

# 多クラス分類器とその中間層出力の再構成器を用いた異常音検知の検討

松本 啓汰<sup>†</sup> 山田 武志<sup>†</sup> 牧野 昭二<sup>††</sup>

<sup>†</sup> 筑波大学大学院システム情報工学研究群 〒305-8573 茨城県つくば市天王台 1-1-1

<sup>††</sup> 早稲田大学大学院情報生産システム研究科 〒808-0135 福岡県北九州市若松区ひびきの 2-7

E-mail: <sup>†</sup>{s2220642@s, takeshi@cs}.tsukuba.ac.jp, <sup>††</sup>s.makino@waseda.jp

**あらまし** 近年、正常音データのみを用いる教師なし学習によって、未知の異常音を検出する技術が求められている。現在主流となっているのは、正常音データの再構成に基づく手法である。この手法は、オートエンコーダを用いて入力データを再構成し、その再構成誤差を異常スコアとすることで異常検知を行う。また、学習時に仮想的な異常音データを用意することを前提に、正常・異常の二値分類器と潜在空間上の距離学習を組み合わせた手法が提案された。この手法では正常音と仮想的な異常音データを用いて二値分類器を学習するが、潜在空間上における正常、異常それぞれのクラス重心に基づく指標を損失関数と異常スコアに組み込んでいる。本稿では、これらの手法を統合してさらなる性能向上を目指す。具体的には、多クラス分類器、潜在空間上の距離学習、中間層出力の再構成器を組み合わせた手法を提案する。異常音検知のタスクである DCASE2020 Task2 を用いて実験を行った結果、提案手法が有効であることを確認した。

**キーワード** 異常音検知, 多クラス分類器, 再構成器, 距離学習

## Anomalous sound detection using multi-class classifier and reconstructor of its intermediate layer output

Keita MATSUMOTO<sup>†</sup>, Takeshi YAMADA<sup>†</sup>, and Shoji MAKINO<sup>††</sup>

<sup>†</sup> Degree Programs in Systems and Information Engineering, University of Tsukuba  
1-1-1 Tennodai, Tsukuba, Ibaraki, 305-8573 Japan

<sup>††</sup> Graduate School of Information, Production and System, Waseda University  
2-7 Hibiino, Wakamatsu-ku, Kitakyushu, Fukuoka, 808-0135 Japan

E-mail: <sup>†</sup>{s2220642@s, takeshi@cs}.tsukuba.ac.jp, <sup>††</sup>s.makino@waseda.jp

**Abstract** In recent years, there has been a growing demand for techniques to detect unknown anomalous sounds by unsupervised learning using only normal sound data. Currently, the most popular method is based on reconstruction of normal sound data. This method uses an autoencoder to reconstruct the input data, and uses the reconstruction error as the anomalous score for anomalous detection. A method combining a binary classifier for normal/anomaly and distance learning in the latent space was recently proposed, assuming that virtual anomalous sound data is prepared at the time of learning. This method learns a binary classifier using normal and virtual anomalous sound data, and incorporates an index based on the center of gravity of the normal and anomalous classes in the latent space into the loss function and anomalous score. In this paper, we integrate these methods to further improve performance. Specifically, we propose a method that combines a multi-class classifier, distance learning on the latent space, and a reconstructor of the intermediate layer output. Experimental results using DCASE2020 Task 2, a task for anomalous sound detection, confirm the effectiveness of the proposed method.

**Key words** anomalous sound detection, multiclass classifier, reconstructor, metric learning

### 1. はじめに

近年、機械の状態監視とその自動化において異常音検知 (ASD: Anomalous Sound Detection) が重要となっている。異常音検知

とは、特定の機械やモノが発する音が正常音であるか異常音であるかを識別することである。ここで異常音とは、機械の誤動作や故障によって生じる音のことを指す。工場の設備が正常に動作しているときは、異常音はほとんど発生せず、一方、異常

音が発生するときは、異常の内容に応じて異常音の種類も多様であるため、網羅的に異常音を収集することは極めて難しい。また、意図的に機械を故障させ異常音を収集することはコストがかかる。そのため、ASDでは正常音のみを用いた教師なし学習によって未知の異常音を検出することが求められている。

最近主流となっているのは、正常音データの再構成に基づく手法[1]である。この手法は、オートエンコーダを用いて正常音データを再構成できるように、正常音データのみを用いて学習する。テスト時にはテストデータの再構成誤差を異常スコアとすることで異常検知を行う。この手法において再構成の対象とするのは主に周波数スペクトログラムであるが、正常音データの再構成でさえ難しいという課題が存在する。

