

環境騒音調査の騒音レベルデータを対象としたオートエンコーダを用いた異常音判別 Anomaly Detection for Noise Level Data of Environmental Noise Measurement with Autoencoder

荒川 由人[†] 荒川 永人[†] 大谷 紀子[‡]
Yuito Arakawa Eito Arakawa Noriko Otani

1. はじめに

環境基本法第 16 条第 1 項の規定に基づく環境基準は、生活環境を保全し、人の健康の保護に資する上で維持することが望ましい基準であり、大気、水、土壌、騒音をどの程度保つことを目標に施策を実施していくのかを示している。騒音に係る環境基準の達成状況は騒音レベルデータを収集して評価する。評価対象となる騒音は道路交通等に起因する騒音であるため、評価対象外の騒音は収集したデータから除外しなければならない。除外すべき異常音として、航空機騒音や鉄道騒音、建設作業騒音、鳥の鳴き声などの平常でない自然音、パトカーのサイレンなどの通常は発生しない人工音、測定員の咳払いなどの測定による付加的な音が挙げられる[1]。建設環境研究所では、騒音計により騒音レベルデータ、IC レコーダにより音データを記録し、騒音レベルの時刻歴グラフを見て異常音の疑いがある時点特定した後に、特定した時点の音を聞いて、除外を要するかどうかを判断している。以上のように、現行の主たる異常音処理方法は、記録されたデータを後から丹念に調査する方法となっており、大きな労力と時間を要し、記録時間が長くなるほど、正確に異常音を除外することが困難になる。したがって、環境騒音調査における異常音除外作業は、作業員にとって大きな負担となっており、省力化が必要である。異常音除外作業における作業員の負担を軽減することを目的として、K 近傍法(KNN)を用いた異常音判別手法が提案されているが、滅多に観測されない正常音に対する異常度が高いという問題がある。本問題に対処し異常音判別の性能を向上させるため、本研究ではオートエンコーダを用いた手法を提案する。

2. 異常音判別手法

近年、深層学習は異常検知の分野においても注目を集めており、さまざまな異常検知タスクにおいて、従来手法を上回る性能を示す手法が提案されている[2]。本研究では、深層学習に基づく異常検知手法の中核であるオートエンコーダ(AE)を用いて、騒音レベルデータの異常度を算出する。AE は入力と出力が一致するように学習するニューラルネットワークであり、図 1 に示すように、入力空間を低次の空間に射影する Encoder と、低次の空間から元の空間に戻す Decoder から構成される。正常データのみ、または正常データが大多数を占めるデータセットを用いて AE を学習することにより、中間層に正常データの表現空間を作ることができる。正常データの表現を学習した AE に異常デー

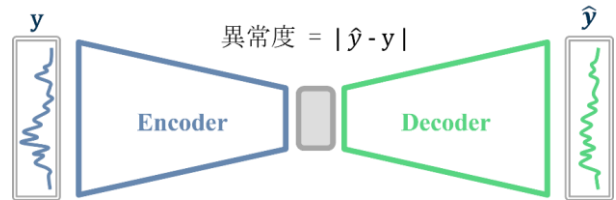


図 1 AE による異常度算出概略図

タが入力されると、Decoder が入力ベクトルを再構成できず、入力ベクトルと出力ベクトルの間に大きな再構成誤差が生じる。再構成誤差を異常度として定義することで AE を異常検知に適用することができる[2]。

本研究における AE を用いた異常度の算出手順の概要を以下に記す。

- ① 学習用の 1 次元の騒音レベルデータから、窓幅 w のスライド窓(図 2)により部分時系列を取り出してベクトル化し、 w 次元のデータセットを作成する。
- ② ①で作成したデータセットを用いて AE の学習を行う。
- ③ 判別対象の 1 次元の騒音レベルデータから、窓幅 w のスライド窓により部分時系列を取り出してベクトル化し、 w 次元のデータセットを作成する。
- ④ ③で作成したデータセットを、②で構築した学習済み AE に入力する。
- ⑤ 図 1 に示すように、④の出力ベクトルと入力ベクトルの差を異常度とする。

