

(405) パターン認識

変分自己符号化器の潜在空間におけるカバレッジに 基づく鉄道設備の異常診断向け学習データの評価

Evaluation of learning data for anomaly diagnosis of railway facilities based on coverage in Variational Autoencoder latent space

青戸 勇太[†] 中村 雅美^{††} 前田 俊二^{††}

Yuta Aoto[†] Masami Nakamura^{††} Shunji Maeda^{††}

[†]Hiroshima Institute of Technology, Graduate School ^{††}Hiroshima Institute of Technology

1 緒言

鉄道設備において、電車線路設備はその種類と数が多く、目視による検査には労力がかかるため、検査の自動化が期待されている[1][2]。画像解析による検査の自動化を実現するには、対象設備の抽出と診断が必要である。本報告では、疎なデータ分布に関して変分自己符号化器(Variational Auto Encoder:VAE)[3]によるデータ拡張を活用し、局所部分空間法(Local Subspace Classifier: LSC)[4]と組み合わせて線路設備の異常診断を実現する方法について述べる[5]-[8]。なお、対象設備の抽出は、一般物体検出手法である Single Shot MultiBox Detector(SSD)[9]を用いる。

本報告では、学習データの粗密の把握方法、粗密が異常診断の感度に与える影響、およびこれらの結果に基づく学習データの拡張方法などについて述べる。

2 識別対象と想定される課題

本報告では、図1から図4に示すハンガ、碍子、コネクタ、き電分岐装置などの多種類の電車線路設備の中からハンガを対象とする。ハンガは、吊架線からトロリ線を吊り下げてレールと平行に保つため、5m 間隔に設置された設備である。走行中の列車内に、車外に向けてカメラを設置し、図5に示すような取得画像からハンガを識別する。

対象設備は、異常時の発生頻度が極めて低いため、教師あり学習に基づく異常判定を行うのに十分な異常サンプル画像を取得することは困難である。そこで、異常と正常を分ける 2class 分類の手法は適用が困難であると考え、教師なし学習による外れ値検出を用いる。

ハンガ画像は、形状や見え方の違いによって様々なパターンが存在する。異常診断を行う場合、様々なパターンから未知のデータに近いものに絞って比較を行うため、近傍データを対象とする LSC 法が有効である。未知のデータに類似した近傍データを取得できればより精度の高い診断を実現できる。しかし、正常データといえども多様であり、ばらつきが大きく、未知のデータの近くに、学習データを生成

することが必要である。本報告では未知データの近傍に VAE により学習データを生成することにする。なお、正常データを対象とし、分類目的ではないため、特徴抽出器としては教師なしの Auto-Encoder(AE)を用いることにする。

3 提案手法

図6にハンガの抽出と診断に関する提案手法を示す。SSD を用いてハンガを含む部分画像を抽出し、これに対して LSC により異常かどうかの判定を行う。SSD では、ハンガのクラス確率と存在領域を表すバウンディングボックスを求める。このバウンディングボックスの画像に対して、AE による低次元特徴を求めてモデル化を行う。低次元特徴からなる正常ハンガの学習データを準備し診断を行うが、対象が立体的で角度によって見え方が異なり、さらに背景が見えるため、特徴空間において疎な分布となる。そこで、VAE を適用することにより学習データの拡張を行う。そして、未知の画像と学習データを比較するが、multi-class 識別器の LSC を 1class 識別器として扱い、外れ値を検出する[10]。LSC では図7に示すように、観測点(未知の評価対象)に近い、k 近傍の学習データを用いて k-1 次元の線型多様体を生成しそこへの投影距離に基づいて異常かどうかを判定する。投影距離が大きいほど異常度が高い。

本報告では既報[5]-[8]を前提に、新たに学習データの粗密の把握方法、粗密が異常診断の感度に与える影響、およびこれらの結果に基づく学習データの拡張方法に関して述べる。一般に学習データ数は異常診断の性能を左右する。本報告では学習データの粗密に着目し、これを起点に、異常診断としてもつべき学習データの特徴について述べる。

まず、学習データの粗密を、ボロノイ図を用いて評価する。次に、診断に使う LSC の投影距離との関係を散布図により明らかにする。

さらに、LSC の投影距離が大きな学習データについて、その近傍に VAE を用いて新たに学習データを生成し、投影距離が小さくなることを確認する。また、並行して、投影距離が小さい学習データ双方についてその近傍に異常が発生した場合に、異常と

