

# 無音演奏動画を用いたスネアドラムの叩打タイミング検出

坂本 一磨 (公立小松大学 生産システム科学科, kazuma.sakamoto@komatsu-u.ac.jp)

井村 悠斗 (公立小松大学 大学院サステイナブルシステム科学研究科, 22211004@komatsu-u.ac.jp)

上田 芳弘 (公立小松大学 生産システム科学科, yoshihiro.ueda@komatsu-u.ac.jp)

## Snare drum onset detection using silent performance videos

Kazuma Sakamoto (Department of Production Systems Engineering and Sciences, Komatsu University, Japan)

Yuto Imura (Graduate School of Sustainable Systems Science, Komatsu University, Japan)

Yoshihiro Ueda (Department of Production Systems Engineering and Sciences, Komatsu University, Japan)

### 要約

自動採譜とは、主に音響を楽譜等の記号表現に変換することであり、音楽情報処理の分野における主要なタスクのひとつである。その中の一つである自動ドラム採譜は、様々な打楽器で構成されるドラムセットに焦点を当て、どの楽器がどのタイミングで叩打されたかを検出し、記号化するタスクである。従来の研究では、主に音響のみを入力として、自動採譜の処理をしている。しかし、音響のみを入力とする手法では、ポリフォニックな楽器の採譜や、バックグラウンドノイズが存在する環境下で録音された音響の採譜が困難となる場合が多い。解決方法の一つとして、楽器を演奏している様子を撮影した映像の視覚情報から自動採譜することが考えられる。そこで、本研究では、ドラムセットの中でも主要な楽器の一つであるスネアドラムに焦点を絞り、その無音演奏動画からモノフォニックな条件下で、叩打タイミング検出の可能性を検討する。具体的な方法としては、まず、叩打タイミングの画像と非叩打タイミングの画像を用いて、事前学習済みのResNet-18を2値分類モデルにファインチューニングする。そして、評価データの分類精度や最終層出力を検証する。検証実験の結果、叩打タイミングを高い精度で検出することが可能であることを示した。

### Abstract

Automatic music transcription, which is primarily the conversion of sound into a symbolic representation such as sheet music, is one of the major tasks in the field of music and computers. One of these tasks, automatic drum transcription, focuses on a drum set consisting of various percussion instruments, and detects which instruments are struck and at what timing, and converts them into symbolic representations. In previous studies, automatic music transcription has been processed mainly using only acoustics as an input. However, methods that use only acoustics as an input often have difficulty in scoring polyphonic instruments and in scoring sounds recorded in an environment where background noise is present. One possible solution is to use automatic music transcription based on visual information from a video recording of a person playing a musical instrument. Therefore, this study focuses on snare drums, one of the main instruments in a drum set, and examines the possibility of detecting the onsets (i.e., the physical time when a certain drum is hit) under monophonic conditions from silent performance videos. As a specific method, we first fine-tuned the pre-trained ResNet-18 into a binary classification model using images of onset and non-onset. Then, the classification accuracy and final layer output of the evaluation data were verified. The results of the validation experiments show that the onset can be detected with high accuracy.

### キーワード

音楽情報処理, 自動ドラム採譜, 画像認識, 深層学習, ResNet18

### 1. はじめに

動画投稿サイトには、日々数多くの動画が投稿されている。総務省(2022)によると、2021年には世界の動画配信市場は9兆9,310億円(前年比24.5%増)、日本の動画配信市場は、4,614億円(前年比19.0%増)となっており、その市場規模は大きく成長している。その中には、楽器の演奏動画も数多く投稿されており、音響情報に加えて、演奏者の動作といった視覚情報も含まれている。これらの情報を自動採譜技術によって、楽譜やMIDI (Musical Instrument Digital Interface)等の音楽的な記号表現(以下、音楽表現)に変換することが可能となれば、

作曲支援、音楽教育、音楽情報処理等の分野の発展に寄与することが可能である。MIDIとは、主に楽曲制作分野で用いられるデータ形式であり、音階、発音時間と音符の長さ等の情報を内包している。自動採譜とは、音響を音楽表現に変換する処理である。ドラムセットの自動採譜の場合、その処理内容は「叩打タイミングの検出」と「叩打された楽器の分類」に大別される。