異常検知に効果的な AE のアーキテクチャとして、全結合型ニューラルネットワークを利用したオートエンコーダ(FC-AE)や、畳み込みニューラルネットワークを利用したオートエンコーダ(CNN-AE)、回帰型ニューラルネットワークの一種である LSTM を利用したオートエンコーダ(LSTM-AE)が挙げられる[2]。本研究では、上記 3 種類の AE モデル、および KNN と FC-AE のアンサンブルモデル(KNN+AE)を構築し、環境騒音調査における騒音レベルデータに対する異常音判別の性能を比較した。

FC-AE は、各層のニューロンが前の層のすべてのニューロンと接続されている全結合層のみで構成された Encoder

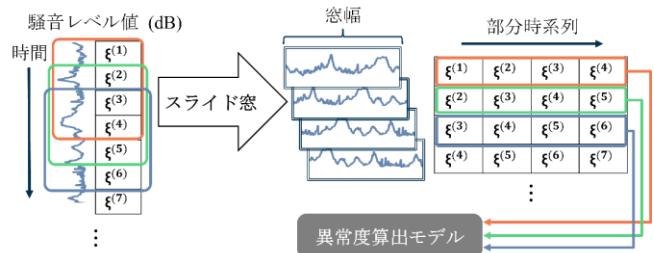


図 2 スライド窓概略図

[†] 東京都市大学大学院環境情報学研究科 Tokyo City University, Graduate School of Environmental and Information Studies

[‡] 東京都市大学メディア情報学部 Tokyo City University, Faculty of Informatics

と Decoder を持つ AE である。シンプルな構造であり、以降に記すアーキテクチャの基礎となる。

CNN-AE は、CNN により構成された Encoder と Decoder を持つ AE である。CNN は画像処理などに使用されており、畳み込み層により空間的な特徴を抽出することができる。本研究において異常音判別の対象とする騒音レベルデータは 1 次元の時系列データであることから、時系列データに対して効果的な 1-Dimensional Convolutional Neural Network(1D-CNN)を用いる[3]。1D-CNN は 1 次元の入力信号に対して、1 次元の畳み込みフィルタを時間方向にスライドして畳み込むことで特徴的な信号を抽出することができる。CNN-AE は Encoder 部の畳み込み層によりダウンサンプリングを行い、Decoder 部の転置畳み込み層によりアップサンプリングを行う。

LSTM-AE は、LSTM により構成された Encoder と Decoder を持つ AE である。LSTM は、リカレントニューラルネットワーク(RNN)の一種である。RNN は出力に向かう信号が入力にフィードバックされる構造を持つネットワークであり、順序関係を持つ時系列データの学習に効果的である。しかし、RNN はネットワークが深いと勾配が消失し、学習が進まなくなる勾配消失問題を抱えている。LSTM は入力ゲート、忘却ゲート、出力ゲートを導入することで、過去データの保持および削除を制御し、勾配消失問題に対応した。LSTM-AE は、Encoder として機能する LSTM 層が入力信号を受け取り、時間的な依存関係を捉え低次元の表現ベクトルにエンコードする。次に、Decoder として機能する LSTM 層が表現ベクトルを受け取り、元の信号を再構成する。

KNN+AE は、KNN と FC-AE の出力の加重平均をとるアンサンブルモデルである。KNN は距離ベースの手法であり、AE は再構成誤差ベースの手法であることから、アプローチが根本的に異なる。また、入力する部分時系列の適切な長さも異なる。したがって、アンサンブルにより、各手法の強みを活かし、弱点を補完することができ、性能向上が期待される。加重平均における各手法の重みの比は、KNN : FC-AE = 7 : 3 とした。