また、学習時に仮想的な異常音データを用意することを前提に、正常・異常の二値分類器と潜在空間上の距離学習を組み合わせた手法[2]が提案された。この手法では、対象外である様々な機械の正常音を仮想的な異常音データとして二値分類器を学習する。その際、潜在空間上における正常、異常それぞれのクラス内分散、クラス間分散に基づく指標を損失関数に組み込んでいる。異常スコアを測るため、二値分類器の出力結果、潜在空間上での正常クラスとの距離を併用することにより、高精度の異常音検知を実現した。

本稿では、これらの手法を統合してさらなる性能向上を目指す。具体的には、多クラス分類器、潜在空間上の距離学習、中間層出力の再構成器を組み合わせた手法を提案する。未知の異常音を検出するというタスクである DCASE2020 [3] の Task2 を用いて、提案手法の有効性を検証する。

## 2. 従来の異常音検知手法

### 2.1 周波数スペクトログラムの再構成に基づく手法

異常音検知のタスクである DCASE2020 Task2 のベースライン手法[1]について説明する。この手法は合計 10 層の Dense 層からなるオートエンコーダに固定時間長の周波数スペクトログラムを入力し、再構成誤差を最小化するように正常音データのみを用いて学習する。学習後、テストデータを入力して再構成し、異常スコアとして再構成誤差を計算する。このとき、学習に用いていない異常音データは上手く再構成できず、異常スコアが大きくなるという仮定に基づいて異常検知を行う。DCASE2020 Task2 に提出された手法の内、約 6 割がオートエンコーダを用いたものである。

この手法の課題としては、高次元である周波数スペクトログラムの再構成自体が難しいことや、入力時間長が固定化されてしまうことが挙げられる。

### 2.2 二値分類器と潜在空間上の距離学習を組み合わせた手法

二値分類器と潜在空間上の距離学習を組み合わせた手法[2]について説明する。この手法の概要を図 1 に示す。この手法は対象である機械の正常音を正常データとして、対象外である機械の正常音を仮想的な異常データとして扱い、BCE (Binary Cross Entropy) を用いて二値分類器を学習する[4]。その際に、ネットワークの中間層出力に制約を与えるために DDCSAD (Deep

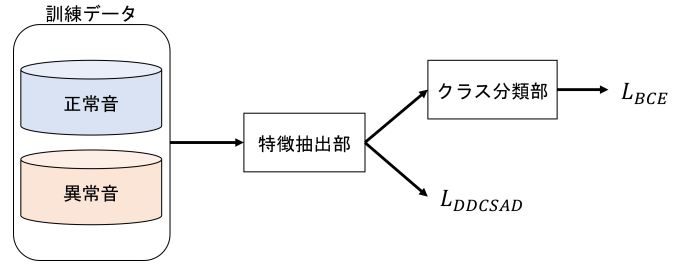


図 1 二値分類器と潜在空間上の距離学習を組み合わせた手法 [2] の概要

Double-Centroids Semi-supervised Anomaly Detection) と呼ぶ損失関数を導入している。DDCSAD 損失関数を式 (1) に示す。

$$L_{DDCSAD} = \frac{1}{N} \sum_{i=1}^N (\|z_i - c_p\|^{2y_i} + \|z_i - c_n\|^{-2y_i}) \quad (1)$$

ここで、 $N$  はバッチサイズ、 $z_i$  は  $i$  番目のデータの中間層出力、 $c_p$ 、 $c_n$  はそれぞれ潜在空間上における正常、異常クラスの重心、 $y_i$  は各データの正解ラベル (1: 正常音, -1: 異常音) を示している。正常データに対しては、正常クラスの重心との差  $\|z_i - c_p\|$  の 2 乗と、異常クラスの重心との差  $\|z_i - c_n\|$  の -2 乗をそれぞれ最小化する。一方で異常データに対しては、異常クラスの重心との差  $\|z_i - c_n\|$  の 2 乗と、正常クラスの重心との差  $\|z_i - c_p\|$  の -2 乗をそれぞれ最小化する。つまり、正常、異常それぞれのクラス内分散を最小化、クラス間分散を最大化することに相当する。 $c_p$ 、 $c_n$  の初期値はランダムに設定し、各エポックにおいて学習データ全体を用いて再計算し更新する。

