

修士論文

機械学習を用いたモータ製造ラインにおける不良品検知システムの構築

平成 31 年度

三重大学大学院 工学研究科
博士前期課程 物理工学専攻

山田 貴也

目 次

第 1 章	序論	4
1.1	研究背景	4
1.2	AI 導入の一般的な問題	5
1.3	本研究の目的	6
1.4	本論文の構成と概略	8
第 2 章	研究対象のモータの特性	10
2.1	モータの仕様	10
2.2	モータに含まれる主な振動成分	11
2.3	モータ不良の原因	12
第 3 章	入力データ作成と前処理	15
3.1	入力データ作成手順	15
3.1.1	オクターブバンド分析	15
3.1.2	主成分分析	16
3.1.3	統計的検定による入力データの次元圧縮	19
3.2	未知のデータに対する予測の注意点	19
第 4 章	線形判別分析とサポートベクトルマシン	22
4.1	フィッシャーの線形判別分析	22
4.2	サポートベクトルマシン	24
4.3	異常検知におけるハイパーパラメータの取り扱い	25
第 5 章	振動データ収集の概要	27
5.1	1 回目のデータ収集	27

目次	3
5.1.1 現行の振動測定システム	27
5.1.2 データ収集システム	28
5.1.3 ソフトウェア概要	30
5.1.4 問題点	31
5.2 2度目のデータ収集	33
第 6 章 AI 分類結果	37
6.1 結果の検証方法	37
6.2 1度目のデータ収集によって得られたデータに対する分類結果	37
6.3 2回目のデータ収集によって得られたデータに対する分類結果	40
第 7 章 結びと自動検査システムの実現	44
7.1 まとめ	44
7.2 類似研究との比較	45
7.3 今後の課題と自動検査システムの実現	45
付 録 A 不良原因の検出方法	48
A.1 擦れ振動検知の手法	48
A.2 結果と擦れ振動検知の課題	49

第1章 序論

1.1 研究背景

本研究に係る共同研究先の某企業では、生産されるモータ全数に対して既定の品質を満たしているかを判断するため出荷前の最終工程で次の2つの検査を行っている。

1. モータ作動時の振動レベルの測定検査
2. モータ作動音を検査員が聴く官能検査

しかし、これらの検査方法には次に述べるように様々な問題がある。

一つ目に良品と不良品の間に客観的な判別基準がないことが挙げられる。振動レベルの電圧値は数値として出力されるが、振動レベルだけで良品と不良品を分類することは極めて困難である。その理由として、不良が原因となる振動は必ずしも大きいとは限らないためだと考えられる。不良品には大きく2種類の振動成分が含まれていて、一つは不良が原因で発生する振動である。もう一つは品質に依らずに良品でも発生する振動で、本論文ではこれをモータの固有振動と呼称する。もしモータ固有振動よりも不良が原因となる振動が小さい場合、不良原因の振動は固有振動に隠れてしまう。実際、モータの固有振動はエネルギーの観点で支配的であるため、非常に大きな不良音がしない限り振動レベルでの検知は難しい。そのため分類で重要となる要素は振動レベルよりも振動のスペクトルである。現行の検査工程の中でスペクトル（音色）をテストできるのは2.の聴覚による官能検査だけであり、これは客観的な検査とは言い難い。

官能検査は導入が非常に簡単であるという大きな利点がある。あらかじめ用意しておいた不良品の作動音をベンチマークとして検査員が学習することにより官能検査が可能となるため、導入に関してコストはほとんどかからない。しかし反面、判断が検査員間で異なったり、検査員の疲労・体調・心理状態の影響を受けたりする難点もある。また導入コストはかからないが継続的に人的コストが生じる。

二つ目に作業効率が悪い問題がある。今回の研究対象とするモータは1日に平均1600台生産されているが、1日に出る不良品は多くとも3個程度であり、不良率は0.1%程度である。しかし、現状1日に生産されるモータ全てに対して振動測定と官能検査を行っている。1つのモータに対して2種の検査を行うために工数が多く効率がいいとは言えない。

三つ目に検査員の負担が大きい問題がある。今回の研究対象とするモータの重量は約1.4 kgである。官能検査のため一日にこのモータ1600台を耳元まで持ち上げる必要があるが、これには腱鞘炎などのリスクがあり身体的負担が大きい。また閉鎖空間で一日中モータ作動音を聴き続ける、不良率0.1 %程度の中から正しく不良品を聴き分けなくてはならないという精神的、心理的な負担も大きい。

これらの問題からこの企業では検査作業の自動化を強く望んでいる。

1.2 AI 導入の一般的な問題

上述の3つの問題は客観的に自動検査するシステムを構築することで解決可能と考えられる。客観性をいかに持たせるかが問題となるが、多くの場合、閾値で分離する方法と人工知能 (Artificial Intelligence, AI) によるアプローチが採用されている。しかしモータの作動音 (振動) というのは様々な要因の振動が複雑に混ざり合って発生している。そのため、閾値によって単純に分離することは不可能であると考えられる。

一方でAIは、クラスタリング [1]、サポートベクトルマシン [2]、ディープニューラルネットワーク [3] などが異常検知によく使われており、類似研究 [4] でも高い成果をあげているため、本研究でもAIを採用した。ただし、本研究ではモータの作動音の官能検査をAIに置き換えるのではなく前述の検査工程1で測定している振動をもとにして行うことにした。これは検査ラインの暗騒音が大きく、音信号では十分なS/N比を確保することが難しいという点や、ノイズ除去が難しいという点が理由として挙げられる。一方で振動は測定治具を適切に製作したり、防振台を用意したりするなどの対策で音よりもノイズコントロールが容易である。

AIを構築するためには大量のデータ収集を行い、精度の良いAIを構築するとよい。しかしながら、これがAIの構築と導入にあたって一般的な問題となっており、製品の変化や新製品の製造において、官能検査よりも柔軟に対応できない。仮に対象モータの品質判別をするAIを構築できたとしてもそのAIの別製品への流用は当然できない。またあるモータ専用学習したAIは、モー

タ自体の機構（巻き線構造やパーツの変更など）が変わると、振動スペクトルが変化するため使えなくなる可能性が高い。共同研究企業では今回対象としているモータ以外にも多種のモータを生産しており、それらすべてのモータに対しても官能検査を行っている。検査対象や AI のモデルに依るが一般的に AI の学習データには数千～数十万のデータが必要であり、生産される全種類のモータに AI を導入するには製品種類ごとに学習用データを集めなくてはならない。データ収集のための人件費や時間、専門知識を持った人が要求されるため多品種生産企業の AI 導入はハードルが高い。また検査ラインを止めてデータ収集するとなるとその期間全く利益を生み出すことはできないため導入コストがかかるだけでなく導入準備期間に利益損失が発生するといった問題もある。

一方で振動を使った異常検知の類似事例として電車の車両機器の診断 [4] や自動車の異常振動検知 [5] があるが、本研究と大きく異なる点の一つの機器に対して繰り返し異常を検知するという部分である。大型機器では振動の様態が変わる機器の変更はまれなため AI を一度構築することで長く使い続けることが可能である。また車両機器診断においては多くの種類の AI を作る必要はない。

1.3 本研究の目的

上述した問題から、本論文で扱う検査の自動化においての要求事項は以下のように整理される。

要求 1：客観的な検査であること

要求 2：検査員の負担が小さいこと

要求 3：作業工数が少ないこと

要求 4：低コスト、短スパンで製品毎に AI を構築する必要があること

そして上記の要求事項を達成するために本研究の目的を次の 3 つと定めた。

目的 1：良品と不良品を高精度で分類する入力次元数の少ない AI の構築

目的 2：検査員の負担を増やさずに既存の官能検査システムと共存しながら AI を構築するシステムの提案

目的 3：目的 2 のシステムのプロトタイプ構築、および導入

目的1に対しては、線形クラス分類のアルゴリズムである線形判別分析と非線形カーネルを使ったサポートベクトルマシンを用いて高精度のAI構築を試みた。目標値はこれまでの企業の実績から、検査員が良品と判定したモータをAIが不良品と判定する誤分類を10%以下かつ検査員が不良品と判定したモータをAIが良品と判定する誤分類を1%以下にすることとした。AIの入力には振動のオクターブスペクトルにフィルタ処理、主成分分析、統計的検定を施し次元圧縮したデータを採用した。これは入力次元数を圧縮することで、AI構築の際の計算資源や収集サンプル数の削減が可能になり、AIの構築を低コスト、短スパンで実現できることが可能になると考えたからである。SVMの計算コストはカーネル関数の選択などによって変わるため、厳密に見積もるのは難しいがOlivier Chapelle[7]によるとオーダーは $O(n^2 d^{1 \sim 2})$ が一つの目安であるという。ここで n はデータサンプル数、 d は入力次元数である。また入力次元数が大きいと過剰に学習データにフィッティングしてしまい汎化性を損なう危険、いわゆる次元の呪い (Curse of dimensionality)[8][9]を回避するためにも入力次元の削減は有効であると考えられる。

目的2に対しては、既存の検査システムを流用し、データ収集やAI構築を自動化した専用プログラムをPCに実装することで専門知識なしでデータ収集と学習を一つのシステム上で一貫して行うシステムとして提案した。これにより要求4をクリアできると考えた。目標とするシステム像は、検査員が普段の検査に並行してデータ収集を行い、データがある程度集まったタイミングでPC上のアプリケーションを介して学習をさせる、つまり検査員が日々AIに分類規則を学習させるような協調作業を可能にするものである。そしてAIが検査員と同レベルで不良品の検知を行えるようになったら、検査員の代わりにロボットアームを導入することでAIの導入が完了する。一般的なAI構築であればデータの収集の後に、データ解析とAI構築を専門家が行い、AIを導入する。しかし、このシステムが実現できればデータ収集とAI構築を専門知識のない人がすぐに行えるため、低コスト、短スパンでAIの導入が可能となる。システムの構成などの詳細は第5章で詳しく述べる。

目的3に対しては、実際に目的2のシステムのプロトタイプを構築し、実際の検査ラインに導入してシステムの有効性を確認することを目指した。

モータの異常検知に関する研究として白井らの研究[6]がある。サポートベクトルマシンでモータの常検知をするという大筋は同じであるが、いくつか異なる点がある。まず大きく異なるのがデータの指標およびデータ収集の環境である。白井は音を指標とし、またデータは無響室で録音

している。一方本研究では振動を指標とし、データは製造現場で取得する。そのため本研究はより導入に近い環境である。両研究の相違点は第7章で詳しく述べる。

1.4 本論文の構成と概略

以下に本論文の構成及び概略を示す。

第2章では、研究対象とするモータの概要を説明する。モータの仕様やモータの品質に依らず含まれている固有の振動成分、異常発生メカニズムを説明する。固有振動成分の説明は第3章のデータ生成法と関係しており異常発生メカニズムは付録に記載されている異常検出のアプローチになっている。

第3章では、目的1に関係するAIの学習データ生成方法や主成分分析 (Principal Components Analysis, PCA)、統計的検定などを用いた入力データの次元圧縮の方法を説明する。

第4章では、目的1に関係するAIのアルゴリズムに関して述べる。フィッシャーの線形判別分析 (Fisher's Linear Discriminant Analysis, LDA)、サポートベクトルマシン (Support Vector Machine, SVM) を説明する。また本研究事例はパターン認識の中でも異常検知に分類される。異常検知特有の問題であるデータ群のばらつきに対応するためのハイパーパラメータの設定方法も説明する。

第5章では、目的2、3に関係することを述べる。構築したシステムのプロトタイプを稼働させて行ったデータ収集について説明する。データ収集は2回行っており、1回目のデータ収集では振動の測定方法に問題が見つかった。そこで2回目のデータ収集では、治具を改良し測定方法を変えることで問題解決を試みた。

第6章では、目的1に関係することを述べる。1回目と2回目のデータ収集で得られたそれぞれのデータについてAIの分類精度を確認する。

第7章では、目的3に関することを述べる。今後の展望を説明し、AIを活用した自動判別シス

テムの実用化を見据えた上での課題を説明する。本研究では試作したプロトタイプを短期間稼働させたただけだが実際に本格運用をするための課題も見つかった。この章では将来的に実用化するための課題とシステムの運用法について述べる。また、類似研究 [6] との違いを説明する。

付録では、不良品の原因を検出する信号解析方法を説明する。目的の中には含まれていないが、将来的には良品と不良品を分類するだけでなく、不良品の中でも何が原因となって生じている不良なのかを分類する必要があると考えた。そこでこの章では異常原因検知の手法を紹介する。

第2章 研究対象のモータの特性

本章では研究対象とするモータの仕様と主な振動成分、不良の原因について述べる。

2.1 モータの仕様

本研究で対象とするモータの仕様を Table. 2.1 に、実際の写真を Fig. 2.1、寸法を Fig. 2.2 示す。モータは主にレンジフードに使われる汎用モータである。

