

EMC 試験における AI の活用に関する研究（第 2 報） —放射イミュニティ試験における音からの誤動作検知—

浜野遼太郎・首藤高德・後藤和弘
電子・情報担当

Research on the use of AI in EMC testing (2nd Report) —Malfunction Detection from Sound in Radiated Immunity Testing—

Ryotaro HAMANO, Takanori SHUTO, Kazuhiro GOTO
Electronics and Information Technology Section

要 旨

EMC 試験の 1 つである放射イミュニティ試験では、強電界環境において、電子機器に誤動作が起きないかを長時間確認する必要がある、負担が大きいという問題がある。そこで、負担軽減と見逃し防止を目的として、音から、電子機器の誤動作が疑わしい状態を検知・通知させる、誤動作判断支援システムを開発する。本研究では、誤動作判断支援システムを実利用する際の課題を整理し、方針として、AI による教師無し学習、少量の学習データ、短時間の学習、少量の設定項目を立てた。そして、代表的な誤動作のシチュエーションに対して、AutoEncoder を用いた、再構成誤差による異常検知の手法検証を行い、誤動作が疑わしい状態の検知が可能であることを確認した。

1. 背景と目的

EMC 試験の 1 つに、試験対象に妨害波を照射し、誤動作が起きないことを確認する放射イミュニティ試験がある。この試験は、長時間にわたり電子機器の状態を監視しておく必要があり、試験の担当者の負担が大きい。

これに対し、山梨県産業技術センターの中村ら^{(1) (2) (3)}は、電波暗室内に設置されたカメラの映像に画像処理を施し、誤動作が疑わしい状態を検出・通知するアルゴリズムの検証とシステムの開発を行った。これにより、目視による誤動作監視の負担軽減が可能となった。

一方で映像の他に、<音>が監視対象として挙げられ、本研究では、AI によりこの問題の解決に取り組む。同時に、近年急速に発展する、AI についてのシーズを蓄積し、企業支援への活用を目指す。

2. 音からの誤動作検知の検証

この章では、まず、音から AI により、放射イミュニティ試験中の誤動作と疑わしい状態を検知（以下、誤動作検知）する上での課題と方針を整理する。そして、使用した手法を説明する。また、手法を検証するための、録音環境と代表的な誤動作のシチュエーションについて説明し、検証結果について考察する。

以降、正常動作時の音を正常音、それ以外、つまり誤動作時の音を異常音とする。

2.1 課題と方針

AI を活用した音からの放射イミュニティ試験中の誤動作検知における、実際の現場で利用する上での課題として次の 3 つが挙げられる。(1) 異常音の定義、(2) 学習データの録音のタイミング、(3) 誤動作判断支援システムの設定項目の量である。

1 つ目の、異常音の定義の課題は、異常音を一意に定義することが困難であるというものである。以下の 3 つに分けられる。誤動作時にどんな音が鳴るかわからない。試験対象の種類に応じて異常音の定義が異なる。誤動作は製品の開発者が決める。また、異常音の定義が困難なことに併せて、多くの場合、異常音を事前に録音することが困難である。

2 つ目の、学習データの録音のタイミングの課題は、AI の学習データをいつ録音するかというものである。候補は、試験前の打合せ段階と試験直前である。試験前の打合せ段階において事前に録音する場合は、試験を希望する担当者（多くの場合、製品の開発者）の負担を増やすこととなる。さらに、録音環境が、学習データ録音段階と評価段階で異なるため、学習データと評価データの分布が異なり、AI の予測性能向上の難易度が上がる。試験する環境に試験対象を送ることで、事前に学習データを録音することは可能だが、試験官の負担が増える。さらに、試験対象が一点物のケースでは、製品の開発者の