この手法における学習時の損失関数を式 (2) に示す。

$$L = L_{BCE} + \lambda L_{DDCSAD} \quad (2)$$

ここで、 $L_{BCE}$  は BCE である。また、 $\lambda$  は損失関数間のバランスを制御するハイパーパラメータであり、 $\lambda = 1.0$  と設定されている。

異常スコアの算出には式 (3) が用いられる。

$$s = \eta(1 - p) + (1 - \eta)d' \quad (3)$$

ここで、 $p$  は正常音クラスである事後確率、 $\eta$  は事後確率と重心からの距離のバランスを決めるハイパーパラメータである。また  $d'$  は、中間層出力と正常クラスの重心との距離  $d = \|z - c_p\|^2$  を計算し、データ全体で標準化 (最大値 1, 最小値 0) したものである。

## 3. 提案手法

### 3.1 提案手法の概要

本稿では、2.1 節と 2.2 節で説明した手法を統合してさらなる性能向上を目指す。具体的には、多クラス分類器、潜在空間上の距離学習、中間層出力の再構成器を組み合わせた手法を提案する。




図2 提案手法の概要

2.1 節で述べた周波数スペクトログラムの再構成に基づく手法の課題を解決するため、別のデータ表現であるニューラルネットワークの中間層出力（潜在表現）に着目する。中間層出力は周波数スペクトログラムよりも次元が少なく、また出力層に近い位置ではタスクを解くために必要な情報が抽出されていると考えられる。さらには、再帰型ニューラルネットワークを用いることにより、入力の実時間長を可変にすることが可能となる。異常画像検知の分野では、画像への幾何学変換を予測するニューラルネットワークの中間層出力を異常画像検知の各層の入力とすることで、少数の異常データを学習に用いた場合の精度に向上が見られた [5]。一方、2.2 節で述べた二値分類器と潜在空間の距離学習を組み合わせた手法 [2] では、潜在空間上で距離学習を行っているため、両者の相性は良いと期待できる。

図2に提案手法の概要を示す。提案手法は、分類器とオートエンコーダからなる。提案手法の学習手順について説明する。まず、学習データを用いて分類器を学習する。ここで、学習データは正常音と仮想的な異常音である。なお、後述する実験では、異常音として同じ機械の別個体の正常音や他の機械の正常音を用いた。学習の際には、潜在空間上の距離学習を組み合わせる。次に、分類器の中間層出力を再構成するオートエンコーダを学習する。この学習は学習済みの分類器を用いて行う。オートエンコーダは各機械の個体ごとに用意し、学習にはそれぞれの正常音の中間層出力のみを用いる。

次に提案手法における異常スコアについて説明する。異常スコアには、式 (3) に加えて、オートエンコーダの再構成誤差を用いる。この異常スコアを式 (4) に示す。

$$s = \alpha(1 - p) + \beta d' + \gamma r' \quad (4)$$

ここで、 $r'$  は再構成誤差を個体ごとの全データで標準化（最大値 1、最小値 0）したもの、 $\alpha$ 、 $\beta$ 、 $\gamma$  はバランスを決めるハイパーパラメータである。

### 3.2 多クラス分類への拡張

提案手法では、2.2 節の二値分類を多クラス分類へ拡張する。多クラス分類へ拡張することで、二値分類の場合には大きな分布を持つ異常クラスを、複数の小さな分布として学習することが可能となる。

式 (1) の DDCSAD 損失関数を元に、多クラス分類へ拡張した損失関数を式 (5) に示す。

$$L_{MULTI} = \frac{1}{N} \sum_{i=1}^N \sum_{j=1}^M \|z_i - c_j\|^{2y_{ij}} \quad (5)$$

ここで、 $N$  はバッチサイズ、 $M$  はクラス数、 $z_i$  は  $i$  番目のデー

表1 実験データの概要

機械の種類 (個体数)	valve (4), slider (4), pump (4), fan (4), ToyCar (4), ToyConveyor (3)
長さ	10 秒
チャンネル数	1
サンプリングレート	16kHz
学習用データ数	約 1000 個/1 個体 (正常音データ)
テスト用データ数	約 100 個/1 個体 (正常音データ) 約 200 個/1 個体 (異常音データ)