Table. 2.1: 研究対象とするモータの仕様

モータの種類	コンデンサラン型単相モータ
重量	1.39 kg
電源	100 V 60 Hz
同期速度	1800 rpm
極数	4 極
ステータ側スロット数	24
ロータ側スロット数	30



Fig. 2.1: 研究対象とするモータの写真




Fig. 2.2: モータの概略図と寸法

2.2 モータに含まれる主な振動成分

今回の研究対象とするモータには発生原因の異なる2つの振動成分が振動レベルの観点で支配的であることが分かっている。あるモータの軸方向の振動の時間波形及びスペクトルを Fig. 2.3 に示す。

1つ目は電源周波数に依存する振動成分で、120 Hz 及びその整数倍に卓越周波数が確認された(図中▼)。横塚 [11] によれば、これは電源周波数の2倍であることから $2f$ 加振力、あるいはトルク脈動と呼ばれる電磁振動である。 $2f$ 加振力はモータのステータに使われる鉄心が磁化されると伸縮するために発生する振動であり、主に電源である交流電圧の周波数 f の2倍またはその高調波で振動し、音が発生する。

2つ目は回転磁界に依存する振動成分で、1.1 kHz、2.8 kHz 付近に卓越周波数が確認された(図




Fig. 2.3: モータの振動時間波形とそのスペクトル

中▽)。この振動はロータのスロット (溝) による磁束密度の周期的な変化により引き起こされる振動である [12]。野呂 [13] によれば、これは電磁加振力と呼ばれ、卓越周波数は (モータの回転数 [rps]) \times (ロータ側スロット数) の整数倍、あるいはそれらの周波数 \pm (電源周波数) $\times 2$ または $\times 4$ の成分である。

これら 2 つの振動成分は良品、不良品関わらず存在するため AI の入力データとしてはふさわしくない。そのため、学習データ作成時にフィルタ処理を施すなどをしてこれらを取り除く方が良い。

2.3 モータ不良の原因

モータは最終的に良品と不良品に仕分けられるが、さらにその後検査員は作動音から不良品を原因別に仕分ける。モータの不良の原因は大きく次の 2 つに大別される。

1. ベアリングに関する不良

2. ロータとステータの間に異物が挟まることにより生じる不良（ここでは擦れ振動と呼称）




Fig. 2.4: 擦れ振動の発生原理

1つ目のベアリングに関する不良は、ベアリングの破損（割れ、欠け）による異常振動が原因である。

2つ目の不良である擦れ振動の発生メカニズムを Fig. 2.4 に示す。これはロータ加工時に生じたバリや金属くずなどの除去しきれなかった異物がロータに擦れることにより生じる異常振動が原

因である。

不良の原因を特定することで生産ライン上のどこで異常が発生しているかを突き止めることができる。モータの不良はこの2つに大別されるため、どちらかの異常を検知することができれば完全に不良原因を特定できることになる。本研究で対象としているモータのベアリング径は小さく、振動波形からベアリング異常を特定するのは困難である。そのため後述するが、本論文ではベアリングの異常ではなく、擦れ振動の検出を線形予測フィルタなどの信号処理技術によって試みた。

第3章 入力データ作成と前処理

本章では AI の入力データ作成手順並びに次元削減の方法について説明する。

3.1 入力データ作成手順

入力データは大きく次の3つの操作により作り出される。

1. 振動データのオクターブスペクトルの算出
2. 主成分分析による直交化
3. t 検定による次元圧縮

以下に各手順の詳細を述べる。

3.1.1 オクターブバンド分析

2.2 で述べた通り、良品、不良品に関わらず存在する振動成分があることが分かっている。判別に関係のないデータを入力として学習させると、かえって分類器の性能低下を招く恐れがある。そこで入力データをつくる処理を施す前にその様な振動成分を取り除く。

良品、不良品関わらず存在する振動成分には2種類あった。1つは120Hzの整数倍に卓越周波数をもつ $2f$ 加振力であり、ピークの位置は容易に特定できる。その為 $2f$ 加振力の6次成分までを、阻止帯域幅6 Hz、2次×6の総計12次のノッチフィルタにより取り除く。2つ目は(モータの回転数[rps])×(ロータ側のスロット数)の整数倍またはその周波数の±(電源周波数)×2もしくは×4倍に卓越周波数をもつ電磁加振力であった。この卓越周波数は式として求められるが、モータの回転数の推定が必要であったり、サンプルモータ毎にピーク位置のばらつきが大きいため除去は難しい。またシステムとして実装する際にリアルタイム性を確保するため、計算コストはなるべく抑えたいという意図もある。そのため電磁加振力を直接除去せず、後述する入力データの次元削減を行うことで分類に無効なデータを入力データから取り除くことを試みる。

具体的な入力データ作成手順を Fig. 3.1 に示して説明する。まず振動センサから収集した振動データ (Fig. 3.1(a)) について $2f$ 加振力をノッチフィルタで取り除いた 1 s の振動時間波形 (Fig. 3.1(b)) をスペクトル波形 (Fig. 3.1(c)) に変換する。後述するが、1 回目のデータ収集ではモータの上下に 1 軸のセンサがあるので、2 つの振動波形について解析する。2 回目のデータ収集では 3 軸の加速度センサを使っているので方向別に 3 つの振動波形を解析することになる。その後スペクトルに対して 1/12 オクターブバンド分析を行う (Fig. 3.1(d))。バンドの中心周波数の下限は 18 Hz、上限はサンプリングレートの半分とした。中心周波数 f_m は次の式で求められる。

$$f_m = (2^{(2x+1)/24})f_r \quad (3.1)$$

ここで f_r は基準周波数であり 1000 Hz、 x は正または負の任意の整数である。今回は x に -100 から 100 の整数を与え、算出される 201 個の f_m を 18 Hz からサンプリングレートの半分の範囲で抽出した。1.1 で述べたように、検査員が作動音に異音がないかを検査することでモータの異常検知を行っている。人間が異音を検知するように AI が異常振動を検知することを目指す事例では、振動や音の音色をデータ化する方法として、人間の聴覚の分解能と同じといわれる 1/3 オクターブバンド分析がよく用いられている。しかし、1/12 オクターブバンド分析によって成果を挙げている類似研究 [4] にならって本研究でも 1/12 オクターブバンド分析を用いた。こうして得られるオクターブスペクトルを AI の入力データとして用いる。この時に算出されるスペクトルデータには電磁加振力の成分が含まれているので、そのまま学習に用いると分類器の性能が低下する可能性がある。そのために分類に有効なデータを絞り込むため次項で述べる主成分分析と t 検定による次元圧縮を行う。

3.1.2 主成分分析

主成分分析 (Principal Components Analysis, PCA) とはデータの分散を最大化する方向の成分 (主成分係数) を抽出することで、データの分散を少ない次元で表現する手法である。多次元空間のデータの分散が大きくなるように直交座標を回転させ、一番大きくなる座標軸を第 1 主成分といい、主成分スコアの変換に使われる係数を第 1 主成分係数という。本論文では主成分の回転方法として直交回転を採用している。第 j 主成分係数と元の変数 (オクターブバンド毎のパワー) の積和を第 j 主成分スコアという。そして 2 番目に分散が最大化し、かつ第 1 主成分に直交する軸が

