

修士論文

筋電波形のスペクトル特徴量を用いた
機械学習によるブラキシズムの自動検出

東京大学大学院 工学系研究科 電気系工学専攻

37-206495 長崎 光弘

指導教員 峯松 信明 教授

令和4年1月27日提出

目次

第 1 章	序論	2
1.1	ブラキシズムの特性	2
1.2	ブラキシズム検出の背景	3
1.3	スペクトルを用いたブラキシズム検出の研究例	5
1.4	研究の目的	6
1.5	本論文の構成	6
第 2 章	特徴量と認識モデル	7
2.1	特徴量	7
2.2	隠れマルコフモデル	8
2.3	オートエンコーダ	11
2.4	モデル間比較	14
第 3 章	ブラキシズムデータの計測	15
3.1	筋電波形の計測箇所を検討	15
3.2	意識的ブラキシズムデータ	16
3.3	無意識的ブラキシズムデータ	19
第 4 章	筋電特徴量の選定	21
4.1	実験概要	21
4.2	意識的ブラキシズムデータに関する検討	21
4.3	意識的ブラキシズムデータの結果・考察	22
4.4	無意識的ブラキシズムデータに関する検討	24
4.5	無意識的ブラキシズムデータの結果・考察	24
4.6	まとめ	26
第 5 章	マルチストリーム HMM を用いたブラキシズム検出の検討	27
5.1	実験概要	27
5.2	モデル構築	27

5.3	結果	28
5.4	考察	29
第 6 章	オートエンコーダを用いたブラキシズム検出精度の向上	30
6.1	実験概要	30
6.2	意識的ブラキシズムデータを用いた検討	30
6.3	無意識的ブラキシズムデータを用いた検討	33
6.4	テストデータの拡張	34
6.5	非ブラキシズムデータを用いた学習の検討	35
6.6	まとめ	37
第 7 章	オートエンコーダの中間層特徴量を用いた HMM によるブラキシズム検出の検討	38
7.1	実験概要	38
7.2	次元圧縮としてのオートエンコーダ	38
7.3	オートエンコーダの構築	39
7.4	HMM の構築	39
7.5	結果	39
7.6	考察	40
第 8 章	結論	41
8.1	本論文のまとめ	41
8.2	今後の展望	42
謝辞		44
参考文献		45
発表文献		48

目次

1.1	一般的なブラキシズムの検出方法	4
1.2	BiteStrip [®]	5
2.1	MFCC の求め方の概要	8
2.2	HMM の模式図	8
2.3	先行研究での筋電センサーの貼り付け場所	10
2.4	マルチストリーム HMM の模式図	11
2.5	オートエンコーダの模式図	11
2.6	オートエンコーダの構造	12
3.1	筋肉群の配置図	15
3.2	電極貼付位置	16
3.3	筋電計測の概要図	17
3.4	咬合力が大きい被験者の咬筋で計測した筋電波形の例	18
3.5	咬合力が小さい被験者の咬筋で計測した筋電波形の例	18
3.6	同一被験者の咬筋で計測した各行動の筋電波形	19
3.7	無意識的ブラキシズムデータにおける咬筋で計測した筋電波形の例	20
4.1	データ配分の概要図	22
4.2	意識的ブラキシズムデータを対象とし個々の筋電を特徴量とした HMM でブラキシズムを検出した結果	22
4.3	それぞれの EMG での筋電波形及び検出結果	23
4.4	EMG6 における検出結果の例	25
8.1	ナノメッシュセンサー	42

表目次

4.1	クラス分類	21
4.2	意識的ブラキシズムデータを対象とした HMM のブラキシズム検出性能の評価結果 (被験者平均)	23
4.3	無意識的ブラキシズムデータを対象とした HMM のブラキシズム検出性能の評価結果	25
5.1	マルチストリーム HMM によるブラキシズムの検出結果	28
5.2	マルチストリーム HMM によりエネルギーのみを用いたブラキシズムの検出結果	28
6.1	オートエンコーダの基本パラメータ	31
6.2	オートエンコーダによる意識的ブラキシズムの検出結果	32
6.3	オートエンコーダによる無意識的ブラキシズムの検出結果	33
6.4	テストデータを拡張した場合のオートエンコーダによるブラキシズムの検出結果	34
6.5	非ブラキシズムデータを学習データとしたオートエンコーダによるブラキシズムの検出結果	36
7.1	オートエンコーダの基本パラメータ	39
7.2	オートエンコーダで次元圧縮した特徴量を用いた HMM によるブラキシズムの検出結果	40