自動採譜の手法として、音響のみから推論する手法、音響と映像の両方を用いて推論するマルチモーダルな手法の2つが主に研究されている。

音響のみから推論する手法は盛んに研究されており、バックグラウンドノイズが無いクリアな環境であれば、高精度な自動採譜が可能である。Callender et al. (2020)は、電子ドラムを用いたクリアな音響のデータセットを用いて、高精度な

自動採譜を実装した。しかし、同時に複数の音を発するポリフォニックな楽器や、バックグラウンドノイズが存在する環境下で録音された音響を用いた場合、音響同士の干渉により、自動採譜が困難となる場合が多い。

マルチモーダルな手法は、聴覚情報において不足している部分を視覚情報により補うことが可能である。大矢・松島(2013)は、叩打時刻のフレーム画像を解析し、叩かれた可能性がある楽器の候補を選出している。これにより、音響のみを使用して推論した場合の音響同士の干渉による精度低下の緩和を可能としている。しかし、マルチモーダルな採譜は、音響と映像の時系列同期にずれがある場合、精度が低下する可能性がある。また、多様なノイズを含む悪環境で自動採譜を行う場合、音響に依存することのない自動採譜の可能性を検証する必要がある。

そこで、本研究では、先述した手法とは別の方法として、映像のみからドラム採譜を行う手法について検証する。特に、「叩打タイミング検出」を対象とし、モノフォニック（複数楽器が同時に発音されない）な条件下で検証を行う。そのため、ドラムセットの中でも主要な楽器の一つであるスネアドラムに焦点を絞り、その無音演奏動画から叩打タイミングを検出することを旨とする。

## 2. 関連する研究

### 2.1 音響と映像情報を活用したマルチモーダルなドラム採譜

McGuinness et al. (2007) は、音響と映像情報を入力とするマルチモーダルなドラムセットの自動採譜を実装した。方法としては、ドラムのエッジを楕円として検出し、ドラムスティックのドラム打面への衝撃、叩打後の楽器の動きの特徴から叩打タイミングを検出している。ドラムセットの各楽器の分類は、画像ピクセルのRGB値から推定している。

大矢・松島(2013)も音響と映像情報からマルチモーダルなドラム採譜を行っている。これは、音響情報から叩打タイミングを抽出し、叩打時刻のフレーム画像を解析して、叩打の可能性のある楽器の候補を選出している。そして、この楽器候補と周波数分析の結果を用いて、楽器判別を行い、ドラム演奏の自動採譜を行う方法を提案している。

### 2.2 無音演奏動画を用いたピアノ採譜

Koepke et al. (2020) は、視覚情報のみを用いたシングルモーダルな手法で、ピアノの自動採譜を実装した。方法としては、ResNet-18 (He et al., 2016) をベースとした深層学習モデルを使用し、動画を分割したフレーム画像それぞれに対して、畳み込み処理を行っている。その後、畳み込み処理された複数の画像を束ねてから畳み込み処理を行うことで、時系列を考慮しながら学習を行い、適合率、再現率、 $F$ 値と正解率で評価している。学習データの動画フレームへのアノテーションには、ピアノの音響から採譜する深層学習モデル(Hawthorne et al., 2020)を用いることで、正解ラベルを取得している。

Su et al. (2020) は、ピアノの無音演奏動画から元の演奏音響を再現しようと試みている。これは、Koepke et al. (2020) の「どのキーがどのタイミングで押されたか」を検出する深層学習モデルに「ピアノ演奏として尤もらしい演奏情報」とし

て、出力するための深層学習モデルを追加することにより、高精度なピアノ採譜と演奏音響の再現を可能とした。無音演奏動画を用いたピアノ採譜の場合、鍵盤の動きと指の動きによって、打鍵のタイミングを推定可能である。一方、無音演奏動画を用いたドラム採譜、特にスネアドラムのような太鼓楽器の場合、叩打タイミングの瞬間における楽器の動きは少なく、スティックの動きや、スティックと打面の瞬間的な接触のみによって叩打タイミングを推定する必要があり、検出が難しいタスクとなる。

