

マルチモーダルディープラーニングによる一般回転機器の 診断自動化とクラウドオンライン学習システムの構築

Automating Rotational Machinery Diagnostics using Multimodal Deep Learning and Developing Cloud-based Online Model Training Systems

○長野 達朗^{*1 *2}, 澤田 作雄^{*1 *3}

Tatsuro NAGANO^{*1 *2}, Sakuo SAWADA^{*1 *3}

^{*1} プラスインテリジェンス株式会社 Plus Intelligence Corp.

^{*2} 株式会社プライア Prior Inc.

^{*3} 株式会社沢田テクニカルサービス Sawada Technical Service Co., Ltd.

With full cooperation from experienced diagnosticians and engineers, we have developed a system that automates rotational machinery diagnostics using multimodal deep learning method. The multimodal approach has advantage in mimicking diagnosticians' thinking process and works well with current deep learning frameworks. We discuss how the multimodal model is built and how it behaves on robustness testing. We also introduce originally developed wireless acceleration sensor device and cloud-based application which allows us to update model online.

Key Words : Multimodal, Supervised, Deep learning, Rotational machinery, Vibration, Diagnostics

1. 緒 言

我が国製造業において、熟練技能者の後継者不足は喫緊の課題である。製造現場にて長い経験を持つ熟練技能者が蓄積した知識やノウハウは往々にして属人的であり、人材育成や設備の高度化等を通して組織の仕組みとして十分な対策が取られていないのが現状である⁽¹⁾。

我々は、製造現場において該当設備が多く、高度な技術を要する一般回転機器の保全に焦点を当て、近年発展が目まぐるしいディープラーニング、特にマルチモーダル的手法⁽²⁾を用いて診断プロセスのモデル化を行った。ここでは特に、振動診断による設備の常時監視および診断自動化に付き述べる。先ず、振動計測データから設備の運転状態や異常兆候を自動診断するマルチモーダルディープラーニングのアプローチとその検証結果について説明する。次に、振動診断に必要な波形データを一定時間収録して、全波形データを送信する無線センサデバイスに付き述べる。最後にディープラーニングによる学習モデルを実装し、常に更新を続けるクラウド上のオンライン学習サーバに関して今後の開発も含めて触れる。

2. マルチモーダルディープラーニング

2・1 波形性状と設備属性

熟練技能者は設備診断を行う際、過去のメンテナンス記録に目を通し、起こりうる不具合を想定しつつ、現場の音や振動をはじめ、温度や湿度、油のにおいなど五感を働かせて状況把握に臨む。我々は熟練技能者への度重なるヒアリングを通じて、経験と勘で行われていた診断プロセスを言語化し、センサによって測定可能かつ判定に影響する主要項目を選定しアルゴリズムを構築した。

ある任意の時点での設備状態は、加速度センサにより収録される電圧信号の「波形性状」と、「設備属性」により一意に定義されるものとした。波形性状は、加速度の時系列波形 (ACC WAVE)、高速フーリエ変換を適用した加速度波形のスペクトル (ACC SPEC)、時間積分にて得られる速度の時系列波形 (VEL WAVE) およびそのスペクトル (VEL SPEC)、そしてヒルベルト変換を適用した包絡線波形のスペクトル (ENV SPEC) の 5 項目から、また設備属性は、機種、駆動タイプ、軸受、基礎架台の 4 項目から成る。各波形性状はその波形の形状から表 1

のように、また設備属性は表2のように分類される。一方、波形性状と設備属性から定義される設備状態に対して、アンバランスの挙動（歪み）、軸受部摩耗、潤滑不良、嵌め合い不良、偏芯傾向のような設備異常もしくは異常兆候の要因が紐付けられる（全239項目）。