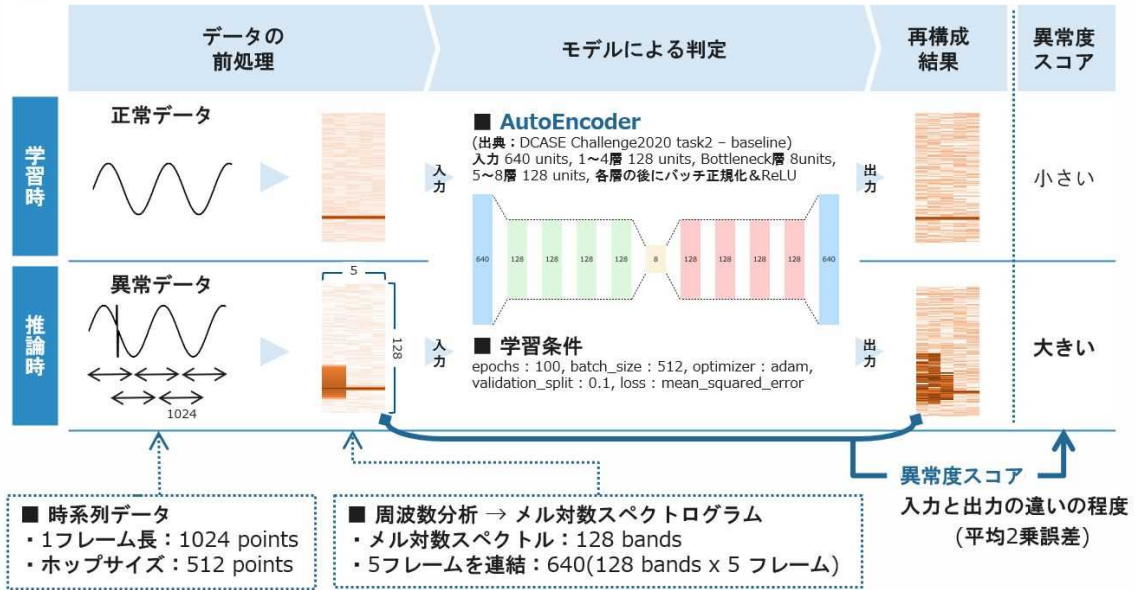


Fig.1 DCASE2020 challenge task2 baseline system の計算器

元から製品が離れるため、開発の時間に影響する。また、試験直前に試験環境で録音する場合、長時間学習データを取ることは、円滑な試験の妨げになる。この場合、学習データの録音時間に加え、計算器の学習時間も考慮する必要がある。前年度の取り組み（第1報⁽⁴⁾参照）では、10秒の音データの学習に3分を要した。

3つ目の、誤動作判断支援システムの設定項目の量の課題は、システムが設定項目を豊富に持つ場合、試験対象ごとの調整に手間がかかるというものである。

本研究では、3つの課題に対する方針として、教師無し学習を採用する。そして、試験直前に試験環境で学習データを録音し、そのデータで計算機を学習するため、学習データの録音時間を短くし、計算機の学習時間も短くすることで、試験時間への影響を少なくすることを目指す。また、システム上での設定項目を減らすことで、試験対象ごとの調整の手間を減らすことを目指す。

2.2 手法

2.1で示した方針を達成するため、本研究では、DCASE2020 challenge task2 から baseline system として提供されている、AutoEncoder ベースの異常度スコア計算器⁽⁵⁾を使用し、性能を検証する。計算器の全体像を Fig.1 に示す。このモデルは、入力層と出力層が 640次元のベクトルであり、音の時系列データからメル対数スペクトログラムへ特徴抽出したデータを扱う。この特徴抽出の工程は、前年度の取り組み⁽⁴⁾と大きく異なる点である。入力と再構成結果である出力の、平均二乗誤差を異常度スコアとしている。正常・異常の判定は、異常度スコアに対して、ユーザーが閾値を任意に設定することで実現し、異常の判定を持って、誤動作検知とする。



Fig.2 放射イミュニティ試験における録音環境

2.3 録音環境

録音環境の構成について述べる。Fig.2 に示す。録音用のマイクは、コロナ電子工業株式会社の光リンクマイクユニット COS-004 である。電波暗室内に設置する当該マイクの送信ユニットは、マイクに金属製のシールドが施されており強電界環境下でも動作が可能で、電波暗室外の受信ユニットへ、光信号で音の信号を伝達する。受信ユニットに届いた音の信号は、アナログ信号へと変換され、オーディオ出力端子からオーディオインターフェース (ZOOM H8) へ入力される。オーディオインターフェースは、録音用のパソコンに接続し、音の信号を音データとして保存する。その後、音データを機械学習用マシンへ取り込み、検証を行う。

機械学習用マシンのスペックは次の通りである。
CPU : Intel Xeon W-2223, RAM : 32GB, System drive : Samsung SSD 860 EVO 500GB, GPU : NVIDIA GeForce RTX 2080 Ti.