タの中間層出力、 $c_j$  は  $j$  番目のクラスの重心、 $y_{ij}$  は正解ラベル (1:  $i$  番目のデータがクラス  $j$  に属する, -1:  $i$  番目のデータがクラス  $j$  に属さない) を示している。この損失関数は、多クラス分類においてクラス内分散最小化、クラス間分散最大化を行うことに相当する。

多クラス分類器の学習の際には次の損失関数を用いる。

$$L = L_{CCE} + \lambda L_{MULTI} \quad (6)$$

ここで、 $L_{CCE}$  は CCE (Categorical Cross Entropy) である。また、 $\lambda$  は損失関数間のバランスを制御するハイパーパラメータであり、 $\lambda = 1.0$  とする。

## 4. 実験

### 4.1 実験データ

表1は実験に用いるデータであり、DCASE2020 Task2 の Development dataset と同じものである。この音響データは ToyCar, ToyConveyor の 2 種類のおもちゃの動作音 [6] と、valve, slider, pump, fan の 4 種類の機械の動作音 [7] からなる。テスト用データの異常音は対象機械を意図的に破損させて収録したものである。この音響データは、録音した機械音と、複数の実際の工場環境で録音された環境音を重畳して生成されている。各機械には 3 個または 4 個の個体があり、合計で 23 個の個体がある。そのため、多クラス分類を行う際のクラス数は 23 となる。

### 4.2 評価指標

DCASE2020 Task2 において、性能を評価する指標として受信者動作特性 (ROC) 曲線の AUC (Area Under Curve) と部分的 AUC (pAUC) を用いる。AUC は式 (7)、pAUC は式 (8) で定義される。

$$AUC = \frac{1}{N_- N_+} \sum_{i=1}^{N_-} \sum_{j=1}^{N_+} \mathcal{H}(\mathcal{A}_\theta(x_j^+) - \mathcal{A}_\theta(x_i^-)) \quad (7)$$

$$pAUC = \frac{1}{\lfloor pN_- \rfloor N_+} \sum_{i=1}^{\lfloor pN_- \rfloor} \sum_{j=1}^{N_+} \mathcal{H}(\mathcal{A}_\theta(x_j^+) - \mathcal{A}_\theta(x_i^-)) \quad (8)$$

ここで  $N_-$  と  $N_+$  はそれぞれ正常、異常のデータ数、 $\mathcal{A}_\theta(x)$  は異常スコア、 $x_i^-$  と  $x_j^+$  はそれぞれ正常、異常のテストデータ、 $\mathcal{H}(x)$  は  $x > 0$  のときに 1、それ以外ときに 0 を返す関数、 $\lfloor \cdot \rfloor$  はフロアリング関数、 $p$  は偽陽性率の範囲を制限するパラメー

FC1	- Dense(512, 512)
FC2	- Dense(512, 512)
FC3	- Dense(512, 512)
FC4	- Dense(512, 512)
FC5	- Dense(512, 512)
FC6	- Dense(512, 512)
FC7	- Dense(512, 128)
FC8	- Dense(128, 2) (二値分類の場合) - Dense(128, 23) (多クラス分類の場合)

図3 分類器のネットワーク

表2 分類器の実験条件

入力特徴量	OpenL3 [8] の埋め込みベクトル
最適化手法 (学習係数)	Adam [9] (0.001)
損失関数	$L_{BCE} + \lambda L_{DDCSAD}$ (二値分類の場合) $L_{CCE} + \lambda L_{MULTI}$ (多クラス分類の場合)
エポック数	50
バッチサイズ	64

タで, DCASE2020 Task2 では  $p = 0.1$  とされている.

AUC は  $\mathcal{A}_\theta(x_j^+) > \mathcal{A}_\theta(x_i^-)$  である確率を求めている. つまり正常データの異常スコアより異常データの異常スコアが大きい確率であり, 正しく分類できている確率に相当する. pAUC は偽陽性率 (FPR: False Positive Rate) の範囲を  $[0, p]$  とした時の AUC である. 閾値が低い場合, 異常音を正しく異常であると識別する真陽性率 (TPR: True Positive Rate) は高くなるが, 正常音を誤って異常であると識別する偽陽性率も高くなってしまふ. 一方で閾値が高い場合, 真陽性率と偽陽性率が低くなってしまふ. 理想的なシステムは偽陽性率が低い条件下で真陽性率が高いシステムである. そのため偽陽性率の範囲を  $[0, p]$  に制限した pAUC を用いる.