Table 1 Wave and spectrum properties

ACC WAVE	ACC SPEC	VEL WAVE	VEL SPEC	ENV SPEC
Modulation	1k to 6kHz or over	Sinusoidal	fr (sin)	fr
Impact wave	Below 3k, 5k to 7kHz or over	Non-linear	fr, n, n (fr or higher)	fr, n, n (metal)
Non-impact wave	3k to 6kHz or over	Modulation	fr, 2fr, n (2fr, fr)	fc, n, (fr, fb, fo, fi)
	Single frequency and n multiple		fr, 3, 4fr, n	fr, n, fz
	NZ components and n multiple		fz (nz)	fo, n, (fr, fc)
	5k or over		fr, fz	fr, n, fz, n
	2k to 5k or 4k to 8k or over		fc, fr	fr, n, power freq
	Entire range		fr, n, P/(power freq×2)	fr, n, (fb, fo, fi)
	1kHz neighborhood or over		fr, n or higher	fi, n, (fr)
			Low and fz, n	fb, n, (2fb, fi)
			fo (3fr), n	2fr, n

Table 2 Machine properties

Type	Drive	Bearing	Mount
Blower	Motor direct	Plain (metal)	Rigid
Horizontal pump	Belt	Rolling	Flexible Steel
Vertical pump			Flexible Steel (elastic rubber)
Motor			Hanging
Geared system			

2・2 ユニモーダル構造によるモデル化

図1に示すように、ユニモーダル構造では独立した5つの波形性状の分類結果に設備属性を併せることで設備状態を定義している。異常要因の特定は、後述する診断カルテデータベースより予め作成した設備状態と要因の関係マップを用いて行う。

診断プロセスの自動化にあたり、各波形性状の特定は形状パターン認識に有効な畳み込み処理層を持つニューラルネットワークを用いて行う。特徴抽出を担うニューラルネットワーク前段の各層には、畳み込みと併せてプーリング層を設け、活性化関数には Leaky ReLU, そしてドロップアウト, バッチ正規化, L2 正規化を使用した。各ニューロンは He Normal 分布⁽³⁾で初期化し、最適化関数は Adam を用い、誤差逆伝搬法で学習を行った。また、教師データを準備する作業が発生するが、高い予測精度を期待できる教師あり学習を採用した。

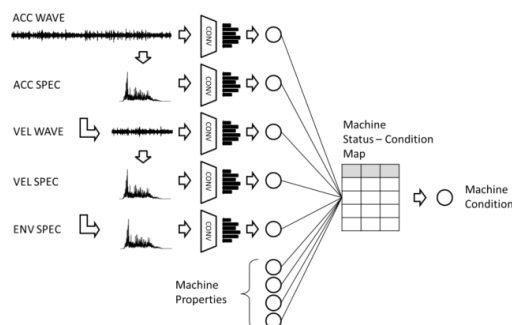


Figure 1 Unimodal structure model

ユニモーダル構造のモデルでは、各波形性状の特定に独立したニューラルネットワークを定義するため、分類クラス数も限られ、ネットワーク規模を小さく抑えることが出来る。またモデルの学習段階において膨大なデータを必要とすることなく計算時間も短い。一方で、モデル全体の予測精度は、5つのニューラルネットワークの中で最も精度の低いモードの影響を受けることになる。要因の特定は、設備状態との関係マップで紐付けられるため、未知の入力があった場合、データベースに記録がない関係性に対しては予測が出来ない。

2・3 マルチモーダル構造によるモデル化

マルチモーダル構造において、入力は5つの波形性状と4つの設備属性を同時に扱い、出力は直接要因を特定する一つのニューラルネットワークを定義する。図2において左側縦一列の5つの台形は畳み込み処理を含むニューラルネットワークの一部であり、特徴抽出部として機能する。設備属性は、各属性の種類を次元とし、大きさが1のユニットベクトル (One-hot vector) として入力する。特徴抽出された波形性状と設備属性を連結し次元ベクトルとしたものを右側の台形で示す全結合層に入力しクラス分類を行う。要因は、全結合層を経て確立分布として出力される。

マルチモーダル構造では、ユニモーダルに比べニューロン数が増え、ネットワーク規模も大きくなり、必要となる学習データ量や計算時間も増加する。一方で、各波形性状に対するクラス分類は行わないため、教師データ作成時のラベル付け作業が大幅に軽減される。未知の入力があった場合、ユニモーダルとは違い、既知の要因クラスの範囲内で予測が可能である。