Table 1 代表的な誤動作のシチュエーションと
検証用データセットの内訳

	1. 瞬間的な異音 が 鳴る	2. モーターの回転音が 止まる	3. 周期的な音が 止まる	
正常動作時の 挙動と音	 音が鳴らない (無音)	 一定速度で回転する (ウーン)	 周期的に音が鳴る (ピッ!...ピッ!)	
誤動作時の 挙動と音	 瞬間的に音が鳴る (ピッ!)	 回転が止まる (無音)	 音が止まる (無音)	
想定する機器	電子機器全般	モーター等	電子機器全般	
検証用データセット	学習データ	3分 (18サンプル)	3分 (18サンプル)	3分 (18サンプル)
	正常データ	4分 (24サンプル)	2分30秒 (15サンプル)	9分10秒 (55サンプル)
	異常データ	8分10秒 (49サンプル)	3分 (18サンプル)	7分10秒 (43サンプル)

2.4 誤動作のシチュエーションと検証用データセット


誤動作検知の検証を行うにあたり、実際に誤動作を起こす機器を集めることは困難である。そこで、過去の試験事例から、代表的な誤動作のシチュエーションを3つ列挙し、正常動作と誤動作を模擬した音を作成して、2.3の録音環境で録音した音データを、検証用データセットとして用意する。その内容をTable 1に示す。

1つ目の、瞬間的な異音が鳴るケースは、正常動作時の試験対象からは音が鳴らず、無音であり、誤動作時に瞬間的な音が鳴るという想定である。想定する機器は、スピーカーを有するものや、リレーなどの電磁的スイッチを有するもの、ソレノイドやモーターなどのアクチュエーターを有するものなど、電子機器全般である。誤動作を模擬した音の録音時の環境をFig. 3 (a)に示す。スピーカーとマイクを向かい合わせに置き、スピーカーから音を出して録音する。スピーカーから鳴る音は、音の長さが200msの正弦波、周波数が50Hz-20kHzの範囲でランダムであり、音が鳴ってから10秒以内にランダムなタイミングで次の音が鳴るよう、プログラムで作成した音データである。正常動作時は、試験対象からは音は鳴らないが、録音データへはフロアノイズが記録される。これを、学習データと、評価データのうちの正常データとする。また、先ほどの自作の音データを録音し、これを評価データのうちの異常データとする。

2つ目の、モーターの回転音が止まるケースでは、正常動作時に一定の速度で回転するモーターが、誤動作時に回転を止める想定である。想定する機器はモーターを搭載した電子機器全般である。誤動作を模擬した音の録音時の環境をFig. 3 (b)に示す。DCモーター (TSUKASA ELECTRIC - TG-35B-AM-15-KA) に12Vの電圧を印加し、一定速度で回転させて、その音を録音して音データを作成する。これを、学習データと、評価データのうちの正



(a) 瞬間的な異音が鳴る, 周期的な音が止まる



(b) モーターの回転音が止まる

Fig. 3 誤動作を模擬した音の録音時の環境

常データとする。また、一定速度で回転するモーターへ印加する電圧出力を、別室から手で停止し、モーターが回転を止める際の音を録音し、これを評価データのうちの異常データとする。

3つ目の、周期的な音が止まるケースでは、正常動作時に試験対象から周期的に音が鳴り、誤動作時に音が止まるという想定である。想定する機器はスピーカーを有する電子機器 (例えば心電図モニター) 全般である。誤動作を模擬した音の録音時の環境は、1つ目と同じくFig. 3 (a)である。スピーカーから鳴る音は、音の長さが200ms、周波数が500Hz、音が鳴ってから2秒後に次の音が鳴る、プログラムで作成した音データである。正常動作時の想定としてこの音を録音し、学習データと、評価データのうちの正常データとする。また、音データの再生中に、プレーヤーの音量をリモートで制御し、100%と0%の2つの値を手動で切り替えて誤動作を模擬した音を作り、その音を録音して評価データのうちの異常データとする。

これらの録音した音データを検証用のデータセットとして使い、手法の検証を行う。音データは全て、サンプリングレート44.1kHz、量子化ビット数32bit、1チャンネル、PCM (IEEE) (float) のwavフォーマットで取り扱い、10秒を1サンプルとして、ファイルに分割して保存する。

2.5 結果と考察

サンプル単位の混同行列を Table 2 に、ROC 曲線 (Receiver Operating Characteristic 曲線：縦軸を真陽性率、横軸を偽陽性率として、閾値を変化させながらプロットして描いた曲線。) と AUC (Area Under Curve : ROC 曲線下部の面積。1 に近いほど計算機の予測性能が高く、0.5 に近いほど低いことを示す。) を Fig. 4 に、異常データの一例を、スペクトログラムと異常度スコアを重ねて Fig. 5 に示す。