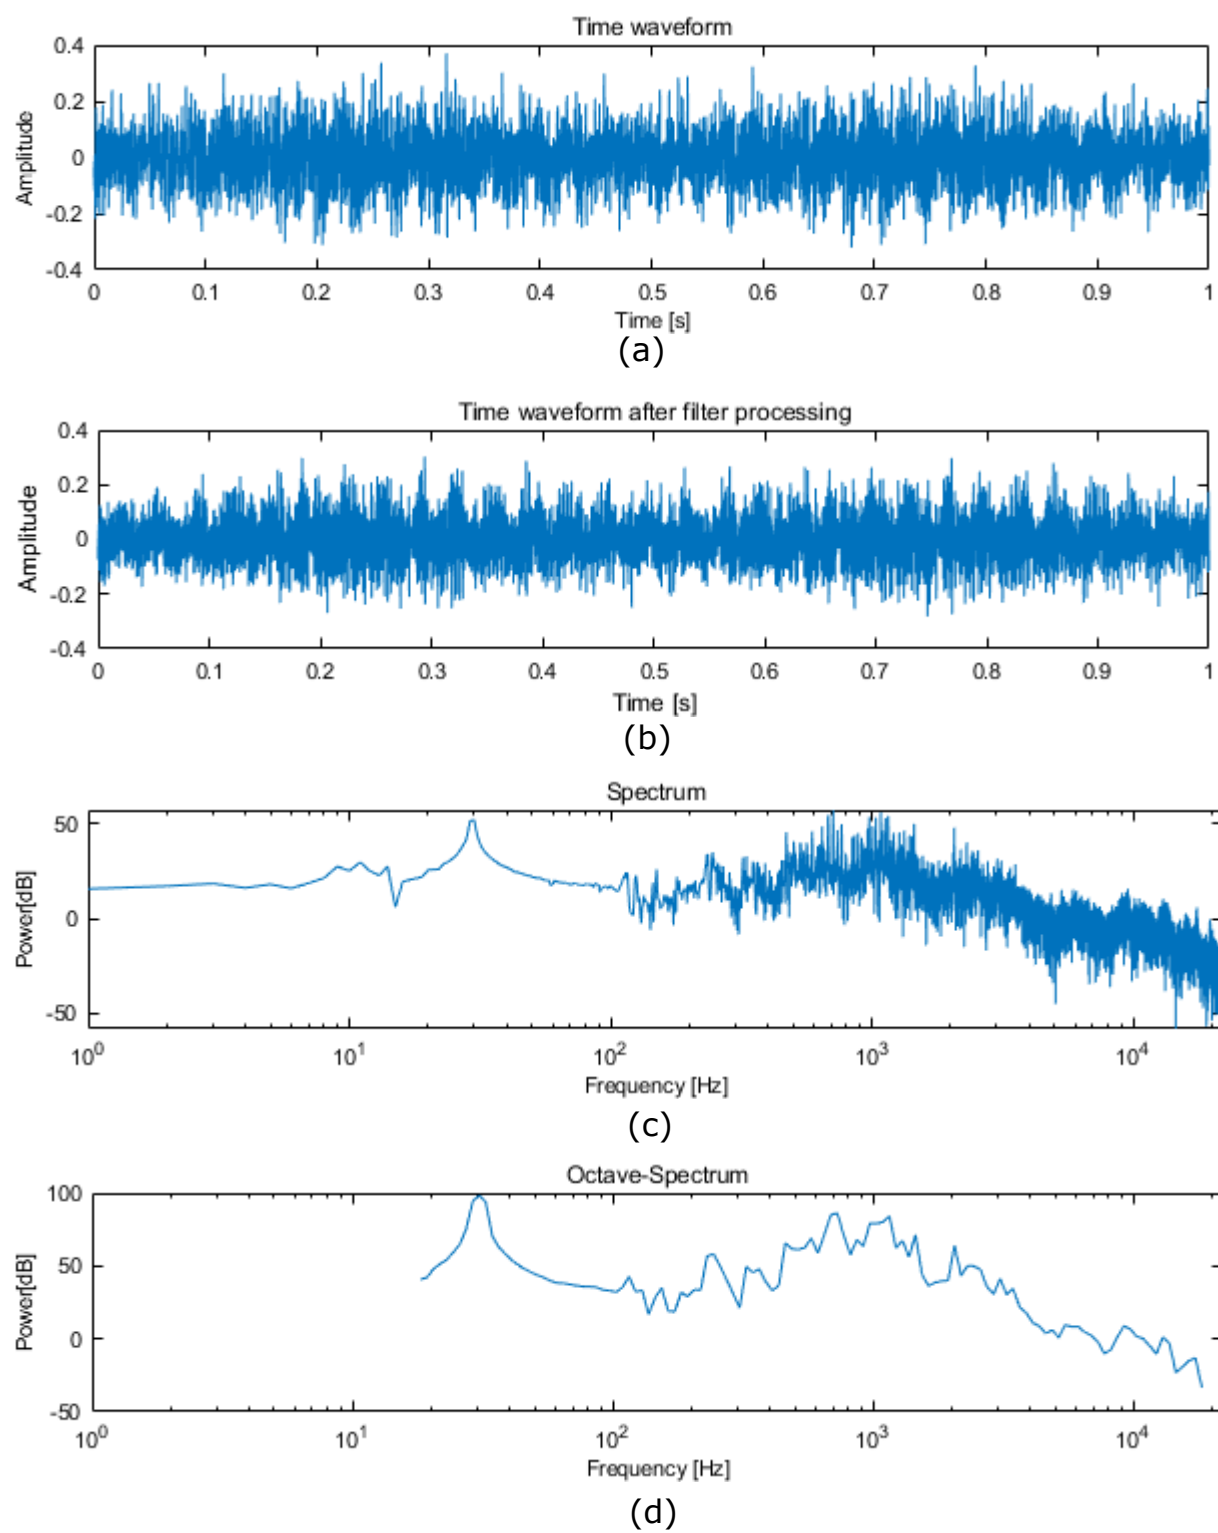


Fig. 3.1: Procedure of creating input elements

第2主成分となり以下データの次元数だけ続く。またPCAの際、抽出した主成分の情報量の大きさはその主成分の分散の大きさに依存している。しかし、主成分の分散は元の変数の分散の大きさに依存しているため、今回のモータのオクターブスペクトルで言えば、オクターブバンド毎の重みが異なる。バンド毎に等しい重みでPCAを行うため、データにはあらかじめ標準化(白色化)を行う[4]。データの標準化とはデータの各成分について、データ成分の平均値を引いてその標準偏差で割る操作である。これにより、データ成分は平均が0、分散は1となりオクターブバンド毎の重みは等しくなる。標準化はデータの分布を原点を中心とする多次元球に近づけるため、変動の大きい成分が支配的になることを防ぐ。PCAによる次元削減により学習に必要なメモリ、計算時間を削減できるが、主成分数をいくつまで採用するかによって分類器の性能は変化する。一般的には学習に用いる主成分数を予め固定することや、もとの変数の分散に対する主成分の累積説明分散率(累積寄与率)の数値を決めておき、それを満たすだけの主成分数を採用することが多い。しかしPCAはあくまでデータの分散が大きくなる主成分を抽出するだけであり、上位の主成分が良品と不良品の分類に有効であるかどうかは別問題である。2次元データを1次元で表現することを例にとり、上位の主成分が分類に有効に作用しない例をFig.3.2に示す。ある周波数バンド2つのオクターブスペクトルで描いた散布図が左図で、PCAを施したものが右図である。右図から第1主成分よりも第2主成分が分類に有効に作用することが分かる。




Fig. 3.2: 第1主成分が分類に有効に作用しない例

PCAの解釈は情報量を分散の大きさで考える。つまり第1主成分は第2主成分よりデータの分散が大きいため、PCAの解釈としては大きな情報量を持つことになるが、第1主成分の方が第2主成分よりも分類に有効に作用するかどうかはわからない。そこで次に述べる統計的検定により

どの主成分が分類に有効か調べ、学習に用いる主成分のインデックスを抽出する。

主成分分析には MATLAB の `pca` という関数を用いた。引数は全て規定値である。

3.1.3 統計的検定による入力データの次元圧縮

各主成分スコアが良品と不良品の分類に使えるかどうかを調べるために統計的検定の一つである t 検定を用いることにした。 t 検定とは2群の母集団平均に差があるかどうかを検定する。良品と不良品の各母集団の主成分スコアについて t 検定を行い、帰無仮説を良品と不良品のそれぞれの母平均に差がないとする。対立仮説を良品と不良品のそれぞれの母平均に差がないとはいえないとする。母集団は良品と不良品のモータであるので対応のない t 検定であり、各母集団の各主成分スコアの分布は正規分布を仮定する。 t 検定による主成分の抽出手順を以下に述べる。

1. 各主成分スコアに対して F 検定を行う。帰無仮説を「母分散に差はない」、対立仮説を「母分散に差はないとはいえない」とする。
2. F 検定の結果、有意水準 1% で帰無仮説を棄却したスコアと帰無仮説を棄却しなかったスコアに分ける
3. F 検定の対立仮説を採択したスコアについては Welch の t 検定、帰無仮説を採択したスコアには Student の t 検定を行う
4. t 検定の結果有意水準 1% で帰無仮説を棄却した主成分スコアを学習に採用する

PCA と t 検定の一連の手順を Fig.3.3 に示す。

この手順により学習に用いる主成分スコアを抽出することにした。

3.2 未知のデータに対する予測の注意点

学習データに対して上述した前処理を行うため、注意点として未知のデータに対して予測を行う際には学習の際に使用したパラメータを記憶しておく必要があり、未知のデータに対しても学習データに行った同様の操作を施さなければならない。具体的に次に示すパラメータを記憶しておく必要がある。

1. オクターブスペクトルの標準化の際に用いた、学習データの各変数の平均ベクトルと標準偏差ベクトル
2. 主成分スコアを算出するための元の変数（オクターブスペクトル）に対する主成分係数
3. t 検定によって抽出した、予測に用いる主成分スコアのインデックス

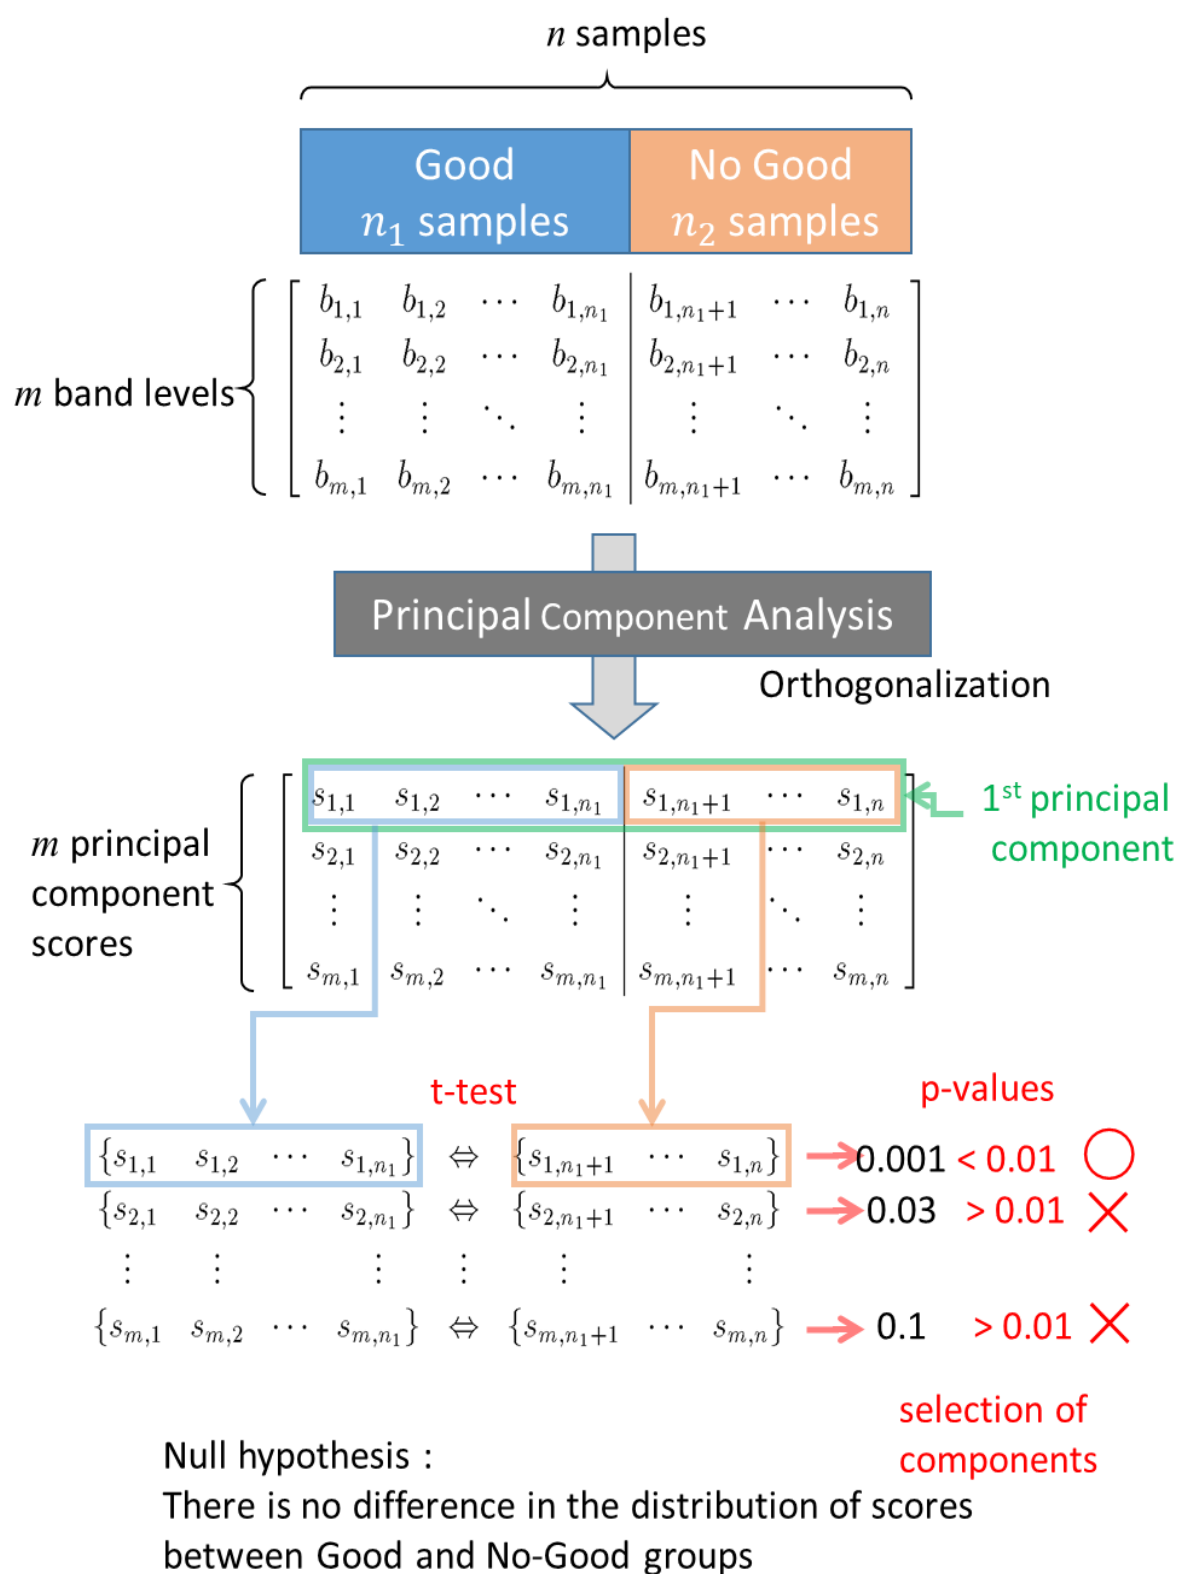


Fig. 3.3: PCA と統計的検定による次元圧縮の一連の手順

第4章 線形判別分析とサポートベクトルマシン

本章では、分類問題でよく使われる判別モデルについて述べる。本研究では線形判別モデルとしてフィッシャーの線形判別分析を、非線形判別モデルとしてガウスクアーネルを用いたサポートベクトルマシン (SVM) を用いた。

4.1 フィッシャーの線形判別分析

フィッシャーの線形判別 [14][15] はクラス間を最も分離する直線あるいは超平面を引くことによりクラス分類を行う。クラス間の境界が線形式で表せない場合この判別法は有効に働かないが、パラメータの設定が容易である。本研究では2群（良品と不良品）の分類を考える。

m サンプルの d 次元データ (ベクトル) $\mathbf{X}_i = (x_{1i}, x_{2i}, \dots, x_{di})^T, i = 1, 2, \dots, m$ を2群 G_1, G_2 に分類することを考える。各群のサンプル数をそれぞれ m_1, m_2 とする。X 全体は以下の d 行 m 列の行列

$$\mathbf{X} = \begin{pmatrix} X_{11} & X_{12} & \dots & X_{1m} \\ X_{21} & X_{22} & \dots & X_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ X_{d1} & X_{d2} & \dots & X_{dm} \end{pmatrix} \text{で与えられる。}$$

各群の平均ベクトルをそれぞれ $\boldsymbol{\mu}_1, \boldsymbol{\mu}_2$ とする。また、 d 次元空間から1次元空間への変換ベクトルを

$$\mathbf{a} = \begin{pmatrix} a_1 \\ a_2 \\ \vdots \\ a_d \end{pmatrix} \text{とする。}$$

このときサンプル \mathbf{X}_i を次の線形判別関数で算出される Z_i に従って2群に分離することを試みる。

$$Z_i = \mathbf{a}^T \mathbf{X}_i = a_1 X_{1i} + a_2 X_{2i} + \cdots + a_d X_{di} \quad (4.1)$$

クラスを最適に分類するような変換ベクトル \mathbf{a} を次の二つの条件から求める。

1. 平均ベクトル μ_1 、 μ_2 の \mathbf{a} による射影 $\mathbf{a}^T \mu_1$ 、 $\mathbf{a}^T \mu_2$ の差 $\mathbf{a}^T (\mu_1 - \mu_2)$ を最大化する
2. 射影後の各クラスの分散の和 $\frac{1}{m_1} \sum_{\mathbf{X}_i \in G_1} (\mathbf{a}^T \mathbf{X}_i - \mathbf{a}^T \mu_1)^2 + \frac{1}{m_2} \sum_{\mathbf{X}_k \in G_2} (\mathbf{a}^T \mathbf{X}_k - \mathbf{a}^T \mu_2)^2$ を最小化する