第1章

序論

1.1 ブラキシズムの特性

ブラキシズム (bruxism) とは、上下の歯の噛み合わせの悪いことが一因となり、無意識のうちに歯を食いしばったり、こすり合わせるなど、上下の歯が不必要に接触している状態のことである。ブラキシズムはその容態により主に以下の3つに分けられる [1, 2]。

1. グラインディング

強い力で上下の歯をこすり合わせること。ストレスがかかった時などに無意識的に行われることが多く、歯の摩耗や平坦化を起こしやすい。

2. クレンチング

強い力で食いしばること。睡眠時、覚醒時を問わず発生し、音をともなわない点でグラインディングとは異なる。咬合圧力が加わることで、顎関節や歯周組織に損傷を与えやすい。

3. タッピング

上下の歯を細かく小刻みに接触させること。持続的に強い力が加わると歯や歯周組織に影響があるが、グラインディングやクレンチングに比べると発生頻度は低い。

ブラキシズムには、日中覚醒時に行われる「覚醒時ブラキシズム」と睡眠時に行われる「睡眠時ブラキシズム」の2種類が存在する。このうち睡眠時ブラキシズムは、覚醒時ブラキシズムと比較して本人の自覚が薄く、客観的観測も容易ではない。また、クレンチングについては音も出ず、外見上に現れないため、外部から確認することは困難である。さらに、睡眠時にはブラキシズムに非常に類似した現象として「擬似クレンチング」と呼ばれるものがある。擬似クレンチングとは、歯と歯が接触しない程度に口を閉じる力が働いている状態で、クレンチングに近いが歯と歯が接触していないことから擬似クレンチングと呼ばれている。睡眠時ブラキシズム検出の際にはこの擬似クレンチングについても考慮する必要がある。

ブラキシズムは、歯や咀嚼筋に非常に強い力を加えており、その影響で歯の喪失、咀嚼筋や顎関節への為害作用を引き起こすことが知られている [2]。食の文化に基づいた歯応えと風味がある食物の十分な咀嚼は、心身の成長の促進、脳の活性化やリラククス作用、運動機能の向上などにつな

がることが示唆されており [3]、歯がなくなったり噛む力が弱くなることで咀嚼能力が低下すると、これらの作用が得られなくなり生活の質の低下につながる。

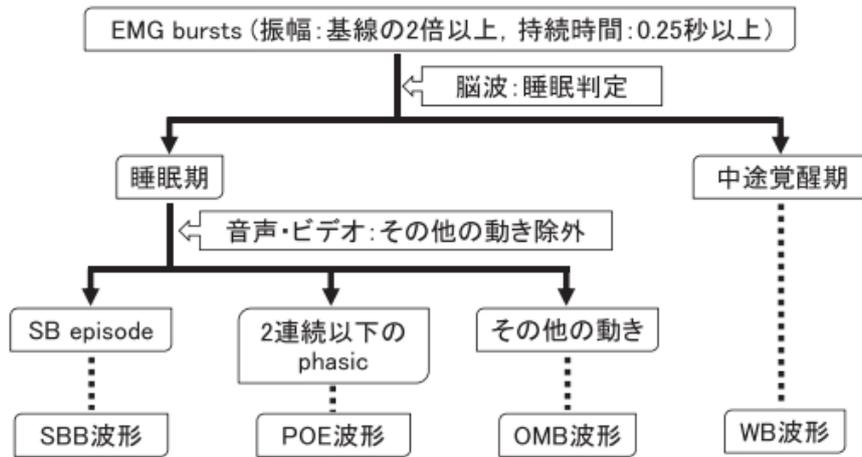
ブラキシズムの原因については様々な可能性が指摘されている。ストレスなどの精神的な原因によるもの、抗うつ剤などの薬の副作用、タバコやコーヒーなどいくつかの中毒性のある物質の影響、あるいは睡眠障害などの病気との関連が示唆されることもあるが、未だにその原因は明確になっていない [4]。また、無意識に行っていることがほとんどであるため、歯軋り音を他人に指摘されるか実際に歯が削れるなどの症状が出るまで本人が自覚できない。仮に本人にある程度の自覚があったとしても、それは実際のブラキシズムよりも軽度であると本人は認識していることが多い [5]。

原因が多様なように治療法もまた画一的なものではなく、様々な方法が考えられている [6]。基本的な治療法としては、ブラキシズムの原因を取り除くことが考えられる。例えば、ストレスや精神的な問題が原因で歯ぎしりしているとすれば、そのストレスなどを取り除くことが治療の1つとして考えられる。あるいは、実際にブラキシズムを行なっていることをバイオフィードバックにより自身に伝えることで気をつけさせるという治療法も存在する。また、ブラキシズムそのものをやめさせるのではなく、ブラキシズムから歯を守るためにマウスピースを装着することもある。