以上の研究を参考に無音演奏動画からドラム採譜を行う手法を検討する。本研究では、マルチモーダルではなくシングルモーダルなアプローチによるドラム採譜に注目し、画像のみからドラム採譜を行う手法を提案する。また、Koepke et al.では、複数フレームを学習モデルへの入力としていたが、本研究では学習モデルとしてResNet-18を用いて、単フレーム画像から叩打タイミングの特徴を抽出できるかどうかを検証する。

## 3. 提案手法

本研究の処理フローを図1に示す。本提案手法の処理フローは、演奏動画を入力とし、各フレーム画像の叩打成否を出力する。具体的な各機能の内容を以下に示す。

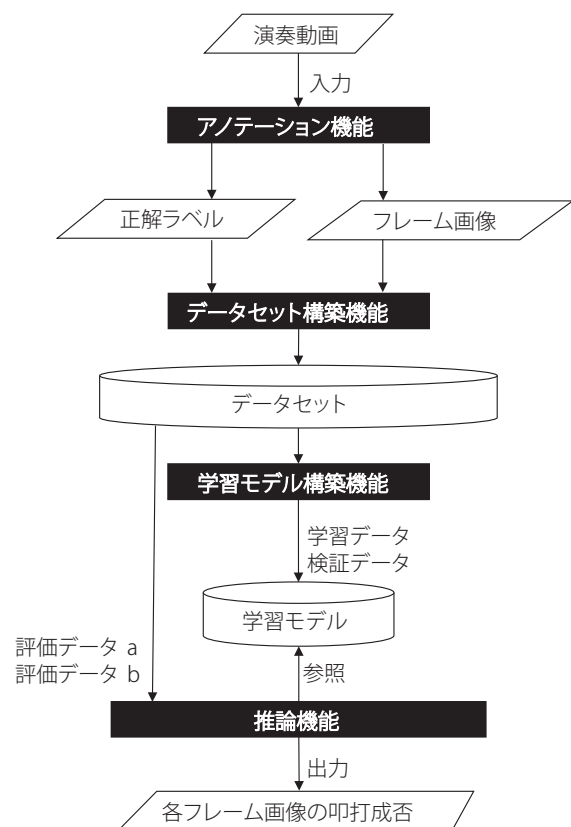


図1：処理全体のフロー

### 3.1 アノテーション機能

アノテーション機能の内部の処理フローを図2に示す。本機能では、音響抽出処理と正解ラベル生成処理によって正解

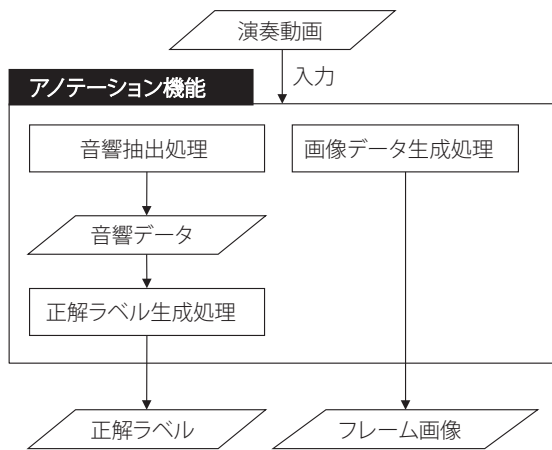


図2：アノテーション機能のフロー

ラベルを生成し、画像データ生成処理で演奏動画からフレーム画像を生成する。各処理の詳細を次に示す。

### 3.1.1 音響抽出処理

本処理では、演奏動画の音響を解析し、正解ラベルを取得するため、FFmpegを使用し、動画に収録された音響を音響データ(wavファイル)に変換する。

### 3.1.2 画像データ生成処理

本処理では、画像分類モデルによる叩打タイミング検出するための画像データを生成する。方法としては、FFmpegを用いて動画を分割し、フレーム画像に変換する。

### 3.1.3 正解ラベル生成処理

本処理では、音響抽出処理によって抽出された音響データを解析し、各フレーム画像が叩打であるか非叩打であるかの正解ラベルを出力する。

まず、動画の音響情報を作曲用ソフトウェアStudio One 4 Professional (2023) を用いて、MIDIに変換する。また、PythonのMIDIデータ処理ライブラリであるPretty\_midiを用いて、MIDIから音の開始時刻(叩打時刻)を取得する。この時、単純に音響をMIDIに変換した場合、反響音も演奏として認識する可能性がある。そのため、叩打タイミングの打音は削除せず、反響音のみを削除するように反響音の音量閾値を動画ごとに手動で定めて、Studio One 4 Professionalの機能を使用し、反響音を削除する。

次に、叩打時刻から各フレーム画像が叩打タイミングか、あるいは非叩打タイミングかを示す正解ラベルをcsvファイルとして出力する。