して診断可能であることを確認する。

4 評価条件

評価条件を表 1 に示す。画像寸法は 1,920×1,080 画素である。車載カメラにより乗客目線で撮影した動画から 93 フレーム(ハンガ:105 個)を切り出し、SSD の学習データとした。テスト用データには、新たに 500 フレーム(547 個)用意し、クラス確率と IoU のしきい値はそれぞれ 0.3, 0.5 に実験的に設定した。

AE の学習モデルを作成するにあたり、SSD で抽出したハンガ画像を 100×200 画素に変更したものを教示させた。また、潜在変数の次元数は 100 次元とした。VAE の模式図を図 8 に示す。VAE は、学習データの各々に対して $\mu + \sigma \cdot \varepsilon$ で定義される分布 z からランダムにサンプリングして類似した画像を生成する。ここで、 μ , σ はそれぞれ平均と標準偏差、 ε は標準正規分布である。 z において、前もって取得していた学習データセットから各画像について 10 点を新規に生成し、学習データに追加して、これを AE の学習データとした。LSC に関しては、近傍データ数を変えて評価を行った。その過程で、提案手法の有効性の確認を行うべく、疑似欠陥を加えて、その異常度を求めた。

5 評価結果

図 10 に、学習データの粗密をボロノイ図により評価した結果を示す。また、図 11 に、診断に使うボロノイ図の各領域の面積と LSC の投影距離の関係を、散布図を用いて示す。この結果から、相関が大きくないこと、そしてその原因はボロノイ図の面積が大きくても、隣接する領域内に距離が近い学習データが存在することにある。したがって、異常診断で用いる LSC の投影距離を用いて、学習データの粗密を表すことが妥当であることが分かる。

次に、投影距離が大きい学習データについて、データ拡張を行った場合の振舞いを評価した。

着目した画像は、図 12 に示す投影距離最小と最大のものである。これらに対し、図 13 に示すようなデータ拡張を行った。図 14 に LSC の評価結果を示す。横軸は、SSD により抽出したハンガ画像の番号を示し、縦軸は LSC に基づく異常度を示す。学習データ数 495 のときのものであり、学習データから一つ抜き方の要領で 1 枚ずつ画像を抜き取り、これを未知の評価画像とした。図 14 に示したものが、すべての学習データに対し、それらがもつ異常度合となる。表 2 と表 3 には、図 12 に示した画像についてデータ拡張により投影距離が減少する様子を示す。いずれも正常データの異常度合を示す。

次に、異常を表現すべく疑似欠陥を加える対象画像は、学習データに対し LSC の投影距離が最小のもの、すなわち近傍に他の学習データが最も多く存在するものとした。これを図 15 に示す。ここで、投影

距離最小となるデータを未知として LSC の距離を求めた場合は、異常の場合でも見逃しを生じやすい。

これらの疑似欠陥に対し、表 4 に示すように示すように、欠陥(大)を異常として認識し得ることが確認できた。

このように提案手法である、粗密に基づく学習データの拡張法の有効性が確認できた。この評価結果から、学習データについて、LSC 距離が一定以下となるようカバレッジの下限制約を設けることが重要であると言える。

つぎに、学習データ数を絞ったときの異常度の評価結果を図 16 に示す。学習データの数の大小は、異常診断にとって検討課題の一つであり、少数学習データでも提案手法が有効に機能してほしい。そこで、ここでは、学習データ数を意図的に絞り込み、LSC に基づく異常度がどのようになるか調査した。試行したいくつかの学習データ数のときの結果を図に示すが、学習データ数 30 のときにデータ拡張した場合でも、疑似欠陥を検知可能であることを確認した。なお、欠陥画像に対応する正常画像を含まない条件にて評価した。これは、運用において必ずしも対応する正常画像が取得できるとは限らないためである。このように、きわめて少数の学習データのときでも提案手法が望み通りに動作することが確認できた。

提案した手法は、大量の学習データを必要とする GAN 等を用いた異常検知におけるデータ拡張にも適用可能であると考えられる。

6 結論

本研究では、ハンガと呼ばれる電車線路設備を対象に、SSD によるハンガ画像抽出と LSC による異常診断を提案し、VAE によるデータ拡張によって、疎な分布を有する少数学習データにおいても異常診断が可能であることを確認した。特に、学習データは LSC 距離が大きくなるよう学習データを取得するか、追加生成すべきことを明らかにした。