1 は射影後のクラス間の距離を平均ベクトルの差を代表値に取り、それを最大化する条件である。2 は射影後のクラスは密集する (分散は小さい) という条件である。

二つの条件を同様に扱うため、平均ベクトルの差を 2 乗したクラス間分散行列 \mathbf{S}_B を定義する。

$$\mathbf{S}_B = (\mu_1 - \mu_2)(\mu_1 - \mu_2)^T \quad (4.2)$$

また、クラス内共分散行列 \mathbf{S}_W を定義する。

$$\mathbf{S}_W = \frac{1}{m_1} \sum_{\mathbf{X}_i \in G_1} (\mathbf{X}_i - \mu_1)(\mathbf{X}_i - \mu_1)^T + \frac{1}{m_2} \sum_{\mathbf{X}_k \in G_2} (\mathbf{X}_k - \mu_2)(\mathbf{X}_k - \mu_2)^T \quad (4.3)$$

すると条件 1 の $\mathbf{a}^T (\mu_1 - \mu_2)$ を 2 乗すると \mathbf{S}_B をつかって $\mathbf{a}^T \mathbf{S}_B \mathbf{a}$ と書ける。条件 2 は \mathbf{S}_W をつかうと $\mathbf{a}^T \mathbf{S}_W \mathbf{a}$ という形で書ける。この平均ベクトルの差とクラス内分散の比 $\eta(\mathbf{a})$ を次の式で定義する。

$$\eta(\mathbf{a}) = \frac{\mathbf{a}^T \mathbf{S}_B \mathbf{a}}{\mathbf{a}^T \mathbf{S}_W \mathbf{a}} \quad (4.4)$$

すなわち $\eta(\mathbf{a})$ を最大化する \mathbf{a}_{max} が最もクラス間を分類することになる。ところで式 (4.4) は \mathbf{a} についての 0 斉次方程式であるため、分母に $\mathbf{a}^T \mathbf{S}_W \mathbf{a} = 1$ という制約を設けても結果に影響はない。結局式 (4.4) の $\eta(\mathbf{a})$ の最大化問題は次式を $\mathbf{a}^T \mathbf{S}_W \mathbf{a} = 1$ の下で最大化することと同義である。

$$\eta(\mathbf{a}) = \mathbf{a}^T \mathbf{S}_B \mathbf{a} \quad (4.5)$$

ここでラグランジュの未定乗数法より

$$h(\mathbf{a}) = \mathbf{a}^T \mathbf{S}_B \mathbf{a} - \kappa(\mathbf{a}^T \mathbf{S}_W \mathbf{a} - 1) \quad (4.6)$$

を最大にする \mathbf{a} を求めるとよい。ここで κ はラグランジュ乗数である。

$$\begin{aligned} \frac{\partial h(\mathbf{a})}{\partial \mathbf{a}} &= \mathbf{S}_B \mathbf{a} - \kappa \mathbf{S}_W \mathbf{a} \\ &= (\mathbf{S}_B - \kappa \mathbf{S}_W) \mathbf{a} = 0 \end{aligned} \quad (4.7)$$

4.7 の両辺に左から \mathbf{S}_W の逆行列を掛けると、

$$(\mathbf{S}_W^{-1} \mathbf{S}_B - \kappa \mathbf{E}) \mathbf{a} = 0 \quad (4.8)$$

\mathbf{E} は単位行列である。このことから \mathbf{a} は、 $\mathbf{S}_W^{-1} \mathbf{S}_B$ の固有ベクトルであり、 κ は対応する固有値である。

こうして得られた $\mathbf{a}_m \mathbf{a}_x$ により線形写像された Z をクラス間全体の平均ベクトル $\boldsymbol{\mu} = \frac{1}{2}(\boldsymbol{\mu}_1 + \boldsymbol{\mu}_2)$ の写像の大きさと比較することで \mathbf{G}_1 、 \mathbf{G}_2 のどちらの群に属するかを決定する。

モデルの構築には数値解析ソフトウェアである MATLAB の statistics and machine learning toolbox に含まれる `fittediscr` という関数を用いた。

4.2 サポートベクトルマシン

線形判別分析は式 (4.4) の線形識別関数で定義される境界面が線形な場合（平面）に限られるが、サポートベクトルマシン (SVM[16]) は非線形カーネル関数を用いることで複雑な境界面（曲面）を形成し、線形分離できない問題に対しても対処できる可能性がある。SVM は判別に不要なデータ群と必要なデータ群 (サポートベクトル) に分類し、マージン最大化の制約のもとで、サポートベクトルによって識別面を構築する。単に各クラスを完全に分離した境界面を構築するのではな

く、各クラスから最も離れた境界面を構築するため、未知のデータについても精度よく分類できる。SVM はデータに対して非線形の写像を施し、高次元空間に変換する特徴写像を行う。そしてその空間で線形判別を行う。実際には非線形変換を行ったのちの特徴ベクトルの内積の計算は、カーネルトリックによりカーネル関数による計算で置き換えることができるので、高次元での計算は行わない。本論文ではガウシアンカーネルを用いて最適な識別面を構築する。モデルの構築には MATLAB の statistics and machine learning toolbox に含まれる `fitcsvm` という関数を用いた。

4.3 異常検知におけるハイパーパラメータの取り扱い

以下分かりやすいように、陽性 (Positive) を不良品、陰性 (Negative) を良品とする。

ところで今回の問題はモータの良品と不良品を判別することである。一般にこういった不良品検知の問題では良品よりも不良品の方が出現率としては低く、事前確率は等しくない。また誤分類時の重み (コスト) は一般的にクラス間で異なるはずである。例えば検査員が良品と判定したモータを AI が不良品と判定する誤分類 (偽陽性、生産者危険、第一種の過誤) と検査員が不良品と判定したモータを AI が良品と判定する誤分類 (偽陰性、消費者危険、第二種の過誤) は後者の方が致命的であることは明白である。事前確率や誤分類時の重みは損失関数の最小化の計算の際に用いられるハイパーパラメータであり適切な設定をしないと分類器としての性能が下がってしまう。

そこで本論文では良品の事前確率を良品サンプル数を総サンプル数で割った値、不良品の事前確率を不良品サンプル数を総サンプル数で割った値と設定する。この値は MATLAB の関数 `fitcdirc` および `fitcsvm` の引数の一つである `Prior` にベクトルとしてそれぞれ設定する。誤分類のコストは誤分類をどこまで許容するのかに依存してパラメータが変わるため、事前に値を決定することは難しい。そのため少しずつパラメータを変えながら分類器として最も性能の高くなるパラメータを採用する手法をとる (グリッドサーチ [17])。誤分類のコストの値は関数の `Cost` という引数に設定する。ここでいう '性能の高い' とは単なる分類器の平均正解率のことではなく、偽陰性率 (検査員が不良品と判定したモータ数のうち AI が良品と判定した数の割合) と偽陽性率 (検査員が良品と判定したモータ数のうち AI が不良品と判定した数の割合) または再現率、適合率、それらの調和平均である F 値などをもとに考える。

グリッドサーチの手法を以下に述べる。調整するパラメータは誤分類のコストのみとし、事前確率などの他のパラメータは固定する。誤分類のコストは偽陽性 (第一種の過誤) を良品の事前

確率の逆比、偽陰性（第二種の過誤）を不良品の逆比として、それらを偽陽性について正規化したものとする。つまり偽陽性の誤分類コストを 1、偽陰性のコストを $\frac{\text{良品サンプル数}}{\text{不良品サンプル数}}$ とする。そして偽陽性の誤分類コストは 1 で固定し、偽陰性のコストを変動させる。具体的には偽陰性の誤分類コストに 0.1～10 で 0.1 刻みで変化する変数 (Error cost と呼称する) を掛けることでコストを変化させた。Error cost が大きい値になると偽陰性率が減るが、一方で偽陽性率は増大する。グリッドサーチの結果を視覚化するために、Error cost を横軸に、縦軸には誤り率をとり偽陰性率と偽陽性率の変化を描画して最適な Error cost を探索する。

第5章 振動データ収集の概要

本章ではモータの振動データ収集の概要について説明する。本研究では2回データ収集を行っており、それぞれ治具の機構やセンサが異なっている。

5.1 1回目のデータ収集

まずは、2018/11/27～2018/12/26に行われた1回目のデータ収集について説明する。1.1で述べた通りモータ検査ラインでは官能検査のほかに振動レベル測定を行っている。1回目のデータ収集システムは以下で説明する振動測定装置を流用する形で構成されている。

5.1.1 現行の振動測定システム

モータの振動レベルを測定するための測定治具の概略図を Fig. 5.1 に示す。測定治具はモータのフランジを受け皿上に懸架する機構となっており、振動はモータの上下に磁石で貼り付けられた1軸の加速度センサにより収集される。

また実際の測定現場の写真を Fig. 5.2 に、測定システムの構成を Fig. 5.3 に示す。実際の検査の一連の流れは次の通りである。

1. 検査員がラインから流れてくるモータを手に取り、電源ユニットに接続し、作動音を聴く
2. Fig. 5.2 に示すように測定装置にモータを置き、シーケンサのスタートボタンを押す
3. シーケンス制御により、ロボットアームがモータの上下に1軸加速度センサを貼り付ける
4. 収集される上下の加速度の大きさ（実効値）がディスプレイに電圧値として出力され、その値を読み取る
5. 官能検査と4.の出力値をもとに、モータを良品と不良品に仕分けする




Fig. 5.1: 実際に製造現場で使われている振動測定治具の概要図

検査ラインとは別に AI の学習データ収集をするとなるとデータ収集の分だけ工数が増え、コストもかかる。そこで普段のモータの品質検査に並行してデータ収集を行うシステムであればそのような問題を解決できると考えた。

5.1.2 データ収集システム

提案したシステムの試験運転の様子を Fig. 5.4 に、システム構成図を Fig. 5.5 に示す。

このシステムは従来の振動レベル測定装置に Dual Tone Multi Frequency(DTMF) リレーボード、オーディオインターフェース、PC をつなぎ合わせて構成される。PC にはコンパイルしておいたソフトウェアをあらかじめインストールしておく。ソフトウェアの概要は 5.1.3 で後述する。従来のシステムでは押しボタンをトリガーとしてロボットアームを制御していたが、提案システムではトリガーをテンキーに変えた。システム構成としては複雑化するが、検査員の操作面から見て押しボタンがテンキーに替わるだけであり、従来の振動レベル測定と比較して工数はほぼ同じである。データ収集の際に教師データ (検査員の判断結果) を収集する必要があるが以下の手順によって教師データを集めることにより検査員の負担を増やさずに振動データと教師データを集めることに成功した。