## 3.2 データセット構築機能

データセット構築機能の内部のフロー図を図3に示す。本機能では、アノテーションしたフレーム画像を加工し、学習データ、検証データ、評価データa、評価データbから成るデータセットを構築する。具体的な各処理の内容を次に示す。

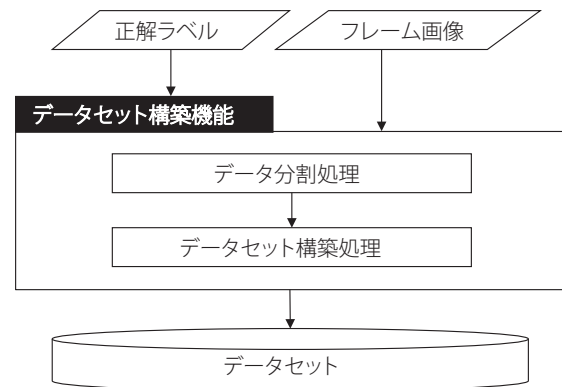


図3：データセット構築機能のフロー

### 3.2.1 データ分割処理

本処理では、演奏動画から作成したアノテーション済みのフレーム画像を入力とし、3つのフレーム画像群を作成する。本研究では、フレーム画像の6割を学習用フレーム画像、2割を検証用フレーム画像、残り2割を評価用フレーム画像とする。

### 3.2.2 データセット構築処理

学習用フレーム画像、検証用フレーム画像、評価用フレーム画像に存在する全てのフレーム画像の内、叩打画像は疎であり、非叩打画像が多数を占める。そのため、本処理では、叩打画像の枚数に合わせて非叩打画像の枚数を削減することで、叩打画像と非叩打画像の枚数を均等にする。

ダウンサンプリングした学習用フレーム画像、検証用フレーム画像、評価用フレーム画像をそれぞれ学習データ、検証データ、評価データaとし、ダウンサンプリングされていない評価用フレーム画像を評価データbとする。

## 3.3 学習モデル構築機能

ImageNet (Deng et al., 2009) によって事前学習されたResNet-18を学習データと検証データを用いて、2値分類モデルにファインチューニングする。モデルにフレーム画像を読み込む際は、ImageNetの学習データの画像サイズである224 px × 224 pxに合わせて、トリミングとリサイズを行った。本研究では、Pythonの深層学習ライブラリであるPytorchを用いて、これらの処理を行う。

## 3.4 推論機能

3.3節で構築した学習モデルを用いて、各評価データに対して推論を実行し、叩打か非叩打かを分類する。出力は、評価データの各フレーム画像の叩打成否と、モデルが予測した叩打である確率(以下、予測叩打確率)とする。

予測叩打確率の計算方法は、次の通りである。評価データのフレーム画像を $X$ としたとき、モデルの最終層出力を $Y$ とし、ラベル「非叩打」に対する最終層出力を $Y_0$ 、ラベル「叩打」に対する最終層出力を $Y_1$ とする(数式1)。各最終層出力に対し、ソフトマックス関数(数式2)を適用することで、予想叩打確率を得る。数式2で算出された値は、モデルが予測した「あ

