

# 金属バリ検出に向けたディープラーニング型異常検知アルゴリズムの開発

中山 恵介\* 平間 毅\*\* 若生 進一\* 小野 浩二\*\*\*

## 1. はじめに

株式会社ヒューマンサポートテクノロジーでは、異常データの発生頻度が少ない金属加工の現場等で有効な画像検査システムの構築を目指し、正常データ及び少量の異常データを用いたディープラーニング型異常検知アルゴリズムの開発を行っている。

当センターは、異常（金属バリ）検知アルゴリズムの中で用いられているハイパーパラメータの最適化技術の研究開発を行った。

## 2. 目的

本研究開発では、株式会社ヒューマンサポートテクノロジーが開発した異常検知アルゴリズムを対象に、ハイパーパラメータの最適化が判別精度向上に与える有効性を検証した。

## 3. 研究内容

### 3.1 異常検知アルゴリズム

本研究開発における異常検知アルゴリズムの学習モデルは、株式会社ヒューマンサポートテクノロジーが提携しているノースカロライナ州立大学松田昇教授から提供された試作プログラムを用いた。

図 1 に学習モデルの全体像を示す。画像を CNN(Convolutional Neural Network)に入力し、距離学習によって CNN の重みを更新する。距離学習では、画像を CNN に入力した時に中間層から出力される中間特徴量を用いる。正常データ入力時に出力される中間特徴量と異常データ入力時に出力される中間特徴量のユークリッド距離が最大化するように学習を行い、CNN の重みを最適化して、学習モデルを構築した。

本研究開発では、学習モデル構築に係るハイパーパラメータの調整を行い、判別精度向上を図った。




図 1 学習モデルの全体像

### 3.2 データセット

本研究開発では、株式会社ヒューマンサポートテクノロジーから提供されたデータセットを用いた。画像の回転、左右反転、上下反転といったデータ拡張を行い、表 1 に示すデータ数に拡張した。

表 1 データ拡張前後のデータ数

	データ数 (枚)	
	データ拡張前	データ拡張後
正常	250	2580
異常	79	756

表 2 に示すように、ハイパーパラメータ調整時は、学習データの一部をハイパーパラメータ調整用に割り当て、各試行における判別精度の評価を行った。配分率は、正常、異常データそれぞれの総数における率を示す。

表 2 データ数及び配分率

		データ数 / 配分率	
		調整用データセット	調整前後比較用データセット
学習データ	正常	1806枚 / 70%	2064枚 / 80%
	異常	453枚 / 60%	529枚 / 70%
ハイパーパラメータ調整用データ	正常	258枚 / 10%	-
	異常	76枚 / 10%	-
テストデータ	正常	516枚 / 20%	516枚 / 20%
	異常	227枚 / 30%	227枚 / 30%

### 3.3 ハイパーパラメータの調整手法

本研究開発では、学習モデル構築に係るハイパーパラメータの調整を行うため、ハイパーパラメータ最適化フレームワークである Optuna を用いて、最適化を試みた。Optuna は、Tree-structured Parzen Estimator (TPE) というベイズ最適化アルゴリズムの一種を用いて調整を行う。

その最適なハイパーパラメータを調整するアルゴリズムの考え方を以下に示す。

- 1) 完了している試行の履歴（目的関数の計算値）に基づいて、有望そうな領域を推定する。
- 2) その領域の値を実際に試し、目的関数の計算値が最大化するよう繰り返し計算を行う。

各試行における目的関数の設定を 3.4 に、目的関数の最大化結果を 3.5 に記述する。

### 3.4 目的関数の設定

目的関数を評価指標 F2 として、F2 が最大化するよう繰り返し計算を行った。本研究開発における F2 は、異常検知アルゴリズムが正常、異常を判別する精度と同義である。正常、異常を判別する流れを図 2 に示す。学習データ、テストデータを学習済モデルに入力すると、CNN の中間層から中間特徴量が出力される。中間特徴量を特徴量空間に埋め込み、学習データとテストデータのユークリッド距離  $d_1$ 、 $d_2$  を求める。

