

# 歯ぎしりの分類における特徴量としての筋電信号の時間波形とスペクトログラムの比較

Comparison time-series waveforms of and spectrograms of myoelectric signals as features in the classification of bruxism.

鎌田 輝夏

Koka Kamada

岡山大学 原研究室

Hara Laboratory, Okayama University

**概要** 本研究は、筋電信号を特徴量とした機械学習で、4種類の歯ぎしりと歯ぎしりの以外の動作を分類することを目的とする。本報告では、9チャンネルの筋電信号を時間波形、メルスペクトログラムに変換し、それぞれをMulti Layer Perceptron(MLP)、Convolutional Neural Network(CNN)に入力して、4種類の歯ぎしりとその他の行動の5クラスの分類を行った。各方式の結果を比較すると、テストデータでは時間波形の方がわずかに出力データの正答率が高くなることが確認できた。




図 1: 異なる電極から得られた9チャンネルの筋電信号

## 1 はじめに

歯ぎしりは口内悪習癖のひとつであり、睡眠中に無自覚に発生することもある。歯ぎしりは、歯の咬耗や歯周組織破壊などの様々な悪影響を及ぼすため、適切な評価や診断によって治療を行う必要がある。

歯ぎしりの評価には様々な方法があるが、より正確とされているのがポリソムノグラフ (PSG) 検査であり、音声ビデオ記録を用いた PSG-AV 検査が最適とされている。また先行研究では、隠れマルコフモデル (HMM) に基づいた識別手法によって、Full polysomnography (F-PSG) を用いて採取した筋電図波形の識別が行われた [1, 2]。結果として、意識下における歯ぎしりとそうでないものを精度高く識別することができ、睡眠時のデータに対しても高い精度で識別できる可能性が示唆された。また、この実験では HMM に与える特徴量として MFCC が使用されている。このことから、筋電信号を音声信号としてとらえることで、歯ぎしりの識別に音声認識の手法が有効であることが示された。

本研究では、音声と筋電信号を特徴量とした機械学習による歯ぎしりやその他の活動の分類の方式を提案する。本研究を行うにあたり、機械学習の特徴量となる筋電信号を様々な信号表現に変換することで、識別の精度を高めることができるか検討する。本報告では、意識下における歯ぎしりとその他の筋活動の筋電信号を機械学習によって分類する。筋電信号は時間波形とメルスペクトログラムに変換し、それぞれ MLP や CNN に入力し分類精度の比較を行う。

## 2 使用データセット

### 2.1 特徴量としての筋電信号

本研究で使用する筋電信号は、生物の筋細胞が収縮活動する時に発生する電位を記録した信号である [3]。時

間波形である筋電信号の振幅は筋肉の収縮の強さを表している。また、筋電信号をスペクトログラムに変換することで、ある時間における信号の周波数成分の分布や、時間に伴う周波数成分の変化などを解析することができる。

今回使用した筋電信号は、EDF ファイルに多チャンネルデータとして保存されている。各チャンネルは異なる電極から得られた筋電信号となっている。

### 2.2 使用したデータの概要

1人分のデータは9チャンネルの筋電信号となっており、各チャンネルは異なる箇所貼付された電極から得られたものである。例として1人分のデータの時間波形を図1、メルスペクトログラムを図2に示す。電極を貼付したのは顎、左右の咬筋、左右の顎下筋、顎二腹筋、腹部、左右の眼球電図の9か所である。筋電信号のサンプリング周波数は1kHzとなっている。12名の健常被験者に意識下で4種類の歯ぎしりと、6種類の歯ぎしり以外の動作をそれぞれ1分間に5回ずつ行ってもらい、筋電信号を測定した。各動作は20秒の間隔を空けて記録されている。行った動作は、表1に示す10種類とした。歯ぎしりとする動作は、食いしばり、疑似食いしばり、タッピング、研削の4種類である。また、歯ぎしり以外の動作として、嚥下、あくび、発語、そう痒、体の動き、いびきの6種類を行った。

## 3 分類性能の比較実験

### 3.1 実験条件

本実験では歯ぎしりである  $E_1$  から  $E_4$  と、その他の行動として  $E_5$  の部分にあたる筋電信号を12人分使用し、5クラスの分類を行う。分類はNeural Network(NN)による機械学習によって行い、NNに入力する特徴量と