### 4.3 実験条件

DCASE2020 Task2 を用いて実験し, 提案手法の有効性を評価する. このタスクは学習データとして各機械の正常音のみを用いるという条件下で, 未知の異常音を検知するものである.

本実験では, クラス分類として二値分類と多クラス分類の2種類, 異常スコアとして式 (3) の異常確率と距離を用いるもの, 再構成誤差を用いるもの, 式 (4) の異常確率と距離と再構成誤差を用いるものの3種類, すなわち計6種類の組み合わせ手法を比較する. なお, 異常スコアの式におけるハイパーパラメータ  $\eta, \alpha, \beta, \gamma$  の値は, 0.0 から 1.0 まで 0.1 ずつ変化させ, 最も pAUC の値が高いものとした.

本実験で用いた分類器のモデルは図3に示すように, 8層の全結合層で構成され, 各ユニット数は [512, 512, 512, 512, 512, 512, 128, 2 (二値分類の場合) or 23 (多クラス分類の場合)] である. 分類器の実験条件を表2に示す. OpenL3 [8] は1枚の画像と1秒の音声に対応しているかを大量のデータを用いて事前に学習したモデルである. 本実験で用いる10秒のデータに対して256ピンのメル変換を施し, 分析窓長1秒, ホップサイズ

FC1	- Dense(512, 128) - Batch Normalization - ReLU	FC6	- Dense(8, 128) - Batch Normalization - ReLU
FC2	- Dense(128, 128) - Batch Normalization - ReLU	FC7	- Dense(128, 128) - Batch Normalization - ReLU
FC3	- Dense(128, 128) - Batch Normalization - ReLU	FC8	- Dense(128, 128) - Batch Normalization - ReLU
FC4	- Dense(128, 128) - Batch Normalization - ReLU	FC9	- Dense(128, 128) - Batch Normalization - ReLU
FC5	- Dense(128, 8) - Batch Normalization - ReLU	FC10	- Dense(128, 512)

図4 オートエンコーダのネットワーク

表3 オートエンコーダの実験条件

入力特徴量	クラス分類器の FC6 の中間層出力
最適化手法 (学習係数)	Adam(0.001)
損失関数	Mean Squared Error
エポック数	100
バッチサイズ	512

100ms に区切って OpenL3 に入力する. こうして得られた 512 次元, 96 フレームの特徴量を, 1 フレームずつ分類器に入力し学習する. また, 損失関数  $L_{BCE}$  は Binary Cross Entropy,  $L_{CCE}$  は Categorical Cross Entropy,  $L_{DDCSAD}$  は式 (1),  $L_{MULTI}$  は式 (5) である.  $L_{DDCSAD}$  と  $L_{MULTI}$  の各クラスの重心  $c_p, c_n, c_j$  は文献 [2] に倣ってランダムに初期化し, エポック毎に全学習データで再計算する. また  $\lambda = 1$  と設定する. 二値分類では個体毎に分類器を用意し, 合計 23 個の分類器を学習する. 一方, 多クラス分類では合計 1 個の分類器を学習する.

オートエンコーダのネットワークは図4に示すように, DCASE2020 Task2 のベースライン手法 [1] と同様に 10 層の全結合層からなる. オートエンコーダの実験条件を表3に示す. オートエンコーダに入力する中間層出力には, 分類器の6層目の出力を用いる. オートエンコーダによる異常スコアの計算法について説明する. 分類器によって10秒のデータが512次元, 96フレームの中間層出力となる. オートエンコーダに96フレームを1フレームずつ入力し, それぞれ再構成誤差を求める. これらの再構成誤差の平均を10秒全体に対する異常スコアとする.

### 4.4 実験結果と考察

クラス分類として二値分類と多クラス分類, 異常スコアとして異常確率と距離を用いるものと再構成誤差を用いるものからなる, 計4種類の手法の pAUC を表4に示す.