るフレーム画像 $x_i$ が叩打である確率」と同義である。

$$X = [x_1, x_2, x_3, \dots, x_n]$$

$$Y(X) = \begin{bmatrix} Y_0(X) \\ Y_1(X) \end{bmatrix} = \begin{bmatrix} y_0(x_1), y_0(x_2), y_0(x_3), \dots, y_0(x_n) \\ y_1(x_1), y_1(x_2), y_1(x_3), \dots, y_1(x_n) \end{bmatrix} \quad (1)$$

$$s(x_i) = \frac{e^{y_1(x_i)}}{e^{y_0(x_i)} + e^{y_1(x_i)}} \quad (2)$$

## 4. 評価実験

### 4.1 実験データ

ビデオカメラを用いて、演奏者の正面から撮影した演奏動画を実験データとして使用する。複雑なフレーズの演奏を撮影した動画に対して、3.1.3項に記した作曲用ソフトウェアを用いたアノテーション方法を用いた場合、演奏音と反響音の分離が複雑化し、演奏の検出が困難であった。そのため、単純な演奏での撮影を行った。撮影は、表1に示す撮影条件で、各30分の3つの演奏動画を撮影した。

表1：各演奏動画と撮影条件

演奏動画No.	撮影条件
演奏動画1	テンポ60 bpmの四分音符を両手（左右交互）で演奏
演奏動画2	テンポ120 bpmの四分音符を両手（左右交互）で演奏
演奏動画3	テンポ60 bpmの四分音符を右手のみで演奏

データセットは、表1に示す3つの演奏動画から作成し、3.2節に示した学習データ、検証データ、評価データa、評価データbから構成される。各データの詳細を表2に示す。

### 4.2 学習モデル

ImageNetによって事前学習されたResNet-18をファインチューニングし、叩打・非叩打を判別する2値分類モデルを構築する。モデルにフレーム画像を読み込む際は、3.3節の学習モデル構築機能に示したとおり、ImageNetの学習データの画像サイズである224 px × 224 pxに合わせて、トリミングとリサイズを行った。トリミングとリサイズが施された画像を図4に示す。

## 5. 実験結果

学習モデルに対し、評価データa（ダウンサンプリングあ



図4：加工されたフレーム画像

表3：評価結果

対象データ	処理対象	適合率	再現率	F値
評価データa	叩打	0.967	0.979	0.973
	非叩打	0.979	0.966	0.972
評価データb	叩打	0.660	0.873	0.752
	非叩打	0.994	0.979	0.987

りの評価データ)、評価データb（ダウンサンプリングなしの評価データ）を入力し、出力された予測ラベル（叩打成否）と正解ラベルを比較し、適合率、再現率、F値で評価する。評価結果を表3に示す。

評価データaを入力した場合では、いずれの評価指標も0.966から0.979の高い値を示し、学習データと近い条件の場合、高い精度での分類が可能であることがわかった。

評価データbは、実際に自動採譜を行うことを想定するため、ダウンサンプリング処理は行わず、連続したフレーム画像から構成される。評価データbを学習モデルに入力した場合、非叩打の適合率、再現率、F値は0.979から0.994の高い値を示したが、叩打の適合率は0.660、再現率は0.873、F値は0.752と評価データaと比較して低い値を示した。

## 6. 考察

### 6.1 叩打画像前後の誤分類

図5に評価データbを学習モデルに入力した際の予測叩打確率の一部を示す。画像番号66のように、叩打画像の直前のいくつかの非叩打画像が誤分類されていることが確認でき、これが評価データbを使用した際の適合率低下に繋がったと考えられる。

表2：データセットの詳細

対象データ	使用動画フレーム	ダウンサンプリング	非叩打画像枚数	叩打画像枚数
学習データ	演奏動画1～3それぞれを6:2:2で分割した際の前半部6割を使用	あり	4,371	4,371
検証データ	演奏動画1～3それぞれを6:2:2で分割した際の中央部2割を使用	あり	1,461	1,461
評価データa	演奏動画1～3それぞれを6:2:2で分割した際の後半部2割を使用	あり	1,097	1,097
評価データb		なし	31,382	1,459