例えば  $d_2 > d_1$  の場合、テストデータが正常の学習デ

ータの近くに埋め込まれており、テストデータと異常の学習データが遠くに埋め込まれていることから、テストデータは「正常」と予測する。テストデータの実際のラベルを確認して「正常」の場合、「TN」にカウントする。FN、FP、TPについても同様に、図2に示す方法によりカウントする。これらの方法により、テストデータセットにおいて正常、異常の判別を行い、最終的なTN、FN、FP、TPの数を求める。

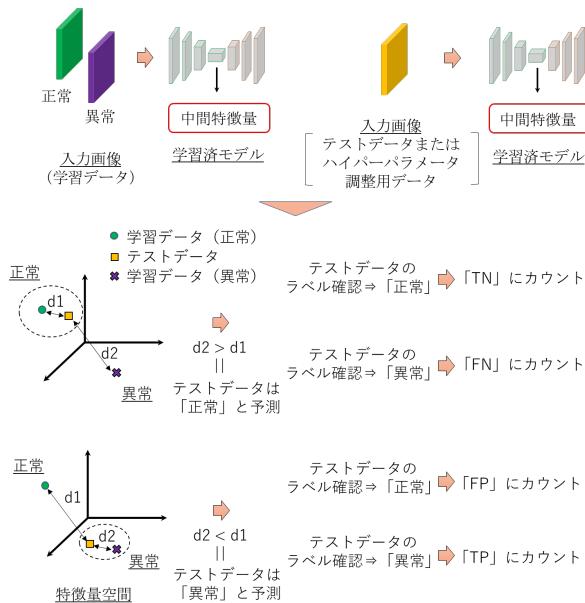


図2 正常、異常判別の流れ

次に、評価指標の適合率(Precision)、再現率(Recall)を求める。

- 適合率：異常と予測して、予測通り異常であった割合…式(1)
- 再現率：実際に異常である内、異常であると正しく予測した割合…式(2)

$$Precision = \frac{TP}{TP + FP} \tag{1}$$

$$Recall = \frac{TP}{TP + FN} \tag{2}$$

また、本研究開発では、適合率と再現率両方を考慮した評価指標であるF値を使用する。F値を式(3)～(5)に表す。

- F1 : 適合率と再現率の調和平均の指標…式(3)
- F0.5 : 適合率を重視した指標…式(4)
- F2 : 再現率を重視した指標…式(5)

異常検知アルゴリズムでは、「異常」の見逃しを少なくすることが求められるため、再現率重視のF2をベイズ最適化手法の目的関数に設定した。

$$F1 = \frac{2Precision \times Recall}{Precision + Recall} \tag{3}$$

$$F0.5 = \frac{1.25Precision \times Recall}{0.25Precision + Recall} \tag{4}$$

$$F2 = \frac{5Precision \times Recall}{4Precision + Recall} \tag{5}$$

### 3.5 ハイパーパラメータ調整結果及び判別精度比較

次に、ベイズ最適化により、表3に示すハイパーパラメータを試行50回にて調整した。

表3 調整したハイパーパラメータ

	本研究における表記	概説
1	learning_rate	損失関数の最適化計算における初期学習率
2	margin	距離学習における距離計算の初期パラメータ
3	emb_size	距離学習における中間特徴量の次元数

試行33回目で目的関数F2が最大となるハイパーパラメータとして表4の結果を得た。

表2の最右列に示すデータセットを用いて評価を行った。表4に、ハイパーパラメータ調整前後における判別精度F2の比較を示す。調整により判別精度は60.7%から72.2%まで11.5%向上した。

表4 ハイパーパラメータ及び判別精度の比較

		ハイパーパラメータ調整前	ハイパーパラメータ調整後
ハイパーパラメータ	1 learning_rate	0.00010	0.06944
	2 margin	512	544
	3 emb_size	8	13
判別精度F2 (%)		60.7	72.2

### 4. まとめ

金属バリ検出に用いる異常検知アルゴリズムのハイパーパラメータを、ベイズ最適化手法により調整することで、正常・異常の判別精度が11.5%向上することを確認した。

今後、さらに判別精度を向上するためには、データセットの画像鮮明化、データ数の増加などを行う必要があると思われる。

### 5. 参考文献

- 1) <https://optuna.readthedocs.io/en/stable/>