

画像処理や機械学習を活用した金属材料の錆レベル自動判定

錆レベル判定の業務量削減、誤判定の抑制に向けて

Automatic Judgment of Rust Level of Metal Materials Using Image Processing and Machine Learning To Reduce Workload of Rust Level Judgment and Control False Judgments

(エネルギー応用研究所 ネットワークG 配電T)

(Distribution Team, Network Group, Energy Applications Research and Development Center)

現状、人が目視により判定している変圧器底部の錆腐食レベルについて、業務の効率化や誤判定の抑制を実現するため、最新の画像処理や機械学習技術を活用した自動判定手法の検討を行った。

At present, the rust corrosion level at the bottom of transformers is determined by visual inspection. To make this judgment more efficient and to eliminate any false judgment, we examined an automatic judgment method that uses state-of-the-art image processing and machine learning technologies.

1 はじめに

電力インフラでは、鉄塔や変圧器、架線用金物等多岐にわたって金属材料を使用している。金属は経年により錆腐食し、腐食が進展すると強度低下や破断に至り、経済的・社会的に大きな損失を与えることもある。このため、不具合発生に至る前に補修や取替をする必要があり、定期的に目視による巡視・点検を行っている。目視での判定は、多くの労力や高い判定能力を要するため、業務の効率化、判断の定量化・バラツキの抑制が期待できる画像処理や機械学習技術を活用した判定手法が有効である。

2 錆画像データの取得

本研究では、変圧器底部の錆を題材とした。画像データは、現地に施設された変圧器の底部画像を真下から撮影し、それぞれの画像について、判定基準に基づき錆レベルを0、A、B、Cにランク分けした(第1図)。

錆ランク	錆レベルの説明	画像例
0	・錆がまったくない	
A	・薄赤褐色の錆が部分的に発生 ・塗装の浮き上がり	
B	・赤褐色の錆が連続で発生 ・塗装部分に「浮き上がり・亀裂・剥離・錆汁」が発生	
C	・黒色化または、赤褐色の錆が発生し素地が露出 ・鉄素地の肉厚が減損	

第1図 錆レベルの判定基準

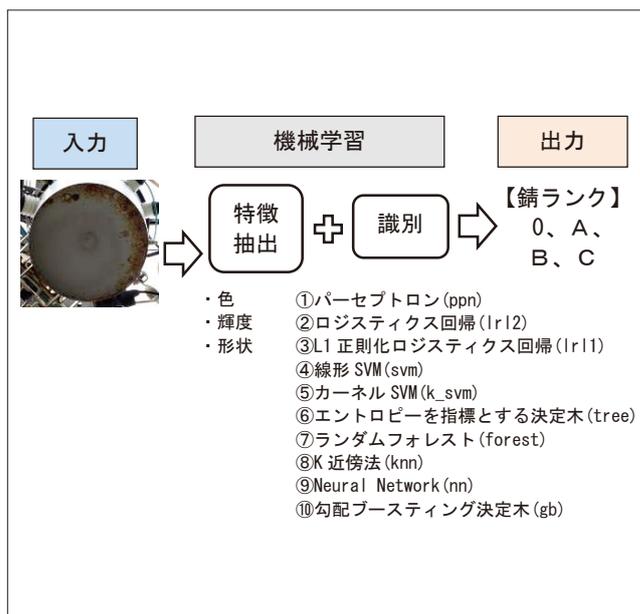
3 自動判定手法

各種機械学習と市販ソフトウェアのHALCON Deep Learning^(注1)を用いて、人が事前判定した結果との合致率を検証した。

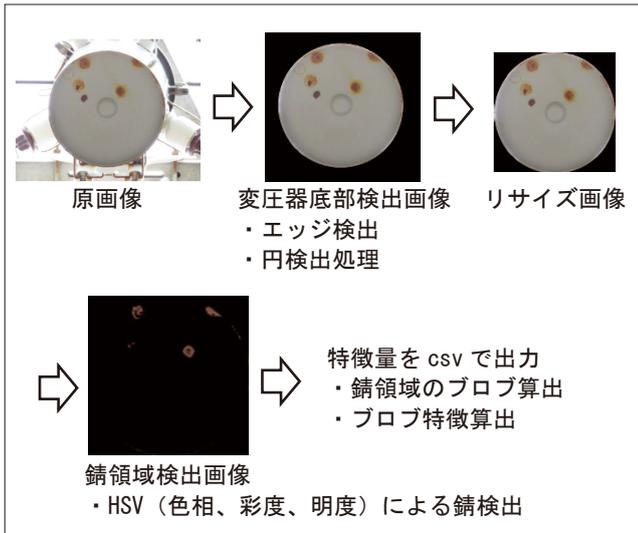
(注1) HALCONは、高精度かつ高機能な画像処理ライブラリで、2000以上もの画像処理関数を組み合わせることで非常に高精度な画像処理を行うことができる。現在、工場や検査装置等、国内だけで数万のシステムでHALCONが利用されている。