今後は、異常診断の感度を左右する学習データの生成についてさらに検討を行う予定である。

参考文献

- [1] 兎束 哲夫：電気設備の健全性維持に向けたメンテナンス技術，第 26 回鉄道総研講演会(2013)
- [2] 根津 一嘉：電車線の非接触測定技術，https://www.rtri.or.jp/sales/gijutu/2016/is5f1i000004iad-att/161021_8.pdf
- [3] Diederik P. Kingma et al, Auto-Encoding Variational Bayes, arXiv(2013), <https://arxiv.org/abs/1312.6114>
- [4] 堀田政二：線型多様体間距離に基づくパターン識別と学習，部分空間法研究会 Subspace2008
- [5] 中村雅美他：Single Shot MultiBox Detector に

よる鉄道設備抽出に関する検討, E06, 精密工学会 2019 年度春季大会(2019.3.13)

- [6] Masami Nakamura et al : Basic Study on Railway Facility Extraction with Single Shot Multibox Detector, International Conference on Machine Learning and Cybernetics, 4016, ICMLC 2019(2019.7)
- [7] 青戸勇太, 中村雅美, 前田俊二, 電車線路設備を対象とした低次元特徴に基づく局所部分空間法による異常診断, 電気学会, 知覚情報/次世代産業システム 合同研究会(2019.8.28)
- [8] 青戸勇太他, 変分自己符号化器による疎な分布のデータ拡張を活用した局所部分空間法による電車線路設備の診断, 令和元年度(第 70 回)電気・情報関連学会中国支部連合大会(2019.10.26)
- [9] Wei Liu, Dragomir Anguelov, Dumitru Erhan, Christian Szegedy, Scott Reed, Cheng-Yang Fu, Alexander C. Berg: SSD: Single Shot MultiBox Detector, European Conference on Computer Vision 2016
- [10] 前田俊二, 渋谷久恵: 部分空間法に基づく残差ベクトル軌跡による異常検知手法の検討, 精密工学会誌, Vol.78, No.12, pp.1087-1092(2012.12)

表 1 評価条件

Index		Conditions
SSD	Input image size	1,920 × 1,080 pixels
	Input image data	500 frames
	Training data	93 frames
	confidence	0.3
IoU	threshold	0.5
Variational AutoEncoder	Training data	494 images
	Augmented data(output)	4,940 images
Auto-Encoder	Training data	494 images (without augmentation)
		5,434 images (with augmentation)
	Input image size	100 × 200 pixels
LSC	Dimension number of latent variable	100
	K-nearest data	2,3,5,8,10

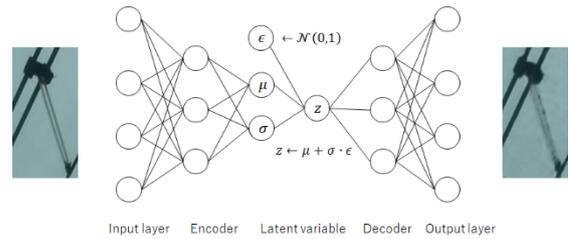


図 8 VAE の模式図



図 1 ハンガ 図 2 碍子 図 3 コネクタ 図 4 き電分岐



図 5 取得画像 (1,920 × 1,080 画素)

