み込み 2 層，プーリング 2 層，全結合 NN の中間層 2 層を経て，3 クラスに分類する CNN (Convolutional Neural Network) である。正常，異常クラスに加え，判別に必要な部位が十分に写っていない画像（無効画像）に対して保留する判定を行うクラスを学習させた。

## 2.5 精度検証

画像全体数の約 7 割で学習を行い，残りの 3 割の画像で試験を行った結果，運搬板が変形した画像に対し 99% 以上の高精度で異常と判別できる CNN が構築された (表 1)。誤判別率も低く，板の変形という異常様態に対しては，本構成の CNN で認識可能であることが示された。

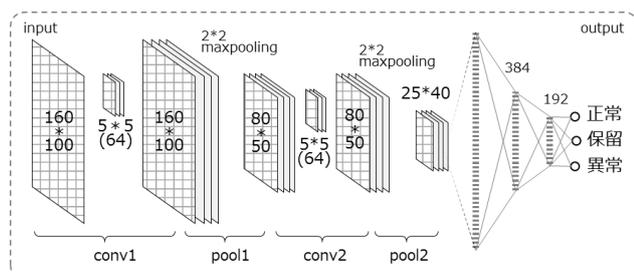


図 6 CNN の構成

表 1 画像認識による判別精度 (n = 10,940)

データ数	クラス	正常判別	異常判別	保留判別
4,704	正常画像	96.7 %	0.4 %	3.0 %
4,704	異常画像	0.1 %	99.7 %	0.3 %
1,532	保留画像	2.3 %	0.0 %	97.7 %

## 3. 現場適用に向けた考察

### 3.1 知見に基づく特徴の画像表現

本研究では，学習用の異常画像を属人的な知見から模倣的に生成した。一般的に，学習には実データを用いるのが通常であり，模擬データの学習は非現実的なバイアスが生じるように思われる。しかしながら，本検証において運搬板の変形という特徴をアルゴリズム的に記述していないにも関わらず，運搬板の位置，個々の板の違い，背景変化に影響されずに，変形のみを選択的に捉えて正しく判別させるこ

とが出来ており，これは現場の人間が視覚情報を整理して異常を認識するプロセスと類似している。

ディープラーニングのアルゴリズムでは，複数のクラスに共通して含まれている外乱的な特徴に対しては，学習時の誤差逆伝播の計算過程の中で，その特徴が意味を持たないようにフィルタ（重み）を誘導する操作が行われる。加えて，クラスの差が特定の視覚的な様態にあるならば，アルゴリズムはその特徴を抽出できるフィルタを探索し，判別のためのネットワークを構成する。結果として，正常画像を元にした異常画像を学習させた CNN は，画像中の外乱的な特徴にはロバストに，異常の様態を示す特徴にはシビアに反応するフィルタを持つように誘導されたと推察している。

人間の場合，初めて見る状態でも構造上の洞察や経験則，類推や因果に基づいて異常状態を認識することが出来る一方，それを定式化して共有することは難しい。逆に，純粋にデータドリブンな異常判別手法では，学習していない状態について異常か否かを判別することは出来ない。本事例は，両者の特性を補完し，限定的な状況においてはあながち，人間の知見により表現した異常様態をディープラーニングさせることで，人間の知見を画像認識 AI 上で定式化出来る可能性を示した。このアプローチは，異常の様態が視覚的に表現できる事象であれば同様に適用できる可能性が高いと考えている。

### 3.2 異常画像の生成手法の比較

一般的な設備は，深刻な異常の発生頻度が小さく，判別したい異常の学習データがない場合もある。このような背景から，学習用の異常データの生成方法がいくつか考案されている。

例えば，実在の設備やサンプルに実際に異常を起こさせてデータを取得する方法で，説得力のあるデータが得られる一方，多額のコストが必要となるため，それに見合う一部の設備にのみ採用される。また，計算機上で異常をシミュレーションし，計算結果から仮想の異常データを得る方法もあるが，物理現象に関わるメカニズムを正しくモデリングする知識技能が前提となり容易ではない。最近では，少数の実データから AI により特徴抽出を行い，類似画像を生成する GAN 等の利用も考案されている[3]。

それらと比較すると，知見に基づく画像生成は属人的な面はあるが，異常様態への特徴学習の誘導やロバスト性の獲得の利点は魅力で，他の手法と組み合わせることで実データの乏しい異常にも対応した診断装置の構築に貢献できる可能性がある。

### 3.3 現場課題への対応

現場では、カメラの故障やズレにより、意図した画像が取得できなくなる状況も考えられる。そのような状況に対し、AIが正常や保留と誤判別し続けると実際の異常を見逃す恐れがある。よって、何らかの手段により状況変化を認識する必要がある。

検証のため、学習済みのCNNへ意図していない画像を入力し、応答を調べた。具体的には、カメラの故障や画角ずれ等を模擬した画像（図7）をCNNへ入力し、出力層の信号強度の分布を調べた。