(1) 機械学習の処理概要

処理概要を第2図に示す。入力画像から錆領域を自動検出し(第3図)、計測した特徴量を入力、錆ランクを出力とする機械学習を実施した。錆ランク判定のための着目点(特徴)は、錆領域一つ一つの輝度平均、コントラスト等の輝度特徴14種類と面積等の形状特徴5種類を設定した。これらについて、変圧器底部全体における平均値、分散等の統計特徴7種類を算出し、画像1枚に対して133種類の特徴量を計測する。これを入力として、第2図に示す10種類の機械学習アルゴリズムで学習とテストを行った。



第2図 機械学習の処理概要



第3図 画像処理の流れ

(2) HALCON Deep Learningの処理概要

画像全体から変圧器底部を検出する方法は、撮影した画像から変圧器底部の縁と一致する「エッジ」を検出する「形状ベースマッチング法」により行った。底部認識後の画像をサイズ調整したものを入力、錆ランクを出力とする学習とテストを行った。なお、精度向上のため、元画像を回転させた画像で学習用画像枚数を増やして学習とテストを行った。

4 テスト結果

(1) 機械学習

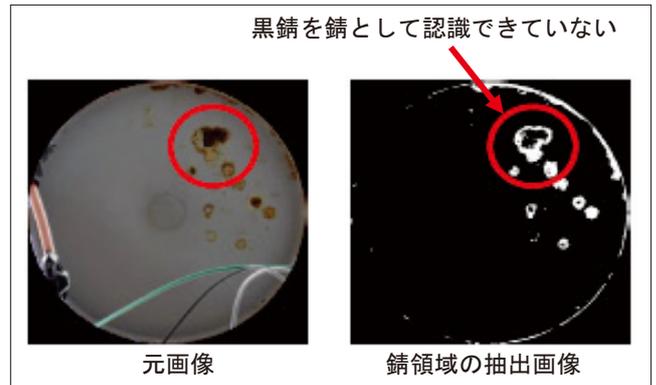
10種類の機械学習アルゴリズムの中では、⑦ランダムフォレストが最も合致率が高く（第4図）、全体合致率は71.4%であった（第1表）。判定不一致の要因として、錆領域抽出において、黒錆領域が検出できていなかったことや（第5図）、ランクCの学習用データが少なかつたため、他のランクより著しく合致率が低下したものと考えられる。なお、人による判定結果のバラつきも影響していると考えられる。



第4図 各機械学習における正解率

第1表 ランダムフォレストにおける判定結果

		ランダムフォレストによる判定結果			
		0	A	B	C
人間による判定結果	0	83	5	5	0
	A	18	46	16	0
	B	4	10	51	0
	C	0	1	13	0



第5図 黒錆領域未検出の例

(2) HALCON Deep Learning

HALCONの全体正解率は86.8%であった（第2表）。学習用画像を増やしたため、機械学習のRandom Forestよりも合致率が高くなったと考えられる。なお、判定不一致の要因としては、機械学習と同じく、人による判定結果のバラつきが影響していると考えられる。

第2表 HALCON Deep Learningの判定結果

		HALCONによる判定結果			
		0	A	B	C
人間による判定結果	0	82	2	1	0
	A	7	58	9	0
	B	0	3	48	3
	C	0	1	4	9

5 今後の展開

今回の検証により、変圧器底部の錆レベル自動判定技術実現に見通しをつけることができた。機械学習においては、黒錆領域の検出結果を加味することで合致率の向上が期待できる。また、機械学習、ディープラーニング何れにおいても、学習用画像を増やすことで合致率の向上が期待できる。今後は、より多くの学習用画像を取得すると共に、錆ランクの定量化・精緻化により、合致率向上を図っていく。また、変圧器底部だけでなく様々な金属材料の錆レベル自動判定に展開していく。



現所属：電力NWCP岡崎支社
豊橋営業所配電建設課
執筆者／揚田剛士