

画像AIによるコンプレッサ設備の運用最適への適用

Application of Image Classification AI to Optimal Operation of Compressors

膨大な設備稼働情報の時系列データに基づく運用良否判定の自動化を目指して

工場のコンプレッサ設備を効率よく運用するための設定チューニングには膨大な時系列データ分析が求められる。本研究では画像AIを用いて膨大なデータから稼働状態の判別を行うとともに、正規表現を活用して設備全体での運用の良否を自動で判定する手法を見出した。



執筆者
先端技術応用研究所
情報技術グループ
中村 剛


1 背景と目的

コンプレッサ（圧縮空気製造設備）は工場における電力消費の約20%を占める代表的なユーティリティ設備であるが、省エネ・最適運用には操業状態に合わせた細かなチューニングが必要である。長期間の設備計測を可能とする近年のIoT・クラウド技術の進化を背景に、中部電力ミライズでも工場のお客さま向けにこうした設備の最適運用サービスを行ってきた。

運用における改善ポイントを見出し最適な設定チューニングを行うには、人手による膨大な稼働状態の時系列データの分析が必要である。分析の省力化・自動化のため、これまで様々な時系列予測モデル手法の検証も行ってきたものの、学習期間外の工場の操業形態の変化に予測を適用し、運転良否を判断させることが困難であった。

今回、時系列データを画像に変換し、画像AIを用いることにより、人間の判断に近い説明可能なプロセスで、操業変化にも追従可能な判断処理を実現した。

2 時系列データからの学習・推論用画像データ生成



第1図 時系列データの画像変換

通常、人間系で設備の稼働状況を把握する際には消費電力の時系列データ（折れ線グラフ）を用いるが、今回の画

像AIによる判別では1秒単位の時系列情報の粒度を損なわずに学習データを作成するため、消費電力の大きさを色に変換し、1秒間=1ピクセルとして、15分間のデータを30x30ピクセルに並べて学習用画像を生成した（第1図）。

学習データは定速機用、インバータ機用にそれぞれクラス分類し、3年分のデータから各1万枚の学習データを準備した（第1表）。こうした学習データをもとにAzure AutoMLで最適と判断されたモデル（MobileNetV2）で学習を実行した。

第1表 学習画像データの例（定速機用）


分類	教師データのイメージ	サンプルイメージ
フルロード (FullLoad)	濃い緑	
しわ取り (Adjust)	濃い緑と薄い緑が混在 色の変化回数が少ない	
ハンチング (Hunting)	濃い緑と薄い緑が混在 色の変化回数が多い	
アンロード (Unload)	濃い青に薄い緑 色の変化がなだらかな	
停止 (Stop)	紫	
欠損 (NoData)	赤	

3 画像AIを用いたコンプレッサ稼働状態の判別

各号機の1秒単位の時系列データから1分ごとに15分間隔の画像を1枚ずつ作成し推論を実行し稼働状態の判定結果に枠色を付与するとともに、判断結果をラベル付け（状態継続時間により大・小文字で区別）を行った（第2表）。

第2表 推論結果のラベル付け（定速機）

分類	判定結果 (枠色)	判定例 (正)	判定例 (微妙)	判定結果ラベル	
				30分未満	30分以上
フルロード (FullLoad)	明るい緑			f	F
しわ取り (Adjust)	暗い緑			a	A
ハンチング (Hunting)	オレンジ			h	H
アンロード (Unload)	青			u	U
停止 (Stop)	紫			s	S
欠損 (NoData)	赤			n	N



第2図 稼働状態推論の例

第2図は1日分の定速機1台の稼働状況と判定結果の例を、第2表は代表的な判定結果を図中①～④の4か所を選定して時系列データ（折れ線）と比較した結果を示す。

第3表 判定結果と時系列データの比較（定速機）

時間帯	判定結果	画像	同時刻の時系列データ
①	A (Adjust) しわ取り		 ロード・アンロードを繰り返しているが④よりも頻度が少ない
②	S (Stop) 停止		 ロード・アンロードを繰り返しているが④よりも頻度が少ない
③	F (FullLoad) フルロード		 ロード・アンロードを繰り返しているが④よりも頻度が多い
④	H (Hunting) ハンチング		 ロード・アンロードを繰り返しているが④よりも頻度が多い

時系列データで見ると、①（しわ取り）と④（ハンチング）はともにロード・アンロードの状態を繰り返しているが、①に比べ④はアップダウンの頻度が多く、適切に判別ができています。第2図のように画像と推論結果の枠色の同時表示によってAI判定結果を視覚的に容易に把握可能とした。

4 設備全体での運用状況の良否判定

設備全体の運用状況の良否を判断するには、個別号機の稼働状況の判別だけでなく、その組合せが重要となる。そこで、各号機の判別結果ラベルを組合せて全コンプレッサの稼働状況を表示する文字列を毎分生成し、中部電力ミライズがこれまで培った知見に基づいて作成した正規表現ルールと照らし合わせ、良否判定を行うロジックを作成した（第3図）。

稼働状態判別結果		人間系の知見に基づき生成された正規表現ルール		
コンプレッサ	稼働状態	状況	正規表現	検出例
1号機 (定速)	フルロード (F)	データ欠損	<code>.*[Nn].*</code>	NS-AS, FFNS-NnS, ...
2号機 (定速)	ハンチング (H)	定速機が1台以上30分以上ハンチング	<code>.*H.*</code>	FH-AS, FHSU-AS, ...
3号機 (インバータ)	停止 (S)	<途中省略>		
4号機 (インバータ)	しわ取り (A)	定速機が30分以上フルロードが停止	<code>^[FS]*.*</code>	FS-SS, FFSS-SSS, ...
		全機が停止	<code>^[Ss]*.*\$</code>	SS-SS, SSSS-SSS, ...
		上記以外	<code>*</code>	Fu-SS, FFSS-SSS, ...

定速機群、インバータ機群ごとにソートしハイフン(-)で接続して文字列化

FH-AS

文字列と正規表現を照らし合わせ良否を判定

第3図 全コンプレッサ稼働状態の文字列化



第4図 運転状態良否判定結果の表示例

第4図は定速機2台、インバータ機2台の工場における運用状況の良否判定を行った例である。状態文字列を正規表現ルールと照らし合わせ、緑（良）、黄（不明）、赤（不良）、灰（欠損）の判定が実現した。

5 まとめ

今回開発した手法は、これまで人間が行ってきた設備稼働状況の判断を説明可能な形での自動化を実現できた。今後、コンプレッサ以外の設備にも活用方法を模索して行きたい。