1 つ目の、瞬間的な異音が出るシチュエーションについては、混同行列 (Table 2 (a)) の偽陽性率が 29.2%, AUC (Fig. 4 (a)) が 0.971 である。偽陽性率が約 30% と高いように思えるが、これは、サンプルごとの平均異常度スコアにより混同行列を求めたためである。詳細に説明する。Fig. 5 (a) の異常データのスペクトログラム上でレベルが大きくなっている (音が鳴っている) 間、異常度スコアが上昇しているのが確認できる。しかし、その時間が短いため、上昇した異常度スコアが、平均異常度スコアに与える影響は小さい。よって、正常音の平均異常度スコアのばらつきの影響により、サンプル単位の平均異常度スコアを閾値で正常と異常を完全に分離できず、偽陽性率が高い。平均異常度スコアではなく、異常度スコアを時系列で確認すると、Fig. 5 (a) に示す通り、時系列的に出力される異常度スコアに対して、閾値を設けることで、誤動作検知が可能である。

2 つ目の、モーターの回転音が出るシチュエーションについては、混同行列 (Table 2 (b)) の偽陽性率が 0%, AUC (Fig. 4 (b)) は 1 である。正常と異常を完全に判定することができている。Fig. 5 (b) を見ると、スペクトログラムにおいて、モーターの回転音を表す 500Hz 付近の信号レベルがなくなる、7 秒以降の区間で、異常度スコアが上昇していることが確認できる。閾値を設けることで誤動作検知が可能である。

3 つ目の、周期的な音が出るシチュエーションについては、混同行列 (Table 2 (c) -1) の偽陽性率が

Table 2 サンプル単位の混同行列 (サンプルごとに異常度スコアの平均を計算し、それを平均異常度スコアとして混同行列を求める。平均異常度スコアの閾値は、真陽性率が 100% になる値を選ぶ。)

(a) 瞬間的な異音が出る

		AIの予測結果		陽性率
		正常 (陰性)	異常 (陽性)	
評価データ	正常音	17 (真陰性)	7 (偽陽性)	29.2% (偽陽性率)
	異常音	0 (真陰性)	49 (真陽性)	100% (真陽性率)

(b) モーターの回転音が出る

		AIの予測結果		陽性率
		正常 (陰性)	異常 (陽性)	
評価データ	正常音	15 (真陰性)	0 (偽陽性)	0% (偽陽性率)
	異常音	0 (真陰性)	18 (真陽性)	100% (真陽性率)

(c) -1 周期的な音が出る

		AIの予測結果		陽性率
		正常 (陰性)	異常 (陽性)	
評価データ	正常音	2 (真陰性)	53 (偽陽性)	96.4% (偽陽性率)
	異常音	0 (真陰性)	44 (真陽性)	100% (真陽性率)

(c) -2 周期的な音が出る (フレーム連結数を 5→201)

		AIの予測結果		陽性率
		正常 (陰性)	異常 (陽性)	
評価データ	正常音	24 (真陰性)	31 (偽陽性)	56.3% (偽陽性率)
	異常音	0 (真陰性)	32 (真陽性)	100% (真陽性率)




Fig. 4 シチュエーションごとの ROC と AUC (赤点は対応する混同行列の陽性率を示す)

96.4%, AUC (Fig.4 (c) -1) が 0.570 である. ROC を見ると, 対角線, つまりランダム計算器の特性に近い. よって, 実用的な計算器とは言えない. この原因としては, Fig.1 で示した計算器の構成のうち, 特徴抽出後に AutoEncoder の入力データとして扱う, メル対数スペクトログラムの時間方向の幅が小さいことが挙げられる. 入力データとして扱う, メル対数スペクトログラムの時間の幅は, データの前処理の1フレーム長 1024points, ホップサイズ 512points, フレーム連結数 5 フレーム, そして, 音データのサンプリングレート 44.1kHz から, 約 69.7ms となる. この時間は, 音が鳴る周期が 2 秒の音データから, 2 秒の周期という特徴を抽出するには非常に短い. よって, この計算器は, 音が鳴らない区間を正常として学習しており, 異常データの音が鳴らない区間をすべて正常と判定している. このケースに対しては, メル対数スペクトログラムの時間幅を広げることが有効だと考えられる. そこで, 時間幅を約 69.7ms から約 2.3s へと変更し, 検証した結果を次に述べる. Fig.1 の計算器の構成のうち, 特徴抽出のフレーム連結数 5 を 201 に変更して再度検証した. 結果は, 混同行列 (Table 2 (c) -2) の偽陽性率が 56.3%, AUC (Fig.4 (c) -2) が 0.945 となり, 大幅に改善された. 偽陽性率が高いように思えるが, 検証結果の1つ目の偽陽性率の考察と同様の理由である. Fig.5 (c) -2 のスペクトログラムと異常度スコアについて確認すると, 音が止まった時間領域で異常度スコアが上昇していることが確認できる (サンプル 10 秒間のスペクトログラムに対して, 異常度スコアの前後約 1 秒がないのは, フレーム連結数が増えたためである.) よって, 閾値を設けることで誤動作検知が可能である.