1.2 ブラキシズム検出の背景

歯の健康を保つ観点から、一部の歯科医や口腔外科の専門家がブラキシズムの検出に取り組んでおり、これまでに数多くの提案がなされている。覚醒時ブラキシズムと睡眠時ブラキシズムはどちらも重要であるが、本研究では、疑似クレンチングや睡眠時の体動などが加わるため、検出がより難しいと思われる睡眠時ブラキシズムの検出に取り組む。睡眠時ブラキシズムの最も正確な検査としては、図 1.1a に示す手順で、図 1.1b のように睡眠時ポリグラフ検査 (Polysomnography; PSG) を用いて睡眠状態を考慮して計測し、さらにカメラで睡眠中の動作や音を確認することで手動でアーチファクトを取り除きつつブラキシズムを検出する方法がある [7–10]。PSG は脳波、眼電図、心電図、酸素飽和度や筋電を計測し、多角的に睡眠状態や付随する生理現象を客観的に評価する検査である。ブラキシズムは睡眠の深度と関係があることが知られているため [11]、PSG によって正確なブラキシズム検査を行うことができる。しかし、PSG は多くの信号計測を行うために専用の睡眠室での検査を必要とし、患者に身体的・心理的負担を強いるので普段と異なる睡眠となり、計測結果に影響が出ることが考えられる。

そのため、簡易的にブラキシズムを検出する方法として、計測したブラキシズムの筋電波形に対してパワーを計算して検出する研究が提案されている [12–14]。筋電とは、筋肉に力を加えることで筋繊維が収縮して生じる活動電位のことである [15]。これが容積伝導により電極に向けて伝搬したものを全て合計したものがその電極の観測する電位であり、これを複合活動電位という。筋肉に加えた力が大きければ大きいほど収縮する筋繊維の数も増加する。よって筋肉に入れる力の大きさが大きくなるほど筋電図に記録される電位は大きくなる。これらの研究では最大随意筋力 (Maximum Voluntary Contraction; MVC) を用いてブラキシズム検査を行っている。対象とする筋肉の最大筋力発揮時の筋電振幅を用いて正規化した値 (%MVC) から、例えば MVC の 3 割の振



(a) 睡眠時ブラキシズムの抽出ステップ [7]



(b) 睡眠時ポリグラフ検査の様子

図 1.1: 一般的なブラキシズムの検出方法

幅波形が2秒続けばブラキシズムというような判定基準を定めて、筋活動を計測するものである。

また、筋電計測を簡単にするために、図 1.2 のような小型の器具も利用されている。図 1.2 の器具は BiteStrip[®] と呼ばれ、頬に貼り付けることで手軽に筋電波形を計測することができる。しかし、筋電のパワーを用いた検査ではブラキシズム以外の、例えば体動や嚥下といった筋活動を伴うアーティファクトが8割存在することがわかっており、ブラキシズムの検出方法として不十分であることが指摘されている [16]。このように、ブラキシズムの検出方法はまだ検討の余地を残している。



図 1.2: BiteStrip®

1.3 スペクトルを用いたブラキシズム検出の研究例

本論文では簡易かつ正確なブラキシズム検出の方法として、筋電波形のパワーだけではなくスペクトルも用いた検出を提案する。

スペクトルとは、信号処理において用いられる周波数特徴量の一種である。信号波形の大きさを表現するパワーとは異なり、スペクトルは信号波形の質、形状を表現する。信号波形のスペクトルを用いた技術としては、例えば音声認識が挙げられる。音声波形のパワーから得られる情報はマイクと話者との距離の影響や話者の声の大きさの影響を受けるため、同じ単語を同じ話者が発声してもパワーは発声ごとに異なる。すなわち、音声認識を行う際に音素情報に相当するのはスペクトルであり、スペクトルから特徴量を計算することで認識モデルを構築することが音声認識においては一般的である。この認識モデルとして、古くから広く用いられているのが、隠れマルコフモデル (Hidden Markov Model; HMM) である。HMM は、音素情報に相当するスペクトル特徴量を学習して、例えば5母音のようにいくつかの種類のあるものを識別するために使われる確率モデルである。HMM とスペクトルを用いることで音声認識同様に筋電の識別が可能であると考えられる。