検査モータが良品の場合、テンキーの Enter キーを押すことでロボットアームが作動し、セン

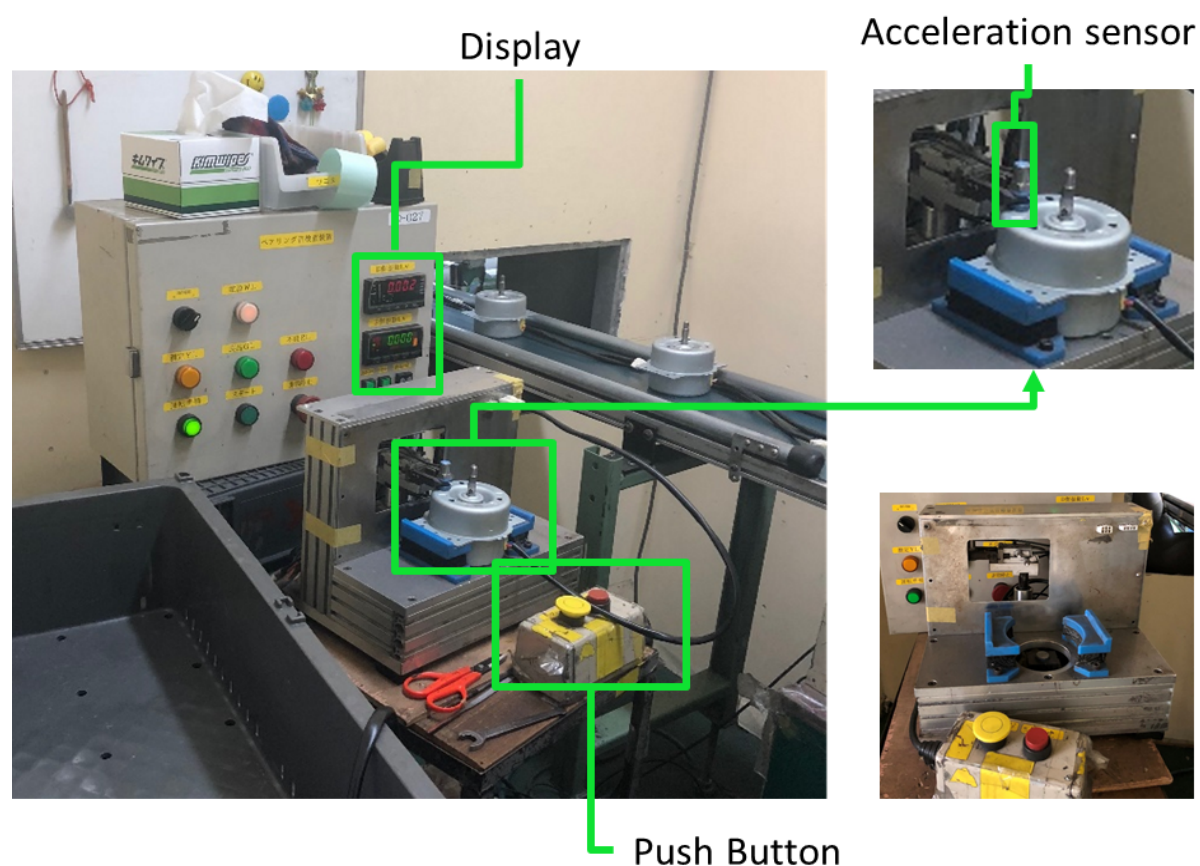


Fig. 5.2: 実際の検査現場の写真

サで取得した振動データはオーディオインターフェースと PC を介して HDD に蓄積されていく。その際教師データとして良品というラベル付けが行われる。操作が異なるのは検査モータが不良品の場合である。テンキーには不良原因を選択するボタンを割り当ててあり、検査モータが不良品の場合は該当する原因のボタンを押したのちに Enter キーを押す。その際、不良品というラベルと不良原因がラベル付けされて保存される。生産されるモータの大半が良品モータであるため、ほとんどの操作はテンキーの Enter キーを一度押すだけである。一日 0~3 台発生する不良品の場合のみボタンを一つ追加で押すことになるが、検査員の負担や工数はほとんど変わらない。

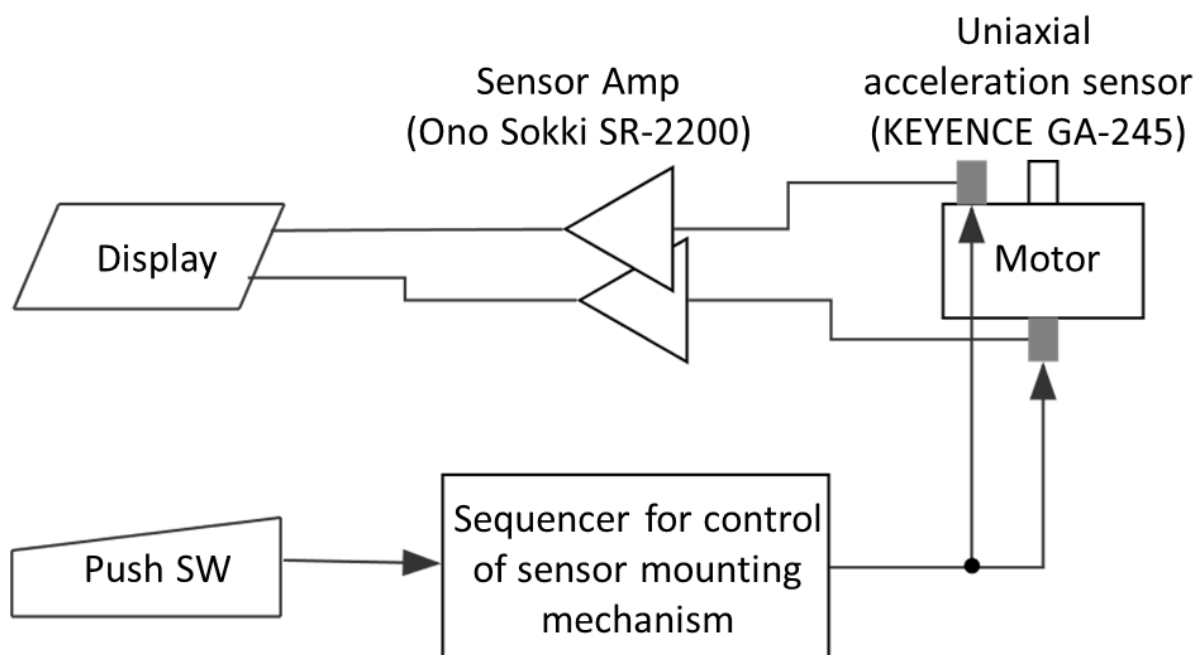


Fig. 5.3: 実際の検査現場で使われる振動測定システムの構成図

5.1.3 ソフトウェア概要

自作したソフトウェアの UI を Fig. 5.6 に示す。ソフトウェアは MATLAB で作成した。ソフトウェア上でできることは次の通りである。

1. 振動データと教師データ、不良原因の収集
2. AI の追加学習
3. 交差検証による AI の学習結果表示
4. AI の分類結果の画面表示
5. サンプリングレート、収集時間、振動が安定するまでの待ち時間などの設定

設定などはソフトウェア上で柔軟に変更できるため、システムを構成するための機器さえあれば別製品への展開は容易である。




Fig. 5.4: 提案システムの試運転の様子

5.1.4 問題点

このデータ収集システムを1ヶ月稼働させ、検査員の負担を増やすことなく普段の検査に並行して32,471件の振動データを収集した。内訳は良品32,275件(99.4%)、不良品196件(0.6%)である。しかし、データ収集の際にセンサヘッドが破損するという問題があった。このシステムは、モーター一つ一つに対してセンサを着脱するため経年劣化が激しい。具体的にはセンサヘッドの摩耗、ゆるみなどが発生するリスクがある。センサヘッドの破損時に検査員は接着剤で補強する処置を行ったが、破損前後で振動スペクトル形状が大きく異なっていることが分かった。接着剤の弾性特性によってセンサ本体の伝達関数に変化したためと考えられる。AIの学習において装置の故障による取得信号の変化は致命的であり、故障以前に学習したAIは正しく機能しなくなる可能性が高い。その様な背景もあり、AIを活用した検査システムには次の事項が要求されたと考えた。

