

1d CNN-LSTM による調節弁内部の異常検知 Anomaly Detection in Control Valves by 1d CNN-LSTM

茂木 貴弘^{*1} 中澤 友哉^{*1} 田原 鉄也^{*1}
Takahiro Motegi Yuya Nakazawa Tetsuya Tabaru

^{*1} アズビル株式会社
Azbil Corporation

This paper proposes an anomaly detection system for time series data by using 1d CNN-LSTM networks, which is a combination of one dimensional convolutional neural network (1d CNN) and long short time memory (LSTM). The CNN processes a time series data from a sensor and its output is passed to LSTM. After training of the networks, the CNN grows into an appropriate filter to emphasize features of the time series in frequency domain, and the LSTM becomes a good feature extractor. The extractor works fine even under noisy conditions. It generates a feature vector and the vector is utilized to diagnose anomalies. We applied the proposed system to vibration sensor data obtained from a control valve. The system detected anomalies due to cavitation, which is one of the most serious phenomenon of control valves, with 99.5% accuracy. The result shows availability of our proposed method.

1. はじめに

本稿では、時系列一次元信号の分類タスクによる異常検知アプリケーションとして、振動センサデータを分析した事例について報告する。

石油・化学業界をはじめ各種プラントにおいては、流量等を制御する操作端として調節弁が用いられており、調節弁内部で発生する異常の一つとして、キャビテーションと呼ばれる現象がある。キャビテーションとは、流体が弁を通過する際に、流体圧力がその流体の飽和蒸気圧以下に下がり再度圧力回復する過程で、流体中に気泡が発生、消滅する一連の現象である[azbil 13]。キャビテーションによる衝撃圧は数百気圧にも達し、弁内部を損傷させるため、放置し続けられれば流体漏洩などの事故につながる可能性もある。そのため、プラントの予防保全の観点からキャビテーションを検出することは重要である。

そこで、キャビテーションを自動で検出することを目的に、調節弁本体の外部に振動センサを取り付けて信号を取得し、振動信号を分析する手法を検討した。振動信号の例を図 1 に示す。

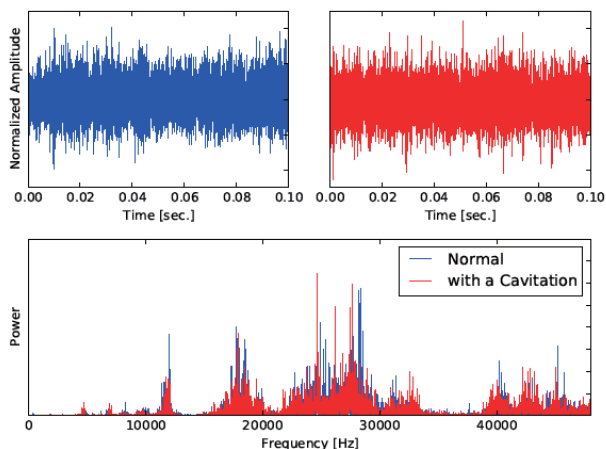


図 1 分類対象の一次元信号

図 1 の青線はキャビテーション無しの波形であり、流体による振動がノイズとして計測されている。図 1 の赤線はキャビテーション有りの波形であり、流体による振動に加えて、非定常にキャビテーションによる振動が混在している。図 1 で比較してわかるように、信号対雑音比は小さく、一般には判別することは難しい。

よって、振動信号からキャビテーション有無を自動で分類する手法として、CNN (Convolutional Neural Network) [LeCun 98] と LSTM (Long Short Term Memory) [Hochreiter 97] に着目した。本稿では、これらを組み合わせ、教師あり学習により、キャビテーションの特徴量を自動で抽出し分類するタスクを試みた。

2. 1d CNN-LSTM による異常分類方法

2.1 1d CNN

一般に、CNN は画像データ等の多次元データを対象に利用されており、画像の局所的な特徴量を学習できることが知られている。先行研究では、一次元信号をスペクトログラム等の二次元データへ変換し、一次元信号を画像として CNN で分類タスクをする試みも行われている [Lostanlen 16]。しかし、ニューラルネットワークへ信号を入力する度にスペクトログラムへ変換する計算コスト、本来一次元である信号をわざわざ CNN で二次元分析する計算コストが必要となり、計算能力の低い現場機器へ学習済みモデルを搭載し運用する用途には適さないという課題がある。また、一次元信号をスペクトログラムへ変換する過程で位相情報が損なわれるため、分類精度へ影響が出る可能性もある。

そこで、一次元信号を二次元化することなく入力できる 1d CNN に着目した [Collobert 16]。1d CNN の畳み込み層は入力信号と同じく一次元の畳み込みフィルタを用いて時間方向へストライドさせる演算となるが、基本的に通常の CNN と同様に実装できる。1d CNN では、分類対象の信号の特徴的な周波数帯域を強調するような畳み込みフィルタを学習により獲得できる。