また、筆者らは先行研究でブラキシズムの自動識別をスペクトルを用いて行う予備検討を行っている [17]。この研究では、男女1名ずつの被験者にそれぞれ3種類のブラキシズムを意識的に再現させ、その3種類のブラキシズム及び安静状態の4つの状態について、筋電波形のスペクトル及びHMMを用いて自動識別を行った。その結果、8割から9割程度の正答率であった。この研究によって、ブラキシズムにより生じる筋電波形について、スペクトルを用いることでその特徴を検出できる可能性が示された。ここで得られた知見を応用することで、覚醒時よりも検出が難しいとされる睡眠時ブラキシズムについても、自動検出が可能になると考えている。

しかし、睡眠時に発生しうるブラキシズムの検討においては、覚醒時に意識的に行ったブラキシズムに加えて、ブラキシズム以外の睡眠時の行動、例えば擬似クレンチングや寝返りなどの影響を考慮する必要がある。また、この研究で行ったのはあくまで識別の検討であり、検出の検討ではない。ブラキシズムであるかどうかを識別すると読み替えれば検出においても応用できる部分はあるが、直接検出する方法も考慮すべきであると考えられる。そこで、本研究ではHMMに加えて、異常

検知の分野などで用いられるニューラルネットワークの一種のオートエンコーダ (AutoEncoder; AE) も検討する。

1.4 研究の目的

本研究は、ブラキシズムの中でも検出が特に難しいと思われる睡眠時ブラキシズムの自動検出技術の精度向上を目的とする。そのために、実際のブラキシズムに加え睡眠時のブラキシズム以外の行動、例えば擬似クレンチングや体動といった行動についても考慮した筋電波形データセットを用意し、そのスペクトル特徴量を用いて隠れマルコフモデル及びオートエンコーダという2つの検出アプローチの異なるモデルでの自動検出を試みる。

1.5 本論文の構成

本論文は全8章で構成される。第2章では、機械学習に用いる特徴量や隠れマルコフモデル、オートエンコーダについて記載する。第3章では、本研究で用いる筋電波形データの計測方法について記載する。第4章では、ブラキシズム検出にあたって用いる特徴量の選定過程について記載する。第5章では隠れマルコフモデル、第6章ではオートエンコーダ、第7章ではその両方を組み合わせてブラキシズム検出を試み、その結果及び考察について記載する。第8章では、本論文をまとめ、今後の課題や展望について述べる。

第 2 章

特徴量と認識モデル

筋電波形のスペクトルを用いてブラキシズムを検出する上で、本研究では 2 つのモデルを提案する。1 つは音声認識でも古くから用いられ、[17] でも使用した隠れマルコフモデル (Hidden Markov Model; HMM) である。もう 1 つは異常検知の分野などで用いられるニューラルネットワークの一種のオートエンコーダ (AutoEncoder; AE) である。どちらを用いる際にもブラキシズムの検出をスペクトルを用いて行うという点は同様であるが、検出までの方針はそれぞれのモデルで異なる。

本章では、ブラキシズム検出に用いた特徴量及び 2 つのモデルについて、それぞれの特性に着目しながら解説し、比較検討する。

2.1 特徴量

音声認識においては、音響特徴量として一般的にメル周波数ケプストラム係数 (Mel Frequency Cepstrum Coefficients; MFCC) が用いられている。MFCC とは聴覚の周波数特性に基づいた特徴量である。計算方法の概要を図 2.1 に示す。まずサンプル波形から数十 ms ほどの区間を切り取り、フレームの端が 0 となるようにハミング窓などをかけて離散フーリエ変換 (Discrete Fourier Transform; DFT) を行う。この対数をとったものに対して、人間の聴覚特性を考慮した三角窓関数群を掛け合わせ、離散コサイン変換を施すことで MFCC が得られる。フレームをフレーム幅の半分ほどずらして特徴量系列を得ることができ、これにさらに時間変化の情報を加えるために動的特徴量 (Δ 特徴量、 $\Delta\Delta$ 特徴量) も用いることが多い。

上記の通り、本来 MFCC は音声認識で用いることに特化した特徴量であるが、例えば音声認識の補助情報として筋電を用いる研究では筋電に対しても MFCC が用いられており [18]、また、筆者も過去に MFCC を用いてブラキシズムの種類判別を行い、9 割近い精度を出している [17]。そこで、本研究でも MFCC を特徴量として用いて、各種モデルによりブラキシズム検出を検討する。