図 2: 1 秒間の筋電信号のメルスペクトログラム

表 1: 収録したイベント

Event (歯ぎしり)	Event (歯ぎしり以外)
$E_1$ 食いしばり	$E_5$ 嚥下
$E_2$ 疑似食いしばり	$E_6$ あくび
$E_3$ タッピング (カチカチ)	$E_7$ 発語
$E_4$ 研削 (ギリギリ)	$E_8$ そう痒
	$E_9$ 体の動き
	$E_{10}$ いびき

表 2: メルスペクトログラム変換に用いたパラメータ

params	value
n_mels	32
sample_rate	1000
n_fft	256
hop_length	20
center	False
f_max	100
f_min	10

して筋電信号の時間波形とメルスペクトログラムを使用する。時間波形は MLP に、スペクトログラムは CNN に入力する。MLP や CNN での機械学習では、11 人分の筋電信号を学習データ、1 人分の筋電信号をテストデータとする。1 つの入力データは 1 秒分の筋電信号となっている。筋電信号のメルスペクトログラムへの変換に用いたパラメータは表 2 に示す。学習の回数は 700 回とし、学習率は MLP では  $2 \times 10^{-5}$ 、CNN では  $5 \times 10^{-5}$  とした。loss の計算には Cross entropy Loss を使用した。

各結果の評価には、学習データと検証データに対する正解ラベルの予測の正答率を用いる。正答率は、出力した予測ラベルが実際の正解ラベルと同じであった数を全データ数で除して算出する。過学習とまらない学習回数は、学習回数に対する正答率をグラフ化して目視で選択する。その学習回数で各方式の評価に用いる正答率を決定する。

### 3.2 実験結果

時間波形を特徴量とした場合の正答率を図 3 に、メルスペクトログラムを特徴量とした場合の正答率を図 4 に示す。図中の train が学習データ、test がテストデータ

表 3: MLP の構成

layer type	input size	output size
L1.1 linear	1000	128
L1.2 linear	1000	128
L1.3 linear	1000	128
L1.4 linear	1000	128
L1.5 linear	1000	128
L1.6 linear	1000	128
L1.7 linear	1000	128
L1.8 linear	1000	128
L1.9 linear	1000	128
L2 linear	$128 \times 9$	128
L3 linear	128	5

表 4: CNN の構成

layer type	input size	ksize	stride
L1 convolution	$9 \times 1000$	(5,5)	(1,1)
L2 convolution	$90 \times 996$	(3,3)	(1,1)
L3 convolution	$180 \times 994$	(3,3)	(1,1)
L5 max pooling	$180 \times 497$	(2,2)	(2,2)

layer type	input size	output size
L4 global pooling	$360 \times 495$	$360 \times 1 \times 1$
L6 flatten	$360 \times 1 \times 1$	5
L7 linear	360	5

の正答率を示している。横軸は学習回数、縦軸は正答率 (%) となっている。

時間波形を特徴量とした場合では、正答率は学習データに対して 89.1%、テストデータに対して 34.6% となった。この時の学習回数は 60 回、loss は 0.5869 であった。メルスペクトログラムを特徴量とした場合では、正答率は学習データに対して 62.4%、テストデータに対して 30.9% となった。この時の学習回数は 565 回、loss は 26.9995 であった。

また、ある一人の学習データに対する予測ラベルと正解ラベルをグラフとして図 5、図 6 に示す。なお学習回数は時間波形では 60 回、メルスペクトログラムでは 565 回とした。上下のグラフは、横軸がデータポイントのインデックスとなっている。上のグラフは、モデルが各クラスに対して予測した確率を表す。特定のデータポイントに対してあるクラスの確率値が高いと、モデルはそのデータポイントにおいてそのクラスであると識別しやすくなる。下のグラフでは ref\_Y が正解ラベル、hyp\_Y がモデルの予測したラベルを表す。ref\_Y、hyp\_Y が重なっているほど予測の精度が高いことになる。