また、通常の CNN では次元削減のためにプーリングを用いることが定石であるが、1d CNN の場合はプーリングによるダウンサンプリングでエイリアシングが発生し、高周波成分が損なわれることが懸念されるため、本稿では用いないこととした。

連絡先: 茂木貴弘, アズビル株式会社 技術開発本部,
神奈川県藤沢市川名 1-12-2, t.motegi.zg@azbil.com

2.2 LSTM

CNN は、局所的な周波数帯域での特徴量学習に適した手法である一方、白色雑音等の広帯域な雑音が混在する分類タスクは苦手と考えられる [三村 17]。図 1 に示すように、分類対象の信号の周波数帯域は広帯域で重複しており、流体による振動に比べてキャビテーションによる振動は小さいことから、1d CNN のみにより分類タスクを高精度で実現することは難しいと考えられる。そこで、LSTM に着目した。LSTM は、過去のタイムステップの信号値を長期間保持できる特性があるため、白色雑音等の広帯域な雑音への耐性が期待できる。

2.3 1d CNN-LSTM

上記考え方に基づき、図 2 のニューラルネットワーク(評価モデル I)を設計した。ネットワークの詳細設計は表 1 に示す。




図 2 ニューラルネットワーク構造

表 1 ニューラルネットワークの詳細条件

レイヤーの設定	
入力層	サイズ: (10000, 1)
畳み込み層①	フィルタ: (100, 1)×1 ストライド: 2 バッチ正規化あり
畳み込み層②	同上
畳み込み層③	同上
LSTM 層	ドロップアウト率: 0.1
全結合層	活性化関数: シグモイド
出力層	サイズ: (2, 1)

3. キャビテーション検出実験

3.1 データセット

流量実験設備に組み付けられた調節弁本体外部に振動センサを設置し、流体条件を変化させたときの振動をサンプリング周波数 96 kHz で収録した。実験時に透明流路を用いてキャビテーション有無を目視確認し、ラベル付けした。ラベル付けされた収録データは、信号長 10,000 サンプルで区切り、データセットとした。また信号の振幅のばらつきが学習に影響しないように、データセットの振幅は実効値で正規化した。キャビテーションあり 1,200 セット、キャビテーションなし 1,600 セットからなるデータセットから、検証データとして各 100 セットをランダムに選択し、残りを訓練データとした。

3.2 学習条件

学習を効率的に進めるために、バッチ数 200 のミニバッチ学習を行った。損失関数はソフトマックス交差エントロピーとし、最適化アルゴリズム RMSprop としてネットワークの更新を行った。

評価モデル I との比較として、1d CNN のみの評価モデル II、LSTM のみの評価モデル III についても検証を行った。評価モデル II、III のレイヤーの設定は、表 1 の畳み込み層、LSTM 層と同様とした。

4. 実験結果

学習回数と分類精度の関係を図 3 に示す。評価モデル II は、学習が収束せず、検証データでの最高分類精度は 90% であった。本稿で着目した評価モデル I は、検証データでの最高分類精度は 99.5% で収束しており、極めて高い分類精度が確認された。一方で、評価モデル III は過学習状態となっており、汎用的な特徴量を学習できていない。その理由については今後も引き続き考察が必要であるが、本実験結果より、1d CNN と LSTM を組み合わせることで時系列一次元信号をより高精度で分類できることがわかった。

5. まとめ

本稿では、教師あり学習により時系列一次元信号から特徴量を自動で抽出できる 1d CNN-LSTM を用いて、キャビテーションを検出した事例を報告した。

実験結果より、評価モデル I は 99.5% という極めて高い分類精度を確認できた。よって、本手法が調節弁内部の異常を早期に検知し、予防保全に貢献できる可能性が示された。




図 3 実験結果

参考文献

[azbil 13] アズビル株式会社編: 調節弁のキャビテーションについて, 調節弁用計装資料, ID1-8000-4600, アズビル株式会社 (2013)

[LeCun 98] Y. LeCun: Gradient-based learning applied to document recognition, Proceedings of the IEEE, Vol.86, pp. 2278-2324 (1998)

[Hochreiter 97] S. Hochreiter: Long short-term memory, Neural computation, Vol. 9, pp. 1735-1780 (1997)

[Lostanlen 16] V. Lostanlen and C.-E. Cella: Deep Convolutional Networks on the Pitch Spiral for Musical Instrument Recognition, Proceedings of the ISMIR2016 (2016)

[Collobert 16] R. Collobert, C. Puhresch, and G. Synnaeve: Wav2Letter: an End-to-End ConvNet-based Speech Recognition System, arXiv:1609.03193 (2016)

[三村 17] 三村正人: 深層学習に基づくフロントエンド特徴量強調と頑健な音声認識, 日本音響学会誌, 73 巻 1 号, pp.47-54 (2017)