図5：評価データbの予測叩打確率の一部

### 6.2 叩打画像前後の学習不足

本手法では、叩打画像に加え、無作為にダウンサンプリングされた非叩打画像を学習データに用いているが、この無作為にダウンサンプリングした非叩打画像に含まれる叩打前後の画像は少数である。そのため、叩打前後の1フレームの違いによる明確な特徴の差異を得ることができず、6.1節の叩打画像前後の誤分類の一因となったと考えられる。

### 6.3 フレームレート

叩打画像（画像番号66）とその前後の非叩打画像（画像データ生成処理によって224 px×224 pxに加工したもの）を図6に示す。本実験では、29.97 fpsで撮影した動画を使用したが、高速で動作するスティックの先端を捉えることができず、叩打画像の明確な特徴を得ることが困難であると考えられる。

### 6.4 1フレームのずれ

本実験では1フレームのずれも許容しないアノテーションが施されている。そのため、図5の画像番号110と111、126と127のように叩打の存在は認識しているが、そのタイミングが1フレームずれている場合を評価することが難しい。しかし、実用環境の場合、人間は1フレームのずれを知覚することは困難であり、楽譜に起こす際、1フレーム単位の細かな時間分解能が必要となる状況は少ない。そのため、本手法の評価と実用環境が必要とする評価には乖離が存在する。

### 6.5 追加検証

6.4節に示した1フレームのずれによる本手法の評価、実用環境が必要とする評価の乖離を解消するため、追加検証を実施した。具体的には、正解ラベルと予測ラベルが1フレームずれている場合を許容し、真陽性（叩打）、真陰性（非叩打）として集計した。

1フレームのずれを許容して真陽性、真陰性を集計する際、予測ラベルから正解ラベルに対して照合する場合（図7）、正解ラベルから予測ラベルに対して照合する場合（図8）では、真陽性と真陰性の数が異なる。そのため、予測ラベルから正解ラベルに対して照合と集計した真陽性を「真陽性p」、正解ラベルから予測ラベルに対して照合と集計した真陽性を「真陽性r」と定義する。

適合率、再現率は、数式3として定義し、評価した。なお、非叩打の適合率、再現率も同様とする。

$$\text{叩打の適合率} = \frac{\text{真陽性}p}{\text{モデルが予測した叩打の総数}} \quad (3)$$

$$\text{叩打の再現率} = \frac{\text{真陽性}r}{\text{正解ラベルの叩打の総数}}$$

追加検証の評価結果を表4に示す。表3に示した評価結果と比較して、叩打の適合率が0.660から0.991と大幅に上昇した。その他の数値も0.897から1.000の高い数値を示した。このことから、約0.033秒の誤差範囲内であれば、高い精度で叩打画像と非叩打画像を分類することが可能であることが確




図6：叩打画像とその前後の非叩打画像（評価データb）

画像番号	正解ラベル		予測ラベル
n-3	0	照合 →	TN
n-2	0	→	TN
n-1	0	→	TN
n	1	→	TP
n+1	0	→	TN
n+2	0	→	TN
n+3	0	→	TN

真陽性の合計：1  
真陰性の合計：6

図7：予測ラベルから正解ラベルに対して集計

画像番号	正解ラベル		予測ラベル
n-3	0	TN ← 照合	0
n-2	0	TN ←	0
n-1	0	TN ←	1
n	1	TP ←	1
n+1	0	TN ←	0
n+2	0	TN ←	0
n+3	0	TN ←	0

真陽性の合計：2  
真陰性の合計：5

図8：正解ラベルから予測ラベルに対して集計

表4：追加検証の評価結果

対象データ	処理対象	適合率	再現率	F値
評価データb	叩打	0.991	0.897	0.941
	非叩打	1.000	1.000	1.000

認できた。

## 7. おわりに

本研究では、画像分類モデルを使用して、視覚情報のみを用いたスネアドラムの叩打タイミング検出を行った。その結果、叩打画像の前後のフレーム画像の誤検知が多くみられる点、29.97fpsで撮影された動画では、1フレームの違いによる明確な特徴の違いを得ることは困難であると考えられる点、約0.033秒の誤差範囲内であれば、高い精度で叩打画像と非叩打画像を分類することが可能である点の3つの知見を得ることができた。