まずクラス分類について考察する. 異常スコアに異常確率と距離を用いる手法に注目すると, 多クラス分類よりも二値分類を用いる手法の pAUC が高かった. 一方, 異常スコアに再構成誤差を用いる手法に注目すると, 二値分類と多クラス分類の pAUC は同程度であった. 3.2 節で述べたように, 多クラス分類へと拡張することで各クラスの分布をより小さくすることを狙ったものの, 実際にはクラス数の増加により  $L_{MULTI}$  が複

表4 4手法の pAUC (%)

機械の種類	二値分類		多クラス分類	
	異常確率と距離	再構成誤差	異常確率と距離	再構成誤差
valve	75.84	57.49	68.53	60.18
slider	72.89	69.85	72.49	75.02
pump	74.26	69.10	73.23	65.55
fan	68.69	61.91	64.50	57.59
ToyCar	76.10	54.15	71.68	54.86
ToyConveyor	51.91	51.67	52.25	51.92
average	69.95	60.70	67.11	60.85

表5 従来手法と提案手法の pAUC (%)

機械の種類	二値分類		多クラス分類
	(従来手法) 異常確率と距離	(提案手法) 異常確率と距離, 再構成誤差	(提案手法) 異常確率と距離, 再構成誤差
valve	75.84	77.61	68.66
slider	72.89	73.14	77.00
pump	74.26	77.63	73.68
fan	68.69	68.79	64.51
ToyCar	76.10	76.11	71.73
ToyConveyor	51.91	52.05	52.45
average	69.95	70.89	68.01

雑化し、学習がやや不安定になったと考えられる。これについては、今後さらなる検討が必要である。

次に異常スコアについて考察する。表4からは再構成誤差を用いる手法より、異常確率と距離を用いる手法の方が pAUC が高いことが確認できる。オートエンコーダの学習に用いるデータは、学習済みの分類器の中間層出力であり、これはオートエンコーダで再構成しやすいとは限らない。解決策としては、クラス分類器とオートエンコーダのネットワークを連結して End to End 学習することが考えられる。

最後に、クラス分類に二値分類、異常スコアに異常確率と距離を用いる手法（従来手法）と、異常スコアに異常確率と距離、再構成誤差を用いる手法（提案手法）の pAUC を表5に示す。表5からは、クラス分類に二値分類、異常スコアに異常確率と距離、再構成誤差を用いる手法の pAUC が最も高いことが分かる。つまり、識別器のみでは捉えられない正常、異常の差をオートエンコーダを用いて捉えることが可能になったと考えられる。

## 5. おわりに

本稿では、多クラス分類器、潜在空間上の距離学習、中間層出力の再構成器を組み合わせた異常音検知手法を提案した。異常音検知のタスクである DCASE2020 Task2 を用いて実験を行った結果、多クラス分類器の学習がやや不安定であったものの、異常スコアとして異常確率と距離、再構成誤差を併用することが有効であることを確認した。

謝辞 本研究は JSPS 科研費 20K11880 の助成を受けた。

## 文 献

- [1] DCASE2020 task2 baseline, [https://github.com/y-kawagu/dccase2020\\_task2\\_baseline](https://github.com/y-kawagu/dccase2020_task2_baseline)
- [2] I. Kuroyanagi, T. Hayashi, K. Takeda, T. Toda, “Anomalous sound

detection using a binary classification model and class centroids,” Proc. EUSIPCO, pp. 1995-1999, Aug. 2021.

- [3] DCASE2020 Website, <http://dcase.community/challenge2020/>
- [4] P. Primus, V. Hauns Schmid, P. Praher, G. Widmer, “Anomalous sound detection as a simple binary classification problem with careful selection of proxy outlier examples,” Proc. DCASE, pp. 170-174, Nov. 2020.
- [5] 岡野弘野, 鈴木雅大, 松尾豊, “深層ニューラルネットワークの中間層出力を利用した半教師あり分布外検知,” 情報処理学会論文誌, Vol. 62, No. 4, pp. 1142-1151, Apr. 2021.
- [6] Y. Koizumi, S. Saito, H. Uematsu, N. Harada, K. Imoto, “ToyAD-MOS: a dataset of miniature-machine operating sounds for anomalous sound detection,” Proc. WASPAA, pp. 308-312, Nov. 2019.
- [7] H. Purohit, R. Tanabe, T. Ichige, T. Endo, Y. Nikaido, K. Suefusa, Y. Kawaguchi, “MIMII dataset: sound dataset for malfunctioning industrial machine investigation and inspection,” Proc. DCASE, pp. 209-213, Nov. 2019.
- [8] J. Cramer, H.H. Wu, J. Salamon, J.P. Bello, “Look, listen and learn more: design choices for deep audio embeddings,” Proc. ICASSP, pp. 3852-3856, May 2019.
- [9] D.P. Kingma, J. Ba, “Adam: a method for stochastic optimization,” arXiv preprint, arXiv:1412.6980, 2014.