Table 3 に, シチュエーションごとの計算時間と AUC と検証結果を示す. 2.1 の方針で掲げた, 学習データの録音時間を短くすることについては, 3 分間の録音を学習データとして用いることで, 誤動作検知が可能である. この時間は実用的な範囲であると考え. 次に, 計算器の学習時間を短くすることについては, 3 分の学習データに対する学習時間が, フレーム連結数 5 では平均約 1 分, フレーム連結数 201 では 8 分強である. 一部のケースを除いて, 実用的な範囲であると考え. 次に, 2.1 の課題で触れた, 前年度の取り組みの課題⁽⁴⁾である, 学習時間の短縮については, 2.2 の手法で触れた特徴抽出により大幅に改善された. また, 評価時間について見ると, いずれのケースでも評価データの再生時間に対して評価時間が短く, リアルタイムでの誤動作検知が可能である. フレーム連結数を多くすると, 計算時間が増える点については, データの前処理 (1 フレーム長, ホッ

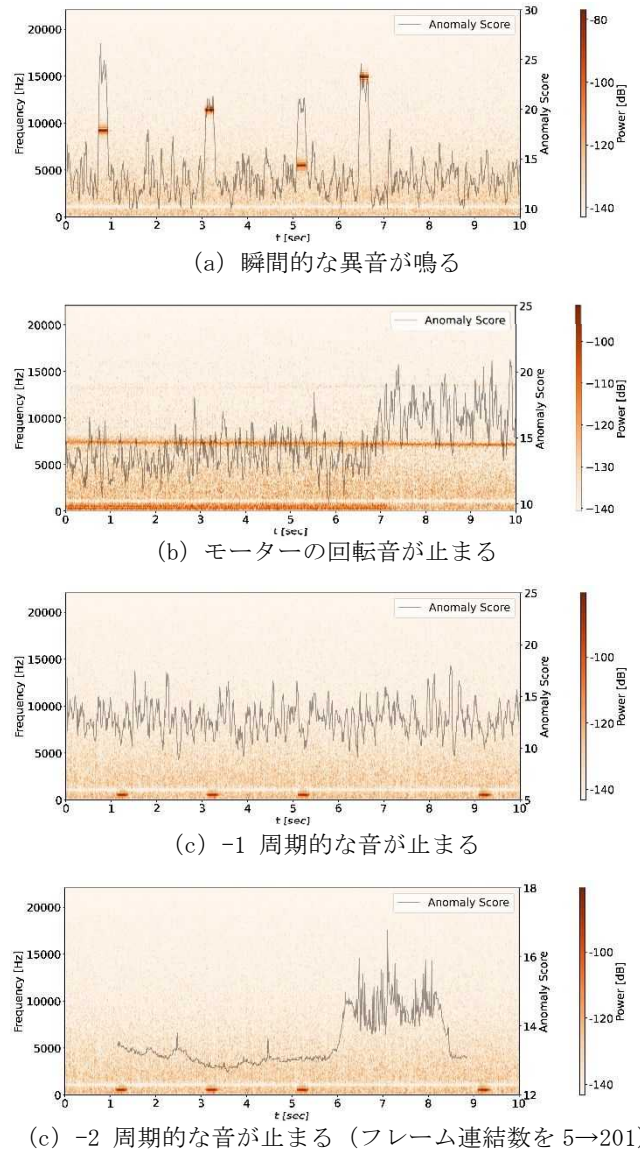


Fig.5 異常データの一例 (サンプルのスペクトログラムと異常度スコア (黒線))

Table 3 シチュエーションごとの計算時間と AUC と検証結果

	1. 瞬間的な異音が鳴る	2. モーターの回転音が止まる	3. 周期的な音が止まる	
シチュエーション				
フレーム連結数	5		201	
学習データ	3分			
学習時間	56秒	1分7秒	1分3秒	8分26秒
評価データ	12分10秒		16分20秒	
評価時間	7秒	12秒	17秒	49秒
AUC	0.971	1.000	0.570	0.945
検証結果	検知可	検知可	検知不可	検知可