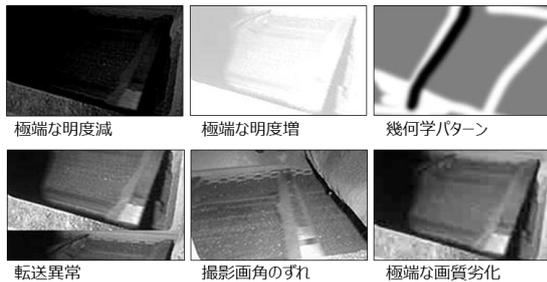


図7 意図しない画像の模擬例

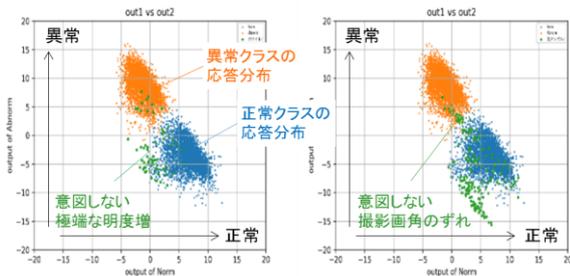


図8 意図しない画像の入力に対する応答分布例

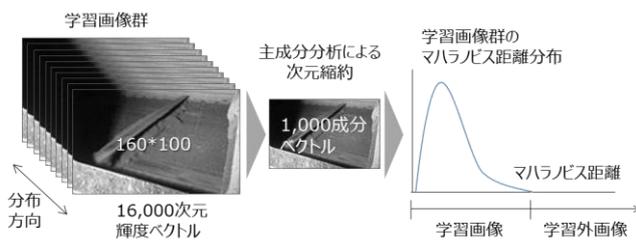


図9 意図しない画像入力への判別

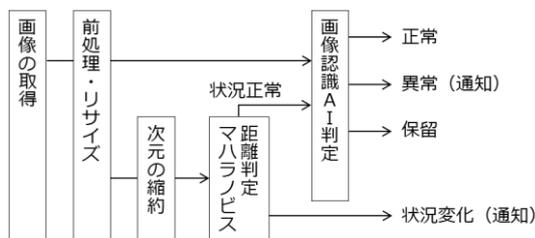


図10 異常判別の検知フロー

図8は、CNNへ画像を入力した際の、出力層における信号値の分布例である。横軸が正常度、縦軸が異常度で、保留度の軸は割愛した。意図しない画像に対する応答は、学習済の画像の応答分布に混じり重なって分布しており、ここから意図しない画像の応答の特徴を判別することは難しい。これは、画像の特徴抽出のため畳み込みフィルタが学習データ画像のクラス分類に最適化され、それ以外の特徴抽出機能が希薄化されるためであると思われる。

そこで本研究では、意図しない状況変化に対応するため以下の手法を用いた。まず、学習画像16,000次元の輝度ベクトルを、分布方向の主成分分析で1,000次元の主成分ベクトルに縮約する。次に、学習画像の各主成分の平均と標準偏差を基準とするマハラノビス空間上で、入力画像の主成分のマハラノビス距離を求める。この距離の大小に基づき、学習画像に類似するか、意図しない画像に属するかを判定する（図9）。この手法を併用し、事前に学習出来ないような現場の状況変化も検知できるよう判別フローを改良し、使用することとした（図10）。

### 4. おわりに。

ハードウェア、ソフトウェア、通信インフラ等、画像やAIをより身近に活用できる環境になる一方、実際の現場にAI技術を適用するには、現場知見を実践的に統合して課題を解決するアプローチがますます重要になると考えている。今後、本研究の成果を足掛かりに画像認識のさらなる技術検証と現場適用を進める予定である。

### 謝辞

本研究は東京電力フュエル&パワー株式会社の受託と協力を受けて実施したものである。

### 参考文献

- [1] 人工知能技術戦略会議：人工知能技術戦略(2017), <http://www.nedo.go.jp/content/100862413.pdf>,
- [2] 総合資源エネルギー調査会 電力・ガス事業分科会 電力・ガス基本政策小委員会（第一回）：電力・ガス産業の今後の在り方(2016), [http://www.meti.go.jp/committee/sougouenergy/denryoku\\_gas/denryoku\\_gas\\_kihon/pdf/001\\_09\\_00.pdf](http://www.meti.go.jp/committee/sougouenergy/denryoku_gas/denryoku_gas_kihon/pdf/001_09_00.pdf)
- [3] 東芝レビュー（2017年9月）：画像認識精度を向上させるディープラーニング技術を用いた学習用画像の自動生成 (p18-21), [https://www.toshiba.co.jp/tech/review/2017/04/72\\_04pdf/a05.pdf](https://www.toshiba.co.jp/tech/review/2017/04/72_04pdf/a05.pdf)