Figure 2 Multimodal structure model

2・4 診断カルテを用いた学習データ

モデルの学習は、熟練技能者が過去数十年以上に渡り蓄積してきた測定データと診断カルテを用いた。製造業において、一般には設備に異常が出る前にメンテナンスが行われるため、異常データが正常のものに比べて圧倒的に少ない。これによりデータセットは不均衡となり、教師あり学習において適切なモデルの作成が難しくなる。そこで、正常データのみで学習が可能な異常検知のアプローチ⁽⁴⁾が考えられるが、異常要因の特定やその兆候を捉えることは難しい。その点において熟練技能者は、定期メンテナンス時のみならず、異常発生時に現場対応をすることが業務の一環であるため、異常データにアクセスしやすい。また都度、報告書として診断カルテを作成するため、学習に必要な教師データと併せてラベル付け作業も同時に行われていることになる。

もちろん熟練技能者所有のデータであっても、異常データを含めた全てのクラス間でデータ均衡が取れている訳ではない。診断の際は、サンプリングレートが 25kHz 以上、測定時間が 10 秒間以上の加速度の波形データを記録しているため、適切に調整された「窓」をスライドさせて部分データを切り出してデータ拡張を行うと共に、併せて SMOTE⁽⁵⁾などのオーバーサンプリングを学習時にメモリ上で行うことで対処する。通常、マルチモーダルのデータセットは、各モード間には何らかの関連があるため、独立してオーバーサンプリングを適用することは出来ない。しかし、ここで扱うモードは全て加速度波形から導出された計算データであるため、ACC WAVE のみにオーバーサンプリングを適用し、残りのモードは拡張後の ACC WAVE から導出することで対応した。

2・5 学習モデルの精度

ユニモーダルとマルチモーダルにおけるモデルの学習結果を表3に示す。教師データは、オーバーサンプリング適用前で合計約10万点のデータセットを用意し、その内72%を学習用、8%を検証用、20%をテスト用とした。ユニモーダルでは、機種および波形形状毎にデータを分けて独立したモデルを作成した。マルチモーダルでは、機種も入力変数の一つであるため、本来データを分けて扱う必要はないのだが、現時点において該当機種全ての教師データの整理が完了していないため、ここでは送風機に限定して比較する。

ユニモーダルのACC WAVEとVEL WAVEは、分類クラス数が少なく波形形状も各クラスで特徴的であるため分類精度は高い。ACC SPECとVEL SPECの精度は、時系列波形から一定サンプルを切り出すスライド窓サイズに影響を受ける。これは熟練者が、設備の運転状態を周波数スペクトル波形に見出す目的で、十分な時間を掛けて測定データを収録することと一致する。ENV SPECにおいては、Macro-F1の値が低い。これは、特に図3の混同行列の橙色枠箇所に見られるように、クラス0の適合率(68.55%)の低さによるものである。これは、周波数スペクトル形状に見るメタル軸受(Plain)特有の現象が、転がり軸受(Rolling)において別の現象の波形に酷似していることが原因と考えられる。実際に軸受の種類毎に教師データを分け、それぞれ学習モデルを作成すると、このような精度低下はみられなかった。マルチモーダルにおいては、今後更にパラメータチューニングを進めるが、ENV SPECのような問題は見られない。これは入力変数が設備属性である軸受値を含んでおり、特徴空間に新たな次元が追加され、異なる軸受のデータが混ざることなく空間的に離れて分布しているため、分類超平面が定義しやすくなったものと考えられる。

マルチモーダルネットワークの出力である異常要因の分類クラス数はユニモーダルのそれと比べて多いため、教師データ量とクラス間バランスを見て、診断に必要な情報を維持しつつ類似クラスの統合を検討する。

Table 3 Blower model accuracy

Model	Unimodal		Multimodal	
	Macro-F1 (%)	Accuracy (%)	Macro-F1 (%)	Accuracy (%)
ACC WAVE	99.61	99.89	96.54	98.27
ACC SPEC	99.47	99.69		
VEL WAVE	100.00	100.00		
VEL SPEC	99.74	99.49		
ENV SPEC	94.02	96.29		