プサイズ, メル対数スペクトルのバンド数) の最適化や, GPU のアップグレードによる計算能力の向上により改善

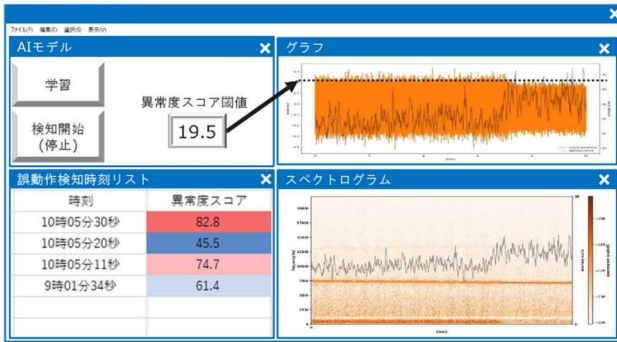


Fig. 6 誤動作判断支援システムのイメージ

可能であると考え、今後の課題とする。また、2.1の方針の、設定項目を減らすことについては、誤動作検知をするにあたり、設定する必要があるのは主に異常度スコアの閾値（ケースに応じてフレーム連結数）のみであるため、達成できると考える。

この異常度スコア計算器を用いた、誤動作判断支援システムの開発を進めている。イメージ図を Fig. 6 に示す。操作をシンプルとすることを目指し、モデル学習と検知開始ボタン、異常度スコアの閾値設定程度の配置を想定している。検知を開始すると、録音データと共に異常度スコアがリアルタイムで表示され、異常度スコアが閾値を超えると、各種情報がリストに記録される想定である。

3. まとめ

本研究では、誤動作判断支援システムを実利用する際の課題を整理し、方針として、AIによる教師無し学習、少量の学習データ、短時間の学習、少量の設定項目を立てた。そして、代表的な誤動作のシチュエーションに対して、AutoEncoder を用いた、再構成誤差による異常検知の手法検証を行い、誤動作検知が可能であることを確認した。現在、誤動作判断支援システムの開発を進めている。

今後は、実試験での活用を進めつつ、併せて、対応するシチュエーションを増やすため、データの特徴抽出の再検討や、LSTM など、別の計算器の性能検証に取り組む予定である。また、企業現場の異常検知などの課題解決のため、蓄積したシーズを活用し、企業支援につなげる。

謝辞

AI に関するご助言をいただいた、北海道大学大学院情報科学研究院 情報理工学部門複合情報工学分野調和系工学研究室 准教授 札幌 AI ラボ テクニカルメンバー 山下倫央先生に深謝する。

映像からの誤動作判断支援システムのデモプログラムと関連資料をご提供いただいた、山梨県産業技術センター 甲府技術支援センター 電子・システム技術部 電子応用科 中村卓氏に深謝する。

参考文献

- (1) 中村卓, 木島一広, 清水章良, 河野裕. イミューニティ試験における誤動作判断支援システムの開発. 平成 28 年度山梨県工業技術センター研究報告, pp. 74-77, (2017).
- (2) 中村卓, 木島一広, 清水章良, 小谷信司. イミューニティ試験におけるモータの回転数変化検出手法. 電気学会論文誌 C (電子・情報・システム部門誌). 138 巻, 11 号, pp. 1375-1383, (2018).
- (3) 中村卓, 木島一広, 清水章良, 小谷信司. イミューニティ試験における誤動作判断支援システムの開発 (第 2 報). 平成 29 年度山梨県工業技術センター研究報告, (2018).
- (4) 浜野遼太郎, 首藤高德, 後藤和弘. EMC 試験における AI の活用に関する研究 (第 1 報). 令和 3 年度大分県産業科学技術センター研究報告, (2022).
- (5) Yuma Koizumi, Yohei Kawaguchi, Keisuke Imoto, Toshiki Nakamura, Yuki Nikaido, Ryo Tanabe, Harsh Purohit, Kaori Suefusa, Takashi Endo, Masahiro Yasuda, and Noboru Harada. Description and discussion on DCASE2020 challenge task2: unsupervised anomalous sound detection for machine condition monitoring. In Proceedings of the Detection and Classification of Acoustic Scenes and Events 2020 Workshop (DCASE2020), pp. 81-85, (2020).