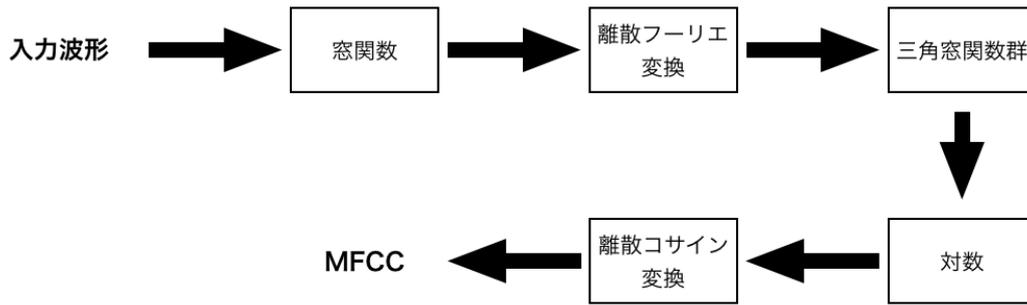


図 2.1: MFCC の求め方の概要

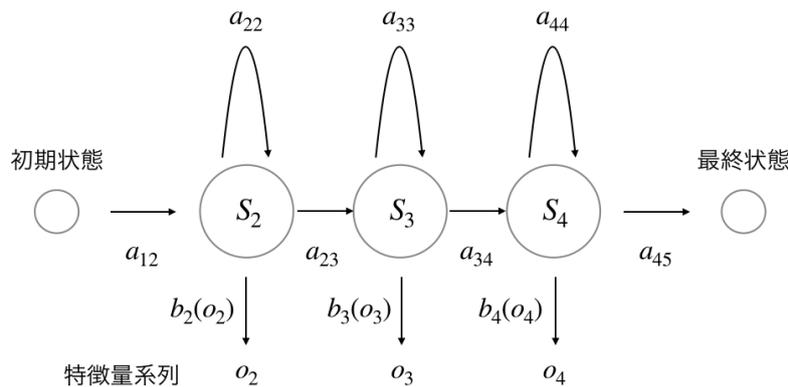


図 2.2: HMM の模式図

2.2 隠れマルコフモデル

音響信号に対してクラス分類をする際に幅広く用いられているのが隠れマルコフモデル (Hidden Markov Model; HMM) である。HMM とは、確率的に遷移する状態それぞれが確率分布をもち、ある特徴量を出力するモデルであるが、どの状態から出力されたのかは観測できない。音声認識では各状態の確率分布として複数の正規分布の重み付け和である混合ガウス分布 (Gaussian Mixture Model; GMM) が用いられる。HMM の模式図を図 2.2 に示す。

HMM はいくつかのパラメータによって定義される。まず、状態数 N 、状態集合 $\{S_i\} (1 \leq i \leq N)$ 、初期状態および最終状態の部分集合である。これらは事前に定められていることが多い。そして状態 S_i から状態 S_j への遷移確率 a_{ij} 、状態 S_i から出力される特徴ベクトル o の確率分布 $b_i(o)$ である。これらの確率は初期値が与えられた状態から訓練によって推定される。出力確率分布とし

て GMM を用いた場合、 $b_i(o)$ は次の式で表される。

$$b_i(o) = \sum_{m=1}^M w_m \mathcal{N}(o; \mu_{im}, \Sigma_{im}) \quad (2.1)$$

$$= \sum_{m=1}^M w_m \frac{1}{(2\pi)^{\frac{d}{2}} |\Sigma_{im}|^{\frac{1}{2}}} \exp\left(-\frac{(o - \mu_{im})^T \Sigma_{im}^{-1} (o - \mu_{im})}{2}\right) \quad (2.2)$$

ここで M は混合数、 μ_{im}, Σ_{im} はそれぞれ状態 i の m 番目の正規分布の平均ベクトル、分散共分散行列である。一般的には分散共分散行列をそのまま用いるのではなく、共分散成分を 0 と仮定した対角化分散共分散行列が用いられる。

観測された特徴ベクトル系列 $O = [o_1, o_2, \dots, o_T]$ について、モデル M_k からの出力確率 $P(O|M_k)$ を計算することを考える。この時、時刻 t で滞在している状態を $q_t (\in S_i)$ とし $Q = [q_1, q_2, \dots, q_T]$ とすると

$$P(O|M_k) = \sum_Q P(O, Q|M_k) \quad (2.3)$$

$$= \sum_Q P(O|Q, M_k) P(Q|M_k) \quad (2.4)$$

となる。ここで初期状態 S_1 から o_1, o_2, \dots, o_t を出力して S_i に至る確率を $\alpha_i(t)$ 、 S_i から o_{t+1}, \dots, o_T を出力して最終状態 S_N に至る確率を $\beta_i(t)$ とすれば、それぞれ以下の漸化式で表現できる。