3. 評価実験

評価実験では、建設環境研究所が用意した 8 日分の騒音レベルデータのうち、7 日分を学習データセット、1 日分をテストデータセットとする 8 分割クロスバリデーションを行い、総合的にモデルの性能を評価する。評価指標として、PR 曲線の AUC を用いる。PR 曲線は、閾値を変化させながら適合率と再現率をプロットしたグラフである。適合率は正例と予測したデータのうち、実際に正例であるものの割合であり、再現率は実際に正例であるもののうち、正例であると予測されたデータの割合である。AUC は PR 曲線の下部の面積を表す。面積が最大で 1、最小で 0 となり、1 に近づくほど性能が高いことを示す。AUC を用いる

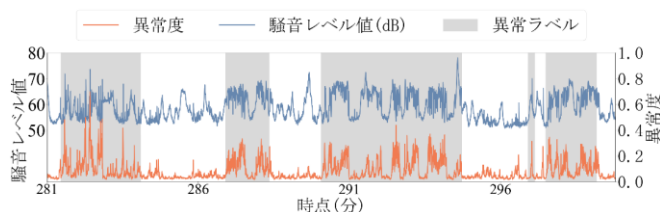


図 3 異常度可視化

表 1 各手法の AUC

Test Data	KNN	FC-AE	CNN-AE	LSTM-AE	KNN+AE
1 日目	0.897	0.846	0.841	0.845	0.907
2 日目	0.903	0.939	0.948	0.946	0.933
3 日目	0.932	0.907	0.857	0.886	0.929
4 日目	0.967	0.904	0.872	0.909	0.971
5 日目	0.895	0.902	0.870	0.882	0.898
6 日目	0.962	0.962	0.956	0.962	0.963
7 日目	0.960	0.963	0.969	0.966	0.969
8 日目	0.961	0.960	0.961	0.959	0.966
平均	0.935	0.923	0.909	0.919	0.942

ことで、閾値の影響を受けずに、汎用的な異常度算出モデルの性能を評価することができる。

KNN+AE により算出した異常度を可視化したグラフの一部とクロスバリデーションによる各手法の評価結果を図 3、表 1 にそれぞれ示す。

4. おわりに

本研究では、環境騒音調査の異常音除外作業における作業員の負担を軽減することを目的として、AE を用いた異常音判別手法を提案した。表 1 に示すように、AE の中でも、全結合層のみで構成されたシンプルなアーキテクチャである FC-AE が特に優れた性能を示した。FC-AE はいくつかのテストデータセットにおいて、先行研究の KNN を上回る性能を示した。また、KNN と FC-AE のアンサンブルモデル KNN+AE は、8 日分の騒音レベルデータのうち、1 日分を除くすべてのテストデータセットにおいて、先行研究の KNN を上回る性能を示した。さらに、図 3 に示すように、異常ラベルが付与されている時間帯で異常度が高くなっていることから、異常度のグラフを見て異常音の疑いがある箇所を容易に特定することができる。したがって、提案手法により異常音除外作業における作業員の負担を軽減することできるといえる。

しかし、本研究で使用した騒音レベルデータは 1 地点のデータのみである。したがって、今後新たにさまざまな地点で騒音レベルデータを収集し、各モデルの真の精度とロバスト性を評価する必要がある。

謝辞

本研究を進めるにあたり、株式会社建設環境研究所に騒音レベルデータをはじめ多くのデータを提供していただきましたことを心より感謝いたします。

参考文献

- [1] 環境省, “騒音に係る環境基準の評価マニュアル 道路に面する地域編” (2015).
- [2] Raghavendra Chalapathy, Sanjay Chawla, “Deep Learning for Anomaly Detection: A Survey”, arXiv:1901.03407 (2019).
- [3] Serkan Kiranyaz, Onur Avci, Osama Abdeljaber, Turker Ince, Moncef Gabbouj, Daniel J. Inman, “1D convolutional neural networks and applications: A survey”, Mechanical Systems and Signal Processing, Vol.151 (2021)