1. システム全体が堅牢である
2. 測定装置の保守点検が容易である
3. 取得信号のロバスト性が高い

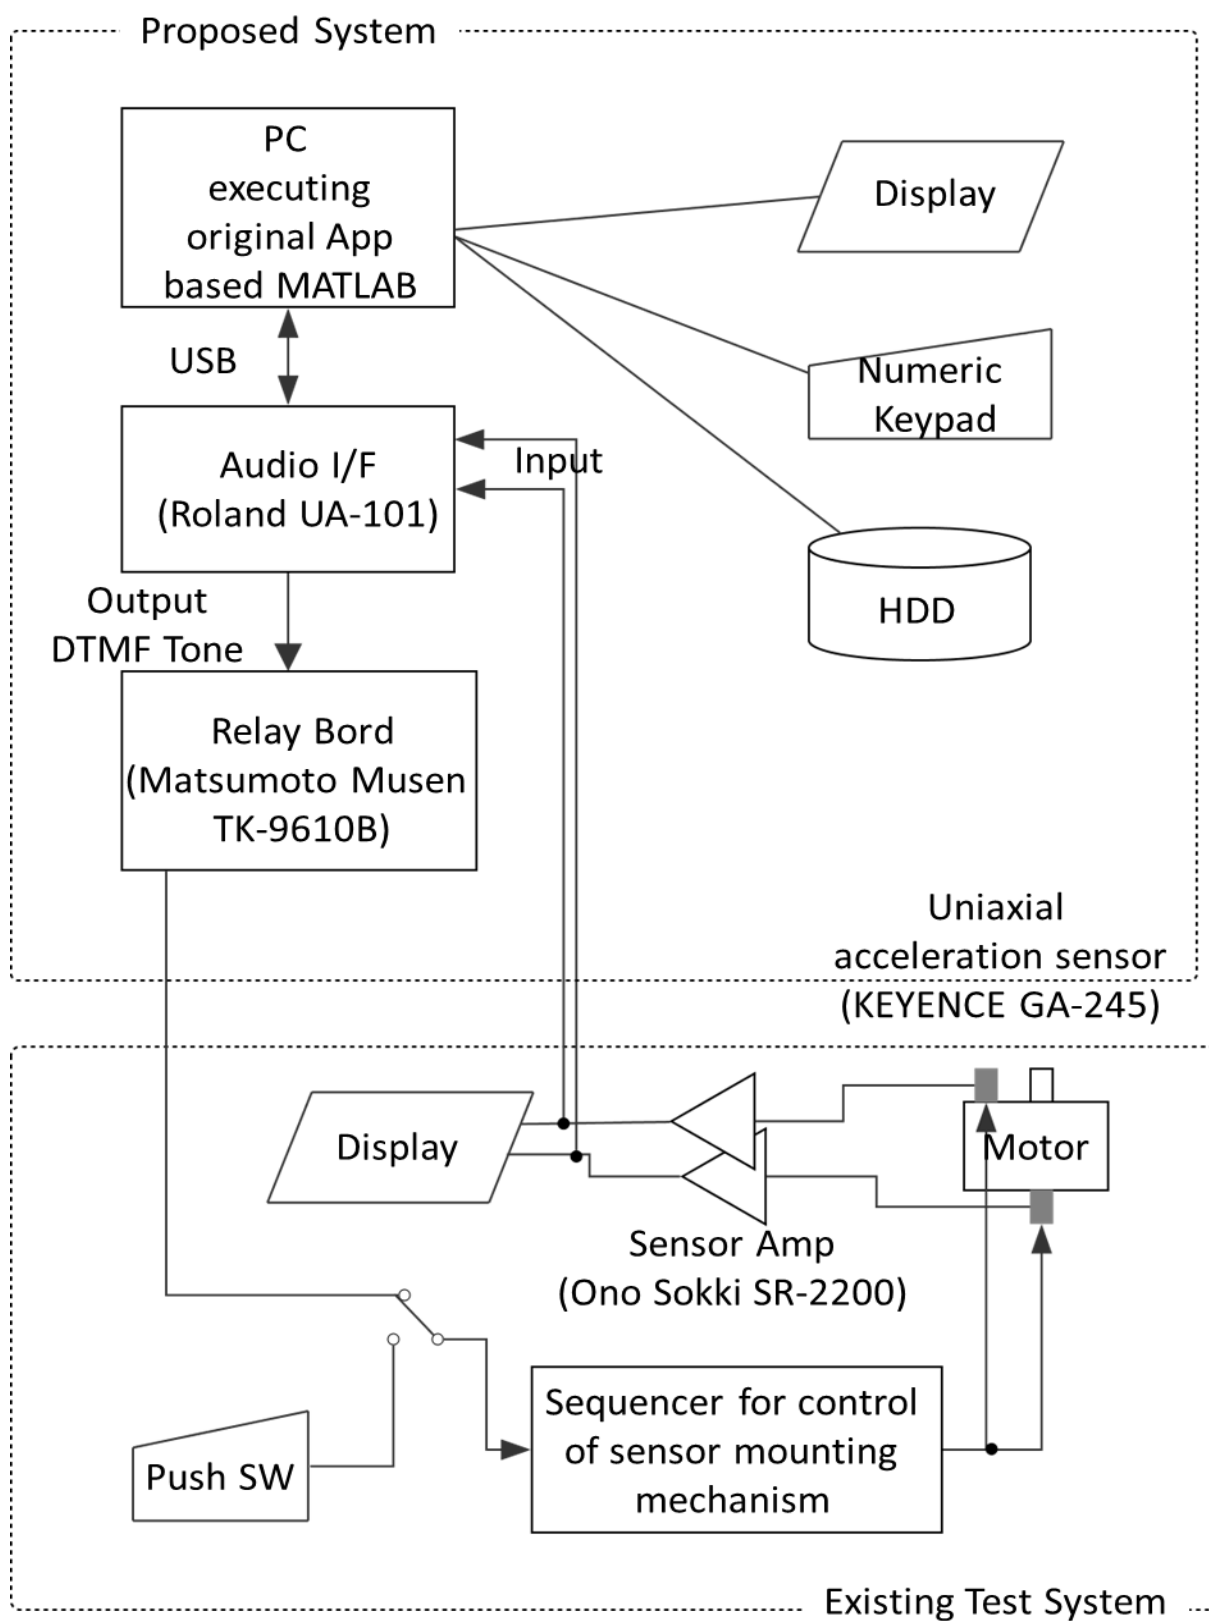


Fig. 5.5: 提案システムの構成図

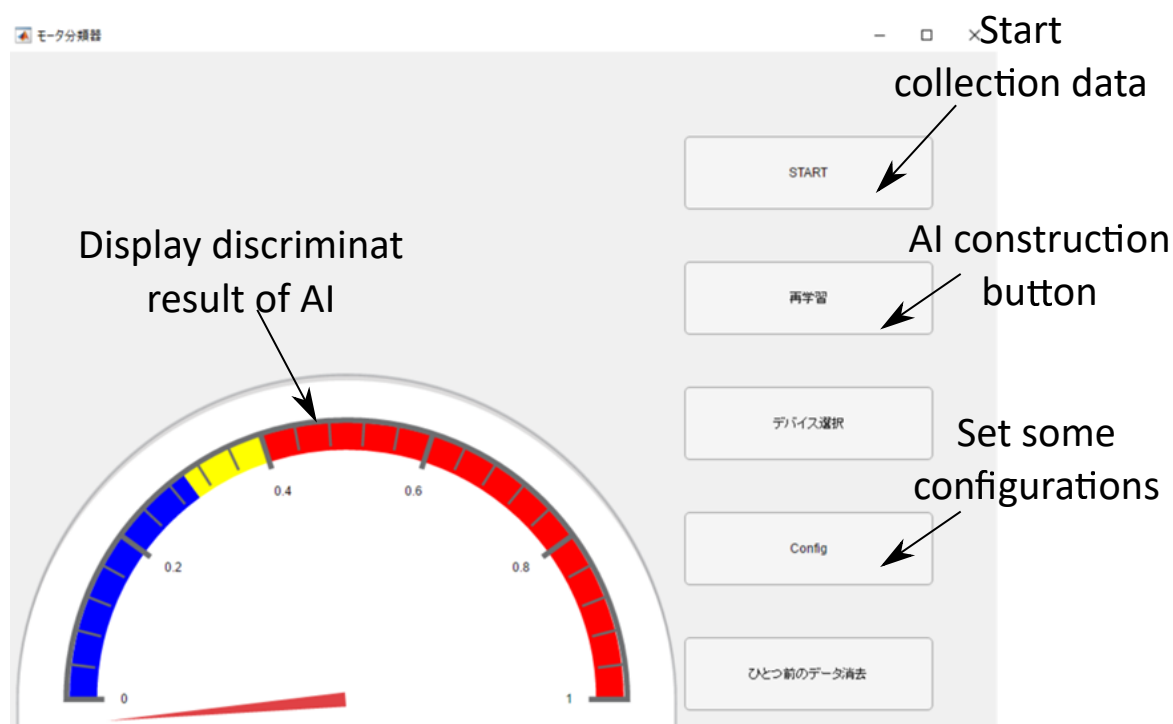


Fig. 5.6: 自作ソフトウェアの UI

これらを満たさない限り、いくら適切なデータ処理を施しても分類器の性能を最大限に高めることは難しいと考えた。そこで次項で述べる 2 回目のデータ収集では上述した要求事項を達成するシステムへの改良を行った。

5.2 2 度目のデータ収集

5.1.4 で述べられているようなシステムの要求事項を達成するため、1 回目のデータ収集システムを改良した。データ収集は 2019/11/26～2019/12/06 に行われた。

2 回目のデータ収集のシステム構成図を Fig. 5.7 に示す。1 回目のデータ収集システムと比較すると必要機器も減り単純化されている。以下に具体的な改善点を述べる。

1 回目のデータ収集で問題となったのが、測定システムの堅牢性であった。そこでシステムの堅牢性改善に焦点を当て、測定治具の改良を試みた。測定治具の写真と概要図を Fig. 5.8 と Fig. 5.9 にそれぞれ示す。3 軸加速度センサの向きは x 軸が回転方向、 y 軸が軸方向、 z 軸が遠心方向とした。

1 回目のデータ収集で使った測定治具と大きく異なるのは 2 点ある。

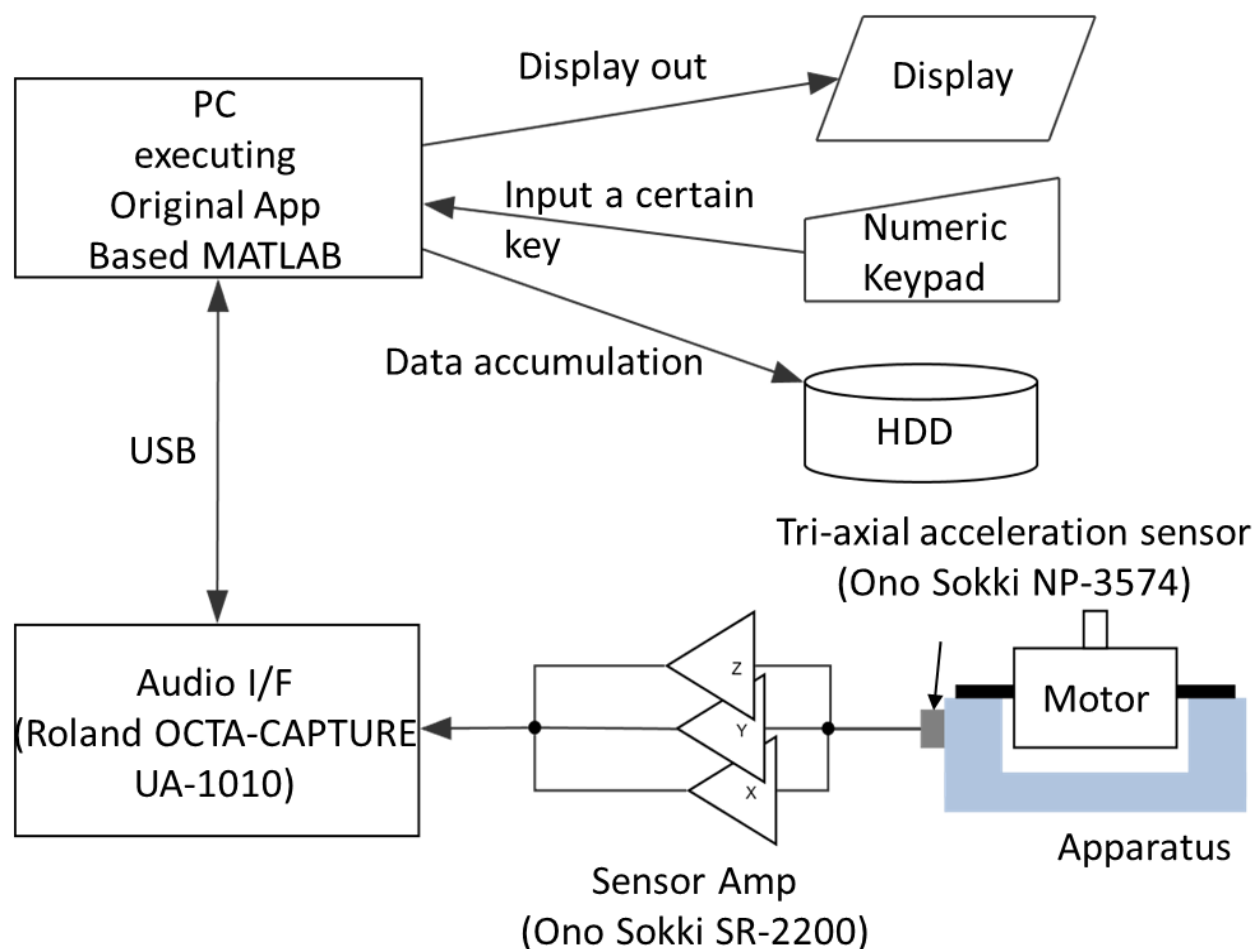


Fig. 5.7: 2 回目のシステムのシステム構成図

1つ目はセンサである。従来は1軸の加速度センサを2つ使っていたがそれを3軸加速度センサに置き換えた。従来では鉛直方向の振動のみしか取得できなかったが、判別に有利になる情報が鉛直方向に現れず他の軸方向に現れる場合、分類が難しくなる。3軸加速度センサを採用することで、鉛直方向以外に回転方向と遠心方向の振動も取得できるため、分類器の性能が向上すると考えた。

2つ目はセンサの取り付け位置である。従来はモータの上下に磁石付きのセンサヘッドを直接貼り付けいていた。しかし、5.1.4で述べた通り、センサを直接動かして貼り付けるのはセンサの劣化やヘッドの摩耗につながるため、取得信号が安定しない。そこでセンサを直接モータに貼り付けるのではなく、測定治具にねじ止めした。センサを直接触らず動かさないで、劣化はしにくい。しかしモータに直接センサを張り付けないので信号が小さくなる可能性がある。そこで作成した治具は測定治具自体が振動しやすいような機構にしている。具体的にはモータフランジの受




Fig. 5.8: 改良治具の写真

け金具部分は軽量のアルミ合金を、受け金具の足はゴムとバネが一体となったインシュレータを採用した。

測定装置の保守についてはセンサを止めているネジのゆるみや治具の立て付けに問題がないか確認するだけである。また、土台の金属にアルミ合金ではなく重量の大きい真鍮を採用することで暗振動の影響を受けにくくした。これらの対策により 5.1.4 のシステム要求の全項の改善を試みた。

このシステムではセンサは治具に組み込まれているため、センサを貼り付けるためのロボットアームを必要としない。更にロボットアーム作動のためのリレー回路も必要とせず、センサの数も1つに減らせるためコスト的に有利である。

測定治具を改善したシステムにより、9131 件の振動データを収集した。良品モータは 9072 件 (99.4%)、不良品モータは 59 件 (0.6%) である。また 1 回目のデータ収集の結果良品のデータ分布




Fig. 5.9: 改良治具の概要図と 3 軸加速度センサの軸の設定

は分散が小さくまとまっていたため、データ総数は 1 回目よりも少なくてよいと考えた。
それぞれのデータ収集の概要を Table. 5.1 に示す。

Table. 5.1: 1 回目と 2 回目のデータ収集の概要

	1 度目のデータ収集	2 度目のデータ収集
収集データ総数	32471(良 32275 不 196)	9131(良 9072 不 59)
使用センサ	1 軸加速度センサ× 2	3 軸加速度センサ× 1
サンプリングレート	20 kHz	44.1 kHz
オクターブスペクトルの次元	109 × 2	121 × 3
センサ取り付け位置	モータ上下ブラケット部	測定治具にねじ止め
ロボットアーム、リレー回路	要	不要

第6章 AI分類結果

6.1 結果の検証方法

本論文では線形判別分析と SVM による分類精度を確かめる。AI の分類結果を確かめる際は過学習や汎化性に対して細心の注意を払う必要がある [17]。そこで今回は交差検証 [3] によって分類精度を確認する。

データサンプルは 1 回目のデータ収集と 2 回目のデータ収集の 2 種類があるので、それぞれについての分類精度を確かめその結果からどちらの予測モデル、データ収集システムが適切か考察する。

4.3 で述べた通り、グリッドサーチによって最適な分類器を探索する。誤り率の計算は 5 分割交差検証により計算される。5 つのデータ群がそれぞれ同じ割合の良品と不良品を持つという条件の下でランダムに分割する。グリッドサーチでパラメータを変更するごとにデータを分割するため同じ誤りコストに設定してもデータの組み合わせによって誤り率は多少変動する。データの分割を固定化させないことにより、データの組み合わせによる影響を排除できるため、結果がより正確に得られる。

また入力データは学習データ群に依存して次元が変わる。なぜなら学習データ内の良品データ群と不良品データ群に対して統計的検定を行い、次元削減を行うためである。

6.2 1 度目のデータ収集によって得られたデータに対する分類結果

線形判別分析による結果を Fig. 6.1 に、SVM による結果を Fig. 6.2 に示す。




Fig. 6.1: 1 回目のデータ収集で得られたデータに対する線形判別分析の結果

パラメータの変更ごとにデータを分割するため、偽陽性率、偽陰性率の各ラインは近接する誤りコストで変動が激しいが、偽陰性率の誤りコストを増大させるにしたがって偽陰性率は低下し、偽陽性率が増加している傾向が見て取れる。

Fig. 6.1 をみると偽陰性率の誤分類コストを 0.1 倍にしたとき偽陰性、偽陽性の二つの誤り率は約 10% で誤分類コストを 2 倍より大きくしても偽陰性率は下がらない。理想は偽陰性の誤りを 0% かつ偽陽性を小さく保つことであるが、偽陰性率 5% の時の偽陽性率が約 40% と高く良品と不良品は線形分離不可能と考えられる。Fig. 6.2 をみると偽陰性の誤分類を 0 にするには偽陽性の誤分類を 90% 程度にしなければならず、両者を分類することは難しい。