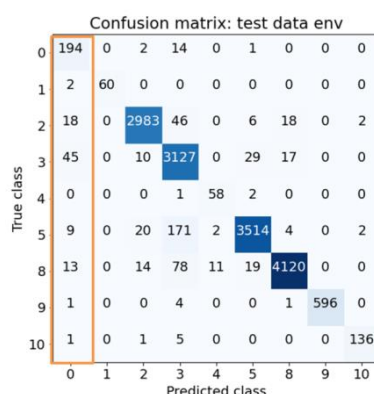


Figure 3 Confusion Matrix of ENV SPEC

2・6 マルチモーダルモデルのロバスト性

ユニモーダルとマルチモーダルのネットワーク構造の違いによるモデルのロバスト性を検証するにあたり、入力データに外乱を加えながら異常要因の予測精度への影響をみる。外乱は、複数あるモードの一つに模擬的にノ

イズを加える。例えば、VEL SPEC 波形に対して、ランダムに選択したデータの値を一定の割合で 0 に置き換える。置換する割合を 0 から 100% まで徐々に変化させて、予測精度への影響の違いを比較する。ここでは過去に実施した検証結果⁵⁾を引用して説明する。

図 4 は、3 つのモードを入力に持つモデルで、横軸に外乱ノイズ割合、縦軸に精度 (Macro F1 値) をプロットした。どのグラフにおいても外乱割合が増加するに従い精度低下が見られるが、ユニモーダルと比べて何れもマルチモーダルの方が影響は少ない。また外乱を加えるモードによって精度低下の様子が異なる。例えば、図 4 の中央のグラフは他の 2 つと違い、ノイズを 50% 含めるまでマルチモーダルへの影響がほとんど無いことから、該当モードがモデル分類への貢献度が相対的に低い可能性が考えられる。これにより、マルチモーダル構成を検討する際、どのモードを優先すべきか判断の助けになる。




Figure 4 Robustness of multimodal model

3. 無線センサデバイス

設備の常時診断を実現するには、適切な入力、つまり主要な稼働状態情報を漏らすことなく電気信号に変換するセンサが必要である。設備の新旧を問わず容易に取り付けが可能な、磁石固定の小型無線センサ⁶⁾を検討したが、要求仕様を満たすものが存在しないため独自に開発した。図 5 は、最大サンプリングレート 30kHz、サンプル時間 10.4 秒、分解能 24 ビットの MEMS センサを使用したクレジットカードサイズの初号機である。今後、複数の通信プロトコル対応を想定して、データ収録用のマイコンと通信用のマイコンを分けて設計した。まずは 1 チャネル収録の Wi-Fi 接続仕様としたが、次期モデルは更なる小型化を図り、SIM によるクラウド直接接続を予定している。




Figure 5 Wireless Acceleration Sensor Device

4. クラウドベースアプリケーション

無線センサで収録される生波形データは、クラウド上のデータベースに蓄積される。クラウドサーバでは、学習済みモデルによる推論エンジンが常時監視しており、アップロードされるデータから異常要因もしくはその兆候を予測する。異常を検知した際は、メールサーバからユーザにアラートが送信される。ブラウザベースのアプリケーションとして実装しているため、タブレット端末等ユーザ所有のデバイスから閲覧が可能である (図 6)。

クラウドベースのアプリケーションとすることで、遠隔監視や常時診断が出来るようになるだけでなく、接続された様々な設備の波形データを集められるようになり、常に最新の学習モデルを提供するオンライン学習を実装した自動診断プラットフォームの実現が可能になると考え開発を進めている。