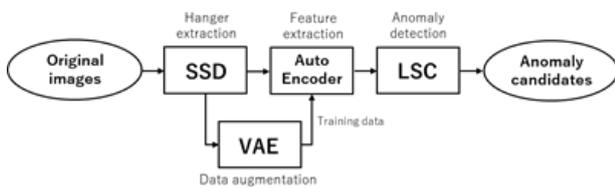


図 6 提案手法

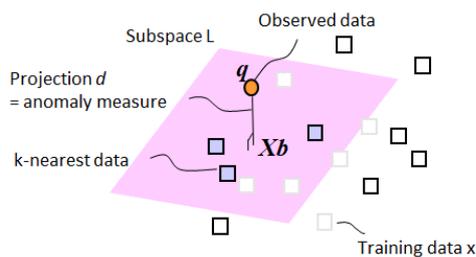


図 7 LSC の概念

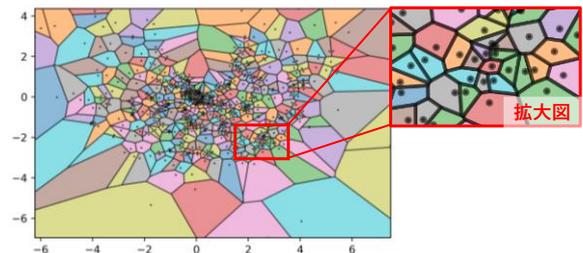


図 9 ボロノイ図と一部拡大

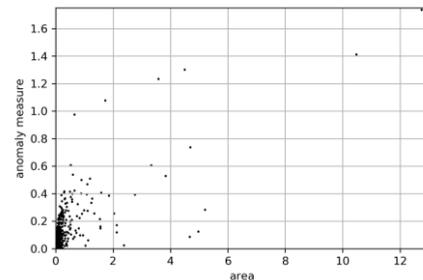


図 10 ボロノイ領域面積と LSC 投影距離の散布図

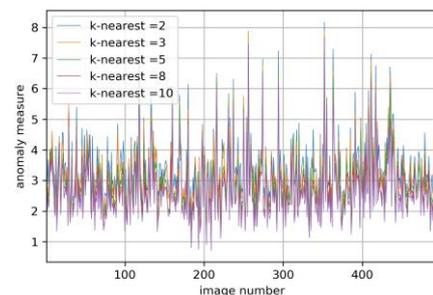


図 11 LSC による異常度評価結果



(a) 投影距離最小 (b) 投影距離最大
図 12 注目画像

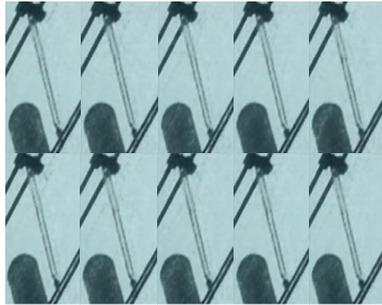


図 13 投影距離最大の画像の拡張
(VAE による生成 10 点, ここで $\mu=0, \sigma=1$)

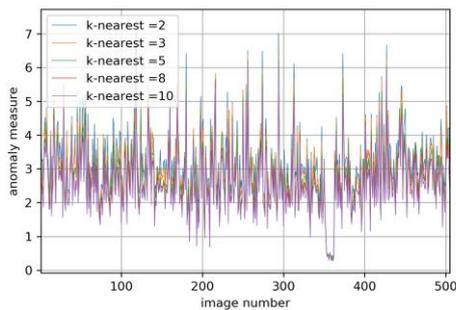


図 14 データ拡張後の LSC 異常度評価結果

表 2 データ拡張による距離最大データの異常度合の変化 (正常学習データ)

k-nearest	anomaly measure	
	without augmentation	with augmentation
2	8.18	1.12
3	7.86	1.11
5	7.70	1.11
8	7.65	1.06
10	7.54	1.05

表 3 データ拡張による距離最小データの異常度合の変化 (正常学習データ)

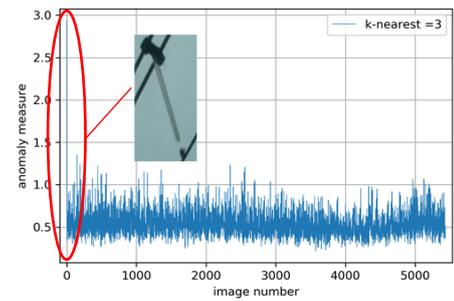
k-nearest	minimum value of minianomaly measure	
	without augmentation	with augmentation
2	1.08	0.356
3	0.957	0.304
5	0.888	0.301
8	0.725	0.281
10	0.713	0.274



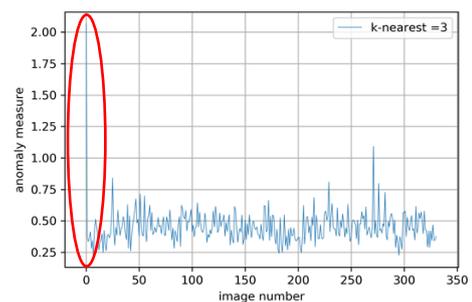
(a) 欠陥(小) (b) 欠陥(大)
図 15 疑似欠陥画像
(100×200 画素)

表 4 疑似欠陥画像の異常度評価結果

(a) 欠陥(小)		(b) 欠陥(大)	
k-nearest	anomaly measure	k-nearest	anomaly measure
2	0.237	2	0.476
3	0.215	3	0.417
5	0.215	5	0.416
8	0.209	8	0.401
10	0.208	10	0.401



(a) 学習データ数 494+拡張データ数 4,940
(疑似欠陥検知可能)



(b) 学習データ数 30+拡張データ数 300
(疑似欠陥検知可能)

図 16 学習データ数を絞ったときの異常度の評価結果