$$\alpha_i(t) = P(o_1, \dots, o_t, q_t = S_i|M_k) \quad (2.5)$$

$$= \sum_{j=2}^{N-1} a_{ij} \alpha_j(t-1) b_i(o_t) \quad (1 < i < N, 1 < t \leq T) \quad (2.6)$$

$$\beta_i(t) = P(o_{t+1}, \dots, o_T, q_t = S_i|M_k) \quad (2.7)$$

$$= \sum_{j=2}^{N-1} a_{ij} b_j(o_{t+1}) \beta_j(t+1) \quad (1 < i < N, 1 \leq t < T) \quad (2.8)$$

ただし、初期条件は以下のように仮定する。

$$\alpha_1(1) = 1, \alpha_i(1) = a_{1i} b_i(o_1) \quad (1 < i < N) \quad (2.9)$$

$$\beta_i(T) = a_{iN} \quad (1 < i < N) \quad (2.10)$$

これを用いれば、 $P(O|M_k)$ は以下のように表される。

$$P(O|M_k) = \alpha_N(T) = \sum_{i=2}^{N-1} \alpha_i(T) a_{iN} \quad (2.11)$$

$$P(O|M_k) = \beta_1(1) = \sum_{i=2}^{N-1} \beta_i(1) a_{1i} b_i(o_1) \quad (2.12)$$



図 2.3: 先行研究での筋電センサーの貼り付け場所 [17]

式 (2.6), (2.11) の総和を \max だと近似すると、最大尤度を示す経路を求めるビタビアルゴリズムが導かれる。

$$\Phi_i(t) = \left[\max_{1 < j < N} a_{ij} \Phi_j(t-1) \right] b_i(o_t) \quad (1 < i < N, 1 < t \leq T) \quad (2.13)$$

$$\hat{P}(O|M_k) = \Phi_N(T) = \max_{1 < i < N} \Phi_i(T) a_{iN} \quad (2.14)$$

式 (2.11) を用いて計算されるスコアをトレリススコアといい、パラメータ推定に用いられる。また、式 (2.14) を用いて計算されるスコアがビタビスコアといい、認識に用いられる。

筋電波形のスペクトルを用いた分類を試みた先行研究として、例えば発話した際あるいは発話したような口の動きをした際の筋電波形を用いて発話分類をした論文がある [18]。この研究では発話の際および発話の口の動きをした際の筋電波形を 11 チャンネルの筋電センサーから計測して MFCC を計算し、HMM により学習し分析しており、この研究では 9 割近くの認識率を出している。

また、筆者は筋電波形の MFCC 及び HMM を用いてブラキシズムの自動識別を過去に検討している [17]。この研究ではクレンチング、グライディング、タッピングの 3 種類のブラキシズムに対して図 2.3 のように咬筋の筋電を計測して 25 次元の MFCC を計算し、3 状態 HMM を用いて 3 種類のブラキシズムを擬似的に再現したデータでクラス分類を行った。その結果、8 割から 9 割の精度でブラキシズムの自動識別に成功している。HMM は単一の特徴量に対して学習・認識を行うが、複数の特徴量を組み合わせて用いる場合にはそれらを 1 つの特徴量にまとめるのではなく並列に扱うことが望ましい。そこで、複数の特徴量を並列に扱う HMM として、図 2.4 に示すようなマルチストリーム HMM [19] が提案されている。本研究では、複数箇所筋電を同時に扱うためにマルチストリーム HMM を用いる。

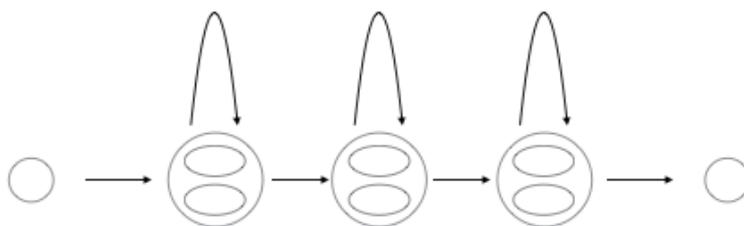
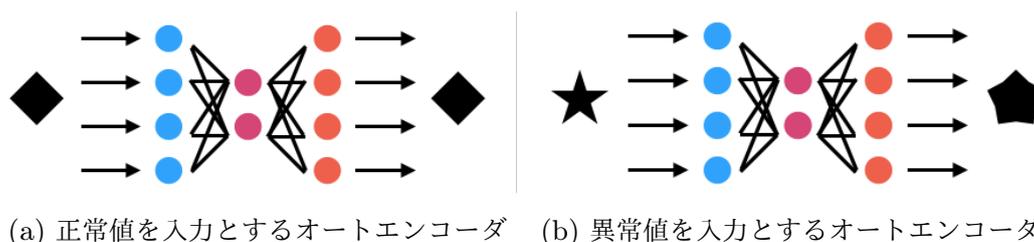