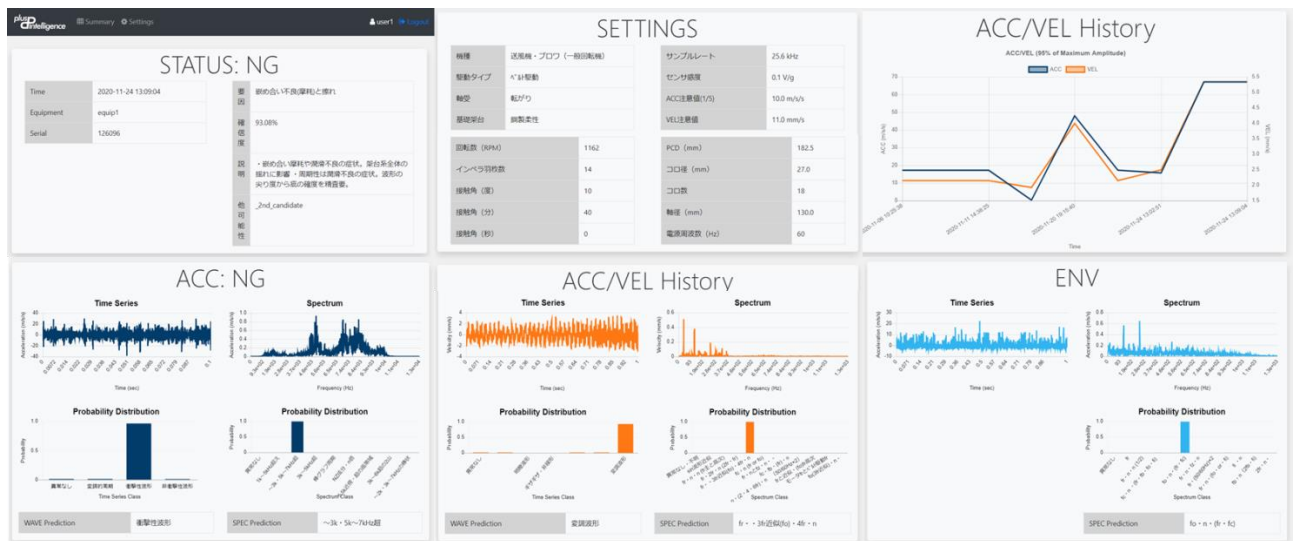


Figure 6 Cloud Application User Interface

5. 結 語

今回の開発において、最初に直面したのが熟練技能者がとのコミュニケーションの難しさである。専門用語の理解もさることながら、感覚や無意識的に進めているプロセスを具体的に表現して理解する、いわゆる暗黙知を形式知にする作業であった。言語化したものを基にプログラムを組み、計算結果と実際の判断の擦り合わせを繰り返し行うことでようやく基礎の構築は出来たが、このサイクルは機能拡張の度に今後も継続が必要と考えている。これに加えて、多岐に渡る異常現象を含む測定データや診断カルテ、またマルチモーダルディープラーニングの手法無しでは、今回の結果は得られていない。

ここでは触れていないが、モデルの実用性を確認すべく、実機コンポーネントを使用した模擬設備での実験にて本アプローチの有用性は確認しているが、今後は更に、既に開始している製造現場での実証実験を進め、オンライン学習の運用方法等を確立した上で、クラウドサービスとして早期にリリースする予定である。

文 献

- (1) 経済産業省 製造産業局，“製造業における人手不足の現状および外国人材の活用について”，製造業における外国人材受け入れに向けた説明会資料，(2018)，pp. 3-5.
- (2) T. Baltrušaitis, C. Ahuja and L. Morency, “Multimodal Machine Learning: A Survey and Taxonomy”, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol 41, No. 2 (2019), pp. 423–443.
- (3) He, K., Zhang, X., Ren, S., and Sun, J., “Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification”, *2015 IEEE International Conference on Computer Vision (ICCV)*, (2015), pp. 1026-1034.
- (4) Pittino, F., Puggl, M., Moldaschl, T., and Hirschl, C., “Automatic Anomaly Detection on In-Production Manufacturing Machines Using Statistical Learning Methods”, *Sensors*, Vol. 20, No. 8 (2020), pp. 2344-2361.
- (5) 長野達朗, 澤田作雄, “実機振動診断カルテに基づいたマルチモーダル・ディープラーニングによる中・小型回転機械の診断効率化”, 日本保全学会 第 16 回学術講演会要旨集 (2019), pp. 483-489
- (6) <https://www.yokogawa.co.jp/solutions/solutions/iiot/maintenance/sushi-sensor-j/>