しかし 1 回目のデータ収集では 5.1.4 で述べた通り、センサの故障が起きたという問題があった。そこでセンサに故障が起きる前に収集したデータのみを使って分類モデルを構築した。センサに故障が起きる前に収集されたデータ総数は 5864 件で良品が 5716 件、不良品が 148 件である。不良品の割合が多いのはあらかじめ蓄積しておいた不良品を初日にまとめて収集したためである。それらのデータで構築した SVM の結果を Fig. 6.3 に示す。全てのデータを用いて学習した場合




Fig. 6.2: 1 回目のデータ収集で得られたデータに対する SVM の結果

よりも偽陰性率、偽陽性率が改善されている。しかし偽陰性率は誤分類コストを大きくしても 0% にならなかった。つまり 1 回目のデータ収集のようにモータの上下に 1 軸の加速度センサを貼り付ける手法では良品と不良品間で差が現れにくく、分類に有効なデータは収集できないと考えられる。偽陽性率と偽陰性率のラインが交差する箇所（図中矢印）での混同行列を Table. 6.1 に示す。この時、偽陽性率は 3.9%、偽陰性率は 2.8%であった。また再現率は 97.2%、適合率は 35.5% でそれらの調和平均である F 値は 0.520 となった。




Fig. 6.3: センサ故障前に得られたデータに対する SVM の結果

1

Table. 6.1: 1 回目のデータ収集によって構築した SVM の混同行列

		Estimated by AI	
		good	defective
Judged by human	good	5495 (96.1%)	221 (3.9%)
	defective	4 (2.8%)	144 (97.2%)

6.3 2 回目のデータ収集によって得られたデータに対する分類結果

2 回目のデータ収集で得られたデータで学習した線形判別分析による結果を Fig. 6.4 に、SVM による結果を Fig. 6.5 に示す。線形判別分析のグラフは縦軸の範囲が 0～100%でないことや、2 回目のデータ収集において不良品のデータ総数は 59 件と少ないため、偽陰性の変動は 1 回目のデー

タ群より大きくなることに注意する。Fig. 6.4 をみると誤りコストを増大させても偽陰性率が変動し安定していないことが読み取れる。データの分割によっては誤りコストが小さい値でも偽陰性率は 0% になるがデータの分割の影響を加味したうえで確実に 0% にするにはさらに誤りコストを高く設定する必要がある。Fig. 6.5 をみると誤分類コスト 4 倍までは偽陰性率、偽陽性率共に非常に低く推移していることが見て取れる。偽陰性率は誤分類コスト 4 倍まで変動している。つまりデータの分割によって結果が変動するが、誤分類コストが 4 倍以降は偽陰性が 0% で一定になっていることが分かる。つまり図中の矢印の位置が偽陰性率が 0% かつ偽陽性が最も低くなり分類器として最もよい性能を示している。矢印の位置での検査員の判定に対する SVM の分類の混同行列を Table. 6.2 に示す。この時、偽陽性率は 3.4%、偽陰性率は 0% であった。また再現率は 100%、適合率は 16.0% で F 値は 0.276 となった。また入力次元は 60 次元で、元々のオクターブスペクトルが 363 次元であったことから約 $1/6$ に圧縮できた。適合率が Table. 6.1 の結果に比べて低い、これはデータに含まれる不良品の含有率が低いためである。しかし誤分類は **4.3** で述べた通り、偽陰性の方が致命的であることから偽陰性率 0% のこちらのモデルの方が優位である。

これらの結果よりデータ収集の方法としては 2 回目のデータ収集の方が有意であり、また SVM を用いた方が分類器の性能も高いということが分かった。




Fig. 6.4: 2回目のデータ収集で得られたデータに対する線形判別分析の結果

Table. 6.2: 2回目のデータ収集によって構築したSVMの混同行列

		Estimated by AI	
		good	defective
Judged by human	good	8764 (96.6%)	308 (3.4%)
	defective	0 (0%)	59 (100%)




Fig. 6.5: 2 回目のデータ収集で得られたデータに対する SVM の結果

第7章 結びと自動検査システムの実現

7.1 まとめ

以下に各章の内容を要約する。

2章では、研究対象とするモータの仕様や電気的特性による振動成分、主な不良原因のメカニズムについて解説した。

3章では、AIの入力データの前処理について解説した。振動のオクターブバンドレベルを用いるが、それをそのまま入力するのでは計算コストや分類器の性能の点で良くないので、PCAや t 検定を用いて入力データの次元削減をして学習に有意な入力要素に絞る方法を述べた。

4章では、AIとして用いたフィッシャーの線形判別とSVMについて説明した。またほとんどの異常検知の例ではカテゴリのばらつきが問題視されるが、それをハイパーパラメータの設定で解決する方法を述べた。

5章では、実際の検査ラインでのデータ収集の概要について説明した。データ収集を簡易的に誰でも行えるようにするため、自作ソフトウェアをもちいたデータ収集システムを構築した。また1度目のデータ収集では振動測定治具の問題による収集データの異常が発生したため測定治具の機構やセンサの取り付けを工夫してデータ収集における堅牢性の改良に努めた。

6章では、線形判別とSVMのそれぞれの結果について説明した。測定治具の改良後のデータを用いて学習したSVMにおいては、生産者危険を3%程度見逃せば消費者危険を0%にすることができることが分かった。

また付録では異常原因の検知について解説している。良品か不良品かの分類だけではなく、その原因は何かを特定する信号処理手法を説明している。しかし、課題も多くまだ現実的ではない。今後はより正確に異常原因をカテゴリ化することが求められる。

さて、1.3で述べた目的は3つあった。それぞれの目的について達成度を振り返る。

目的1は良品と不良品を高精度で分類する入力次元数の少ないAIの構築であった。そのAIの目標精度は偽陽性率10%かつ偽陰性率1%以下であった。第3章で述べた様に入力データに対す

る前処理を行うことで 363 次元あったデータを約 60 次元に圧縮することができ、交差検証で混同行列を確認したところ汎化性の高い結果であることが分かった。**6.3** で求めた混同行列から、偽陽性 3.3%、偽陰性率 0%であり、目標の精度を十分に達成することができた。

目的 2 は検査員の負担を増やさずに既存の官能検査システムと共存しながら AI を構築するシステムの提案であった。**5.1.2** 及び **5.2** で述べた提案システムは検査員の負担にならずに普段の検査に並行してデータ収集を行え、ボタン一つで AI 構築をする事ができるため短いスパンで AI 構築ができる。またコストも導入時の機器類だけで完結するため低コストであり、要求事項も達成することができた。

目的 3 は目的 2 のシステムのプロトタイプ作成および導入であった。**5.1.2** 及び **5.2** で述べたように、実際にプロトタイプを作り 1ヶ月程度稼働させた。また、その際に得られたデータについて SVM を構築したところ高い精度で良品と不良品を分類することができ、目的を達成することができた。

本論文で述べたモータの作動振動を使った異常検知は入力としてオクターブスペクトルをある処理にしたかって帯域を制限した後に学習させているだけであり単純ながら高い精度を確保できているため有効であると考えられる。今回の手法がコンデンサモータはもちろん DC モータなど他のタイプに応用できるかを今後は検討する必要がある。

7.2 類似研究との比較

モータの異常検知をテーマとした類似研究 [6] と本研究を Table.7.1 で比較する。両研究ともモータの異常をスペクトルを入力とした SVM を用いて検知するという点では類似している。しかし、大きな違いとして指標やデータの収集場所が挙げられる。類似研究は音をターゲットとして、無響室で研究従事者がデータ収集を行っている。一方で本研究は振動をターゲットとしており、構築したデータ収集システムにより製造現場で検査員の負担なしにデータを取得しているため、より AI の導入に近い研究といえる。

7.3 今後の課題と自動検査システムの実現

今後の課題としては

1. 異常原因のカテゴリライズを行う手法の開発

2. ハイパーパラメータの設定方法の自動化

3. 別タイプのモータが今回のシステムで判別可能かを検証

が挙げられる。

1については現状異常原因をカテゴライズする手法は完全ではない。AIを導入した際に大量の不良品が検出されても、どの不良原因か検知できず上流工程の不具合発見が遅れるリスクがある。そのため客観的に不良原因を検知できる手法の開発が求められる。

2についてはハイパーパラメータの設定方法はまだあいまいな部分も多い。例えば入力データに対する特徴選択で統計的検定を用いた際の有意水準の値を今回は1%としたがもっと入力次元が必要な場合は有意水準を上げる必要がある。今回グリッドサーチで動かす変数は誤分類コストの一つだけであったが、動かす変数の数を増やすと学習に時間がかかり、汎用のPCでは計算資源が足りなくなる恐れがある。そのため効率的に性能のよい分類器を探索する手法が求められる。

3については今回のAI設計はコンデンサモータでは有効であると判明したが、別タイプのモータで同じような結果が得られるかを確かめる必要がある。モータごとにデータの前処理を変える必要があるのか検討する必要がある。今回対象のモータには2f加振力をフィルタ処理したが、別種類のモータの固有の振動成分をフィルタ処理で取り除く必要があるのか検討する必要がある。もしモータ毎に固有振動の卓越周波数が異なるのであれば、モータ毎に前処理のプログラムを変える必要がある。しかし、主成分分析と統計的検定によって固有振動成分が学習に必要な要素として取り除かれるのであれば、モータ種類ごとにプログラムを変える必要はなくなる。そのため固有振動成分が主成分分析と統計的検定によって取り除かれているのかを製品別に確認する必

Table. 7.1: 類似研究と本研究の類似点と相違点

	類似研究	本研究
収集データ総数	159(良 52 不 107)	9131(良 9072 不 59)
指標	音	振動
分類器	SVM	SVM
データ収集場所	無響室	製造現場
データ次元	34 次元 (メルバンド)	363 次元 (1/12 オクターブバンド)
同じモータに対するデータ収集回数	21 回	1 回
特徴抽出	無	有 (PCA&t 検定)
偽陽性率	7.7%	3.4%
偽陰性率	3.7%	0%

要がある。

最後に以下に具体的な自動検査システムの構想を述べる。システムをスタートする時には学習も何もされていない AI が組み込まれた状態で、最初は検査員がシステムを動かしていく。検査員は普段の検査をして、自分の感覚に基づいて良品か不良品かを判別し、ある操作によりラベル付けされたデータが蓄積されていく。データが集まってきたところで学習ボタンを押すことにより AI が学習する。ハイパーパラメータはプログラム上で最適な値を探索するようにしておく。学習の結果として、交差検証精度を確認し十分な精度であると確認できたら検査員は作業を終え、代わりにロボットアームを導入する。AI の分類結果をもとに出力されるトリガによりロボットアームの動作を決めるようにする。例えば、良品であればモータはパレットに戻され、不良品であればパレットに戻さずに取り除くようにする。本論文であれば 1 s 毎に AI の分類結果が出力されるわけだが、モータの振動は定常的ではないため分類結果にばらつきが生じる可能性は十分ある。そのため、1 s 間の分類結果だけではなくある一定時間の分類結果の平均を AI の出力とすることが必要となるかもしれない。その場合、それだけ検査に時間がかかることになるためトレードオフを考える必要がある。本研究で開発した SVM については偽陰性率が 0 % であったが、偽陽性率は 3 % ほどあった。そのためこの AI を導入した際はシステムの導入費を無視して考えると、人的コストは完全にカットできるが、3 % 分の良品モータは出荷されずに不良品として扱われることになる。そのコスト損失が無視できない場合は、ある一定期間ごとに AI によって不良品と分類されたモータを人によって検査して新たに仕分けを行うと従来に比べてかなりのコストカットが見込める。検査ライン上で学習データ収集と AI 構築また AI による分類が行えるシステムは他のモータにも AI を導入する際に非常に有効であると考えためこのシステムを試験導入することも必要だと考える。

付 録 A 不良原因の検出方法

ここでは不良品と分類されたモータがどのような原因によるものなのかを推定する手法を説明する。この手法は 3 軸加速度センサによる振動データについて検討する。**2.3** で述べた通り、不良原因にはベアリングによって引き起こされるものと擦れ振動によって引き起こされるものの二つがあった。ベアリング不良の推定は、ベアリング径が小さいため異常振動の成分が小さく、難しい。そこで擦れ振動を視覚化することによる異常原因検知の方法を紹介する。

A.1 擦れ振動検知の手法

擦れ振動は **2.3** で述べた通り、ロータとステータの間に異物 (バリなどの金属片) が挟まり、それがロータと擦れる事によって発生する異常振動である。すなわち擦れ振動にはロータの回転角度に依存した振動をしていると考えた。そこで時間経過に対するロータの回転角を横軸に取り、振動波形を整理することで回転角に対する依存性を視覚化することを目指す。

データ処理のフローチャートを Fig. A.1 に示す。

データ処理の手順は以下に説明するとおりである。解析対象とするデータは 3 軸加速度センサで収集した各軸の 1 s の振動波形である。研究対象モータには **2.2** で述べた通り良品、不良品関わらず存在する振動成分がある。それらの振動成分はパワーが支配的で、電源や回転磁界依存の振動である。そのため適切に取り除かないとロータの回転依存の振動は隠れてしまう。その前処理としてフィルタ処理を行う。