図 2.4: マルチストリーム HMM の模式図



(a) 正常値を入力とするオートエンコーダ (b) 異常値を入力とするオートエンコーダ

図 2.5: オートエンコーダの模式図

2.3 オートエンコーダ

オートエンコーダ (AutoEncoder; AE) とは、ニューラルネットワークの一つであり、図 2.5a に示すように入力 x と出力 y が同じになるように学習するネットワークである。特徴量を入力として受け取ったオートエンコーダは、より少ない次元の特徴量に圧縮する。この際に、入力データについてその重要性に応じて重み付けをすることでより情報としての密度を上げる。これを繰り返し、事前に指定された次元まで圧縮する。この一連の圧縮の過程をエンコードと呼び、エンコード後の特徴量を中間生成物と呼ぶ。中間生成物は入力の特徴量に対して次元圧縮を施したものであることから、入力に対する新たな特徴量として別の学習に用いられる [20]。中間生成物 z に対して、エンコードと同様に情報の重要度で重み付けをして次元数を上げることで、入力と同次元の特徴量を出力する。この過程はエンコードに対してデコードと呼ぶ。この入力と出力の差をなるべく抑えることで、入力と同じものを出力するネットワークを実現する。ここで、入力 x と出力 y の誤差として最もよく使用されるのは以下の式で表される平均二乗誤差 (Mean Squared Error; MSE) である。

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - x_i)^2 \quad (2.15)$$

オートエンコーダは入力と出力の誤差を抑えるように学習するが、図 2.5b のようにそれまでに学習したものと異なるデータを入力すると、入力の再現が困難になり誤差が大きくなる。これを応用したのがオートエンコーダによる異常検知である [21]。学習データとして正常値を用いることで、異常値が入力された際に誤差が大きくなり、閾値を設定しておくことで異常値の入力が検出可能に



図 2.6: オートエンコーダの構造

なる。

本研究で用いるオートエンコーダのネットワーク構造について図 2.6 に示す。各層ではまず全結合層を用いている。全結合層は各層の入出力のニューロン同士が全て結合しているものをさし、シンプルかつ広く用いられている。全結合層の入力ベクトルを X 、出力ベクトルを Y としたとき、出力ベクトル Y は以下のように表される。

$$Y = WX + b \quad (2.16)$$

ここで、 W は各ニューロンに割り振られた重みのベクトルであり、 b はバイアス項である。

全結合層の出力結果は活性化関数に渡す前にバッチノーマライゼーション [22] をかけられる。ニューラルネットワークの学習の際には通常膨大なデータを用いるため、1つ1つのデータをネットワークに入力していくのではなく、1度の学習で複数のデータを同時に用いる。この方法をミニバッチ法と呼び、数百から数千個を1回の学習に用いることが多い。そこで、この学習をスムーズに行い、かつ精度を上げる方法として提案されたのがバッチノーマライゼーションである。バッチノーマライゼーションはミニバッチ内の全データに対して正規化を行う処理であり、この処理によって平均分散を新しくしている。

バッチノーマライゼーション後のデータは活性化関数に渡される。活性化関数とはニューラルネットワークの表現力を上げるために導入されている関数で、線形変換を行う各層に対して非線形変換を行う。本研究では近年広く用いられている ReLU 関数 [23] を用いる。変換は非常にシンプルであり、負の値は 0、正の値は入力をそのまま出力する関数である。計算量が少なく活性化関数を導入できるために広く用いられている。

ここまでで解説したように、各層では全結合層、バッチノーマライゼーション、活性化関数によって入力を出力に変換している。エンコーダで 3 層、デコーダで 3 層ずつあり、次元数は実際の

実験について記述する際に記載する。基本的にはエンコーダとデコーダは対称的なネットワークとなっているが、デコーダの最後の出力前に Dropout [24] と呼ばれる処理を行っている。Dropout とは割合を事前に指定し、ニューラルネットワークの学習時に指定した割合のノードを不活性化させることで過学習を緩和するというものである。