本手法の限界としては、正解ラベル生成処理で音響を用いたアノテーションを行っていることや、学習モデルの入力が単フレームであることから、高速なテンポでの演奏や複雑なフレーズの演奏の採譜に適さないことが挙げられる。これらの問題は、打面にセンサを取り付けることで叩打タイミングの取得とアノテーションを行う方法や、複数フレームを入力

とする学習モデルを用いることで、改善することが可能であると考えられる。

本研究成果の応用として、2つのケースが考えられる。まず、1つ目は、音楽教育用ツールとしての活用である。動画から自動採譜が可能となれば、スマートフォンやタブレット端末を活用することにより、生徒や教員の演奏を即座に楽譜化することができるため、より直感的な音楽教育が可能となると考えられる。また、視覚情報から採譜可能なため、周囲の環境音の影響を受けず、複数人数が同じ部屋で演奏している場合や教員が口頭で説明しながら演奏している場合等において、画角を調整するのみで対応可能であると考えられる。

2つ目が、動画ストリーミングサービスやSNSでの活用である。Web上には、ドラムセットで演奏した様々な楽曲動画が投稿されている。しかし、これらの動画のうち、ドラムのみで投稿された動画は比較的少数であり、多くの動画は伴奏つきのものである。そのため、音響を入力とするモデルで自動採譜を行うことが、困難となる場合が多い。しかし、視覚情報のみからの自動採譜が可能となれば、伴奏のようなノイズの影響を受けないため、安定した自動採譜が可能になると考えられる。

## 引用文献

- Callender, L., Hawthorne, C., and Engel, J. (2020). Improving perceptual quality of drum transcription with the expanded groove MIDI dataset. *arXiv*, arXiv:2004.00188.
- Deng, J., Dong, W., Socher, R., Li, L. J., Li, K., and Fei-Fei, L. (2009). ImageNet: A large-scale hierarchical image database. *Proceedings of 2009 IEEE Conference on Computer Vision and Pattern Recognition*, 248-255.
- He, K., Zhang, X., Ren, S., and Sun, J. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 770-778.
- Hawthorne, C., Elsen, E., Song, J., Roberts, A., Simon, I., Raffel, C., Engel, J., Oore, S., and Eck, D. (2018). Onsets and frames: Dual-objective piano transcription. *arXiv*, 710.11153.
- Koepke, A. S., Wiles, O., Moses, Y., and Zisserman, A. (2020). Sight to sound: An end-to-end approach for visual piano transcription. *ICASSP 2020 - 2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 1838-1842.
- McGuinness, K., Gillet, O., O'Connor, N. E., and Richard, G. (2007). Visual analysis for drum sequence transcription. *2007 15th European Signal Processing Conference*. 312-316.
- Raffel, C. and Ellis, D. P. (2014). Intuitive analysis, creation and manipulation of MIDI data with pretty\_midi. *15th International Society for Music Information Retrieval Conference Late Breaking and Demo Papers*, 84-93.
- Su, K., Liu, X., and Shlizerman, E. (2020). Audeo: Audio generation for a silent performance video. *Advances in Neural Information Processing Systems*, 3325-3337.
- エムアイセブンジャパン (n.d.) Studio One. <https://www.mi7.co.jp/products/presonus/studioone/>. (閲覧日：2023

年5月1日)

大矢健二郎・松島俊明(2013). 音響情報と動画像情報を用いたドラム演奏の自動採譜. 2013年電子情報通信学会総合大会, 169.

総務省(2022). 令和4年情報通信に関する現状報告の概要. <https://www.soumu.go.jp/johotsusintokei/whitepaper/ja/r04/html/nd236600.html>. (閲覧日: 2023年5月1日)

---

受稿日: 2023年12月1日

受理日: 2024年3月25日

発行日: 2024年6月30日

Copyright © 2024 Society for Science and Technology



This article is licensed under a Creative Commons [Attribution-NonCommercial-NoDerivatives 4.0 International] license.



<https://doi.org/10.11425/sst.13.31>