まずノッチフィルタにより、120 Hz の整数倍の振動成分を 6 次まで取り除く。これにより電源依存成分を除去する。次に線形予測符号 (Liner Predictive Cording, LPC) を使ったフィルタ処理を行う。ノッチフィルタにより電源依存成分を取り除いた振動波形には回転磁界依存の強いピークが残っている。しかしそのピーク箇所は個体ごとに異なり、卓越周波数の推定は難しい。そこで LPC によるフィルタ処理を施し残差波形を抽出する。2 次の LPC では正弦波を予測可能であり、単一性のピークを予測することができる。この 2 次の LPC フィルタを施すことにより、回転

磁界に依存した強いピークを取り除くことができると考えた。2つのフィルタ処理により電源および回転磁界のモータ固有の振動成分を取り除く。

残差波形には電源、回転磁界に依存した振動成分は含まれないためモータの回転に起因する振動成分が多く含まれていると推測される。そこでこの波形に対して自己相関をとることでモータの回転数を推定できると考えた。3軸それぞれのフィルタ処理後の自己相関波形の和を計算する。モータの同期速度は1800 rpm(30 rps)であるのでモータの回転数は滑りの影響を考え、29~30 Hzの間にあると仮定した。タイムラグに変換した33.3~34.5 msの間で自己相関の値が最大となるタイムラグをモータの回転周期としてモータの回転数を見積もった。

次に推定した回転数をもとに、1 s間の時間経過に対するロータの回転角を計算する。最後に横軸を時間経過に対するロータの回転角として、1 sの間残差信号のパワーを重ね描きする。以上の手順によって擦れ振動の視覚化を試みる。

A.2 結果と擦れ振動検知の課題

A.1 で説明したデータ処理を施した結果を Fig. A.2 に示す。

Fig. A.2 左の列が良品モータ、右の列が不良品モータであり、1行目がx軸、2行目がy軸、3行目がz軸である。良品モータについてみると、ロータ回転角に対して残差信号のパワーは一定であり角度依存性は見られない。一方不良品モータについてみると、特定の回転角で残差信号のパワーが大きくなる角度依存性が視覚化されている。よってロータ回転角に依存した擦れ振動を視覚化することに成功した。

しかしこの手法にはまだ課題が残っている。まず検査員が擦れ振動による不良と判断したモータの中でも Fig. A.2 のような角度依存性が確認されないサンプルがあった。この原因としては二つ考えられる。

一つは擦れ振動の発生原因にある。擦れ振動は異物がロータとステータに挟まり異物がロータに擦れることによって生じる異常振動であるが、モータの傾き具合によって異物の状態が変化する。そのため検査員が手で持ち上げて作動音を聴いた時には擦れ振動が聞こえていたが、測定治具に置いた時には異物がロータに接触しなくなり結果的に擦れ振動の角度依存性が確認されなかったと考えられる。

二つ目は検査員の判断に誤りがある場合である。不良品と判断したが、実際には不良品の特徴

はなく良品であるということも考えられる。実際に検査員が不良と判断した一部のモータで再検査を行ったところ、不良品とは言えないというサンプルが数個あることが分かっている。検査員が誤判定する理由の一つとして次のようなことがある。出現した不良の一部はブラケットを外し、異常個所を取り除いてもう一度検査を行うが、この際検査員は視覚的に一度不良を起こしていることを把握できる。初めて検査するモータよりも一度不良を起こしたモータに対する検査は厳しくなってしまうため誤判定が生じると考えられる。検査員の再現性が何 % 程度あるのかを確かめるのは目標とする AI の精度を確認するためにも今後実施すべきである。

また今回の手法ではあくまで視覚的に擦れ振動が起こっていることを捉えることに特化しており、数値的に不良原因を特定できるわけではない。今回の手法を更に改良して客観的に異常原因を分類することが求められる。

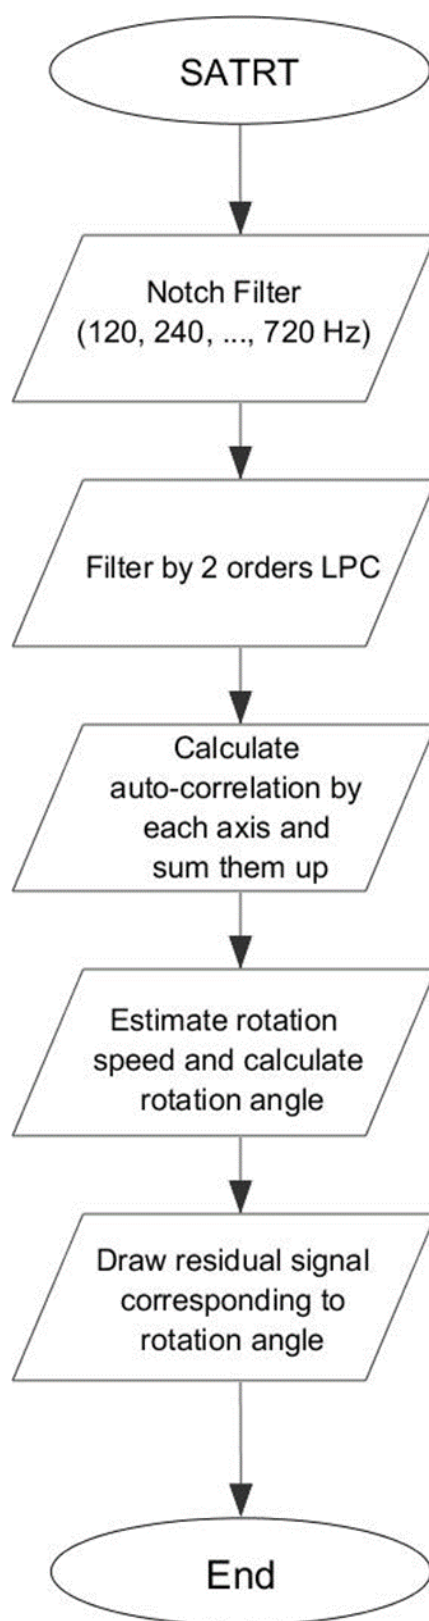


Fig. A.1: 擦れ振動検知のデータ処理フロー

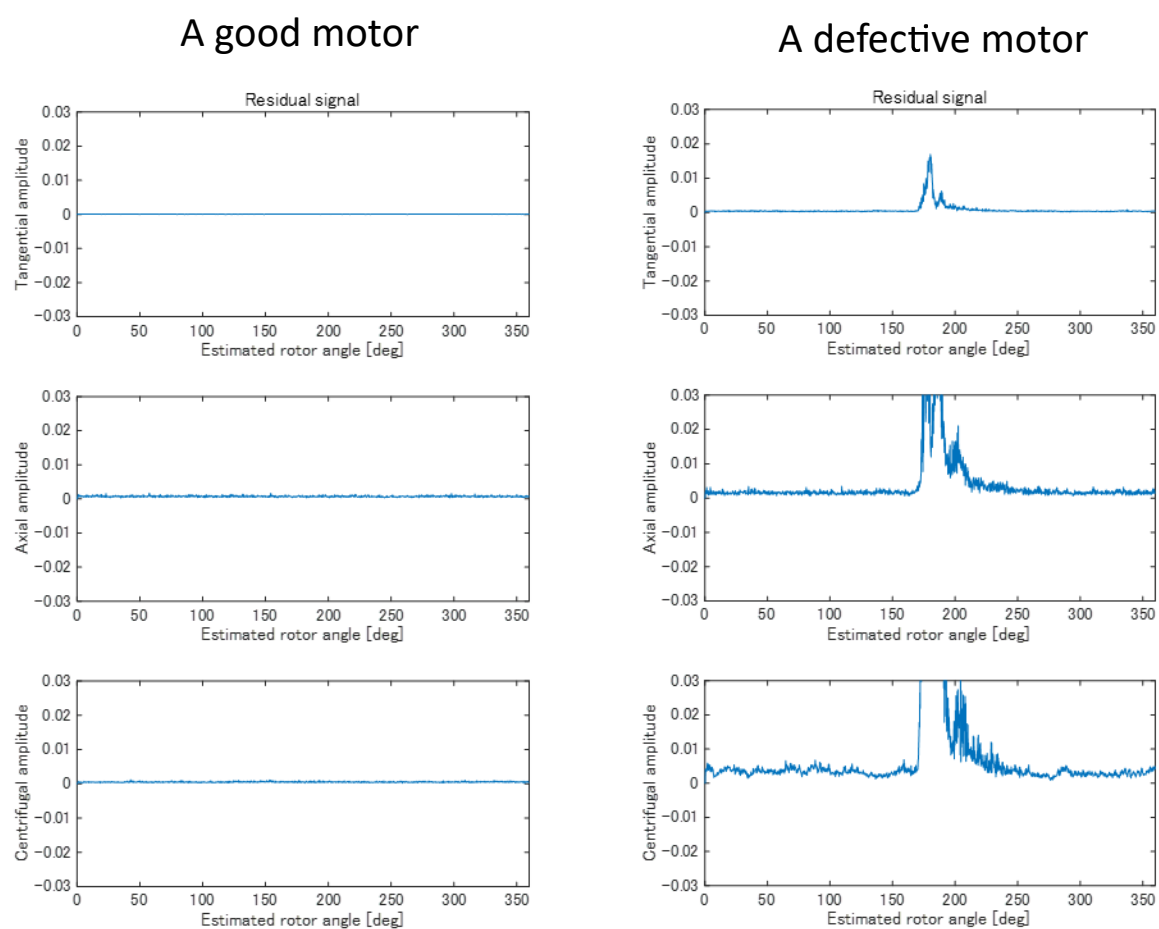


Fig. A.2: 擦れ振動検出の結果

謝辞

本研究の遂行及び本論文作成に際し終始多大なる御指導を賜った野呂雄一教授、本論文をご精読の上有用な御助言を頂いた竹尾隆特任教授、若林哲史教授に心より感謝の意を表します。ならびに実験機材の提供および実験内容の検討にご協力を賜った銀河電機工業株式会社の風間洋一郎氏、太田武志氏に深く感謝の意を表します。また、本研究のために備品の管理や技術指導を下さった山本好弘技術職員、測定治具の製作にご助力いただいた三重大学実習工場の担当者様並びに実験の補助をしていただいた院生、学部生諸氏に深く御礼申し上げます。

参考文献

- [1] 井手剛 “機械学習による異常検知” , コロナ社, pp.5-20, 2015.
- [2] 井手剛他 “異常検知と変化検知” , 講談社, pp.32-54, 2015.
- [3] 岡谷貴之 “深層学習” , 講談社, pp.110-112, 2015.
- [4] 近藤稔 “振動のオクターブバンド分析を用いた異常検知法による車両機器の診断” , 日本機械学会論文集, vol.84, 864, p. 17-00594, 2018.
- [5] 橋本渉他 “機械学習を用いた振動解析による自動車の異常振動検知” , DEIM2019 Forum 2019 D5-2, 2019.
- [6] 白井友貴他 “機械学習を用いたモータの異常検知” , 電気学会研究会資料. ST, pp.79-82, 2018.
- [7] Chapelle, Olivier. “Training a support vector machine in the primal” , Neural Computation, vol.19,5, pp.1155-1178, 2007.
- [8] 坂野鋭他 “怪奇!!次元の呪い-識別問題, パターン認識, データマイニングの初心者のために (前編)” , 情報処理, vol.43, 5, pp.562-567, 2002.
- [9] 坂野鋭他 “怪奇!!次元の呪い-識別問題, パターン認識, データマイニングの初心者のために (後編)” , 情報処理, vol.43, 6, pp.658-663, 2002.
- [10] 田中英晴 “電動機の騒音・振動と対策” , 山形県立産業技術短期大学校紀要, 16, pp.59-62, 2010.
- [11] 横塚勉 , “コンデンサモータの振動トルク特性” 電学誌, vol.91, 3, pp.501-510, 1971.
- [12] 吉桑義雄 “モータの電磁加振力発生要因と低減技術” 日本機械学会誌 vol.110, 1058, p62, 2007.
- [13] 野呂伸一他 “モータの騒音・振動とその低減対策” , NTS, pp.575-578, 2011.

- [14] 杉山高一他 “多変量データ解析,” 朝倉書店, pp.45-48, 2014.
- [15] 佐藤義治 “多変量データの分類”, 朝倉書店, pp.23-28, 2014.
- [16] 赤穂昭太郎 “カーネル多変量解析”, 岩倉書店, pp.12-56, 2008.
- [17] Sebastian Raschka “Python 機械学習プログラミング 達人データサイエンティストによる理論と実践”, インプレス, 2018.