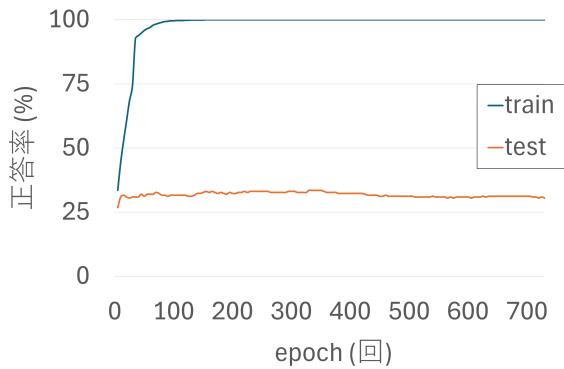


図 3: 時間波形の正答率

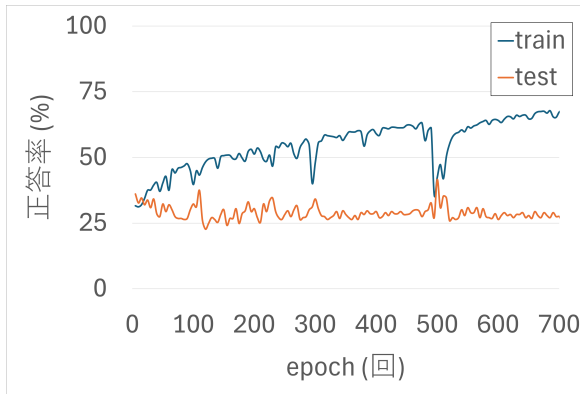


図 4: メルスペクトログラムの正答率




図 5: テストデータに対する正解ラベルと予測ラベル (時間波形)




図 6: テストデータに対する正解ラベルと予測ラベル (メルスペクトログラム)

### 3.3 分類性能の比較

時間波形とメルスペクトログラムでの正答率を比較すると、学習データでの正答率は時間波形を用いた場合の方がかなり高いことがわかる。テストデータでの正答率には大きな差は見られないが、時間波形を用いた場合の方がわずかに高くなっていることが確認できる。しかし、図 3 の通り、メルスペクトログラムを用いた CNN での学習は、学習データとテストデータの正答率の変化がかなり不安定であった。そのため、CNN の構成や学習率などを変更して再度実験を行うことで新たな結果が得られるのではないかと考えた。ここでは、筋電信号を

異なる信号表現に変換することによる分類精度の変化はあまり見られなかったが、CNN の作成方法を見直して改めて実験結果の比較を行う必要があるだろう。

### 3.4 データのラベル付けについての考察

図 5 の上側のグラフを見てみると、どのイベントにおいても正答率が高くなっている地点が約 5 点ほどみられる。下のグラフでは、上のグラフで正答率が高くなっていた箇所以外の点において予測が大きく外れていることが見て取れる。

今回使用したデータセットでは、あるイベントが発生している間の信号には、すべてそのイベントのラベルが付けられている。そのため、例えばタッピングのような間欠的に発生するイベントである場合、行動の合間の部分にあたる信号も何らかのイベントとしてラベルがつけられている。このようなラベル付けによって図 5 のように、あるイベントに対して予測が大きく外れる部分が発生したと考えられる。間欠的に発生するイベントに対するラベル付けの手法について検討することで、より分類の精度を高くすることができると考えられる。

## 4 まとめ

本報告では、筋電信号の時間波形とメルスペクトログラムを用いた歯ぎしりの分類について述べた。筋電信号の時間波形を MLP に、メルスペクトログラムを CNN に入力して出力データの正答率を比較したところ、テストデータに対する正答率に大きな差は見られなかったが、時間波形のほうがわずかに精度が高いことが確認できた。学習が不安定であった CNN の構成や、データに対するラベル付けの手法について検討し、改めて実験を行う必要があると考えられる。

## 参考文献

- [1] 三木春奈, 長崎光弘, Hoang Dinh Loc, 水口一, 西村多寿子, 峯松信明, 窪木拓男 “機械学習の応用による睡眠時筋電図波形のブラキシズム/非ブラキシズム識別の試み,” 日本補綴歯科学会誌, 14 巻, 特別号, p257,2022.
- [2] 長崎光弘 他, “ナノメッシュセンサーを用いたブラキシズムの筋電計測と隠れマルコフモデルによるその分類 “2P-04, 生体医工学シンポジウム 2020 講演予稿・抄録集,2020.
- [3] (株)ALTs “<https://alts-device.com/technology/myoelectric-emg/>”