以上が本研究で用いたオートエンコーダのネットワーク構造である。このようなオートエンコーダに対してデータを入力して出力との平均二乗誤差を計算することで損失とし、この損失をなるべく小さくするようにオートエンコーダは学習する。そこで、この損失を小さくするためのパラメータを計算するために用いられるのが最適化手法であり、本研究では Adam [25] を用いる。

最適化手法はこれまでに多くの種類が提案されており、それぞれの手法の欠点を補う形で新しい方法が考案されてきた。最も単純な手法は最急降下法である。最急降下法はパラメータで損失関数を微分することで、損失を小さくする方向を逐次的に探索し、その方向にパラメータを調整させていく方法である。パラメータを w とした時、その更新式は以下のように表される。

$$w_{t+1} = w_t - \alpha \nabla_w \mathcal{L}(w) \quad (2.17)$$

ここで $w_t, \alpha, \nabla_w, \mathcal{L}(w)$ はそれぞれ、更新 t 回目のパラメータ、学習率、パラメータでの微分、損失関数である。 $\nabla_w \mathcal{L}(w)$ の部分が損失を小さくする方向を表し、学習率 α がパラメータ更新の割合を表している。学習率を大きくし過ぎれば最小値となるパラメータを飛ばしてしまうオーバーシュートを起こし、逆に小さすぎると収束時間が膨大になるため、学習率の調整は最適化において重要である。

最急降下法では初期値として与えられたパラメータから微分によって損失を小さくするため、極小値においてもパラメータ更新が止まってしまうという問題がある。そこで、使用するデータを減らすことで勾配計算にランダム性を持たせた確率的勾配効果法 (SGD)、ミニバッチ学習 SGD といった手法が提案された。次に、これらの問題点を考える。SGD ではオーバーシュートがおきやすい設計をされているため、極小値をとるパラメータが空間上で近接していると、振動を起こしてしまい最小値にたどりつきにくい。そこで、過去の勾配変化を用いて更新式のパラメータを更新するという手法が考案されている。具体的な手法として、モーメンタム法 [26] と RMSProp [27] の 2 種類が提案されており、これらを組み合わせた手法が Adam である。

モーメンタム法では勾配の移動平均をとることでその振動幅を抑える手法である。以下にその更新式を示す。

$$\nu_t = \beta \nu_{t-1} + (1 - \beta) \nabla_w \mathcal{L}(w) \quad (2.18)$$

$$w_t = w_{t-1} - \alpha \nu_t \quad (2.19)$$

ここで、 $\nu_{t-1}, \nabla_w \mathcal{L}(w), \nu_t$ はそれぞれ $t-1$ 回目の勾配、現在の勾配、 t 回目の勾配を表している。第 1 式は勾配の移動平均をとって勾配の更新をしている式となっており、第 2 式で計算結果からパラメータ更新をしている。

RMSProp では学習率を勾配の大きさに応じて調整することで、オーバーシュートしている際に

学習率を自動で小さくするという手法である。以下にその更新式を示す。

$$\nu_t = \beta\nu_{t-1} + (1 - \beta)(\nabla_w \mathcal{L}(w))^2 \quad (2.20)$$

$$w_t = w_{t-1} - \frac{\alpha}{\sqrt{\nu_t + \epsilon}} \nabla_w \mathcal{L}(w) \quad (2.21)$$

ここで、 ϵ は非常に小さい値である。これは、第1式において ν_t が0になる場合に第2式の2項目がゼロ除算となるのを防ぐために導入されている。第1式では、振動が大きくなるほど計算結果が大きくなる。この値で学習率を割ることで、勾配変化が大きくなると学習率が小さくなるように調整される。

モーメンタム法と RMSProp を組み合わせた手法が本研究で用いる、近年広く用いられている Adam である。その更新式もモーメンタム法と RMSProp を組み合わせたものとなっており、以下のように表される。

$$\nu_t = \beta_1\nu_{t-1} + (1 - \beta_1)\nabla_w \mathcal{L}(w) \quad (2.22)$$

$$s_t = \beta_2 s_{t-1} + (1 - \beta_2)(\nabla_w \mathcal{L}(w))^2 \quad (2.23)$$

$$w_t = w_{t-1} - \alpha \frac{\nu_t}{\sqrt{s_t + \epsilon}} \quad (2.24)$$

2.4 モデル間比較

本章では HMM 及びオートエンコーダの2つのモデルについて記載してきたが、これらのモデルでブラキシズム検出を行う際、その過程は大きく異なる。HMM では、ブラキシズム及びアーチファクトとなる各種行動について、それぞれの MFCC を学習データとして各クラスの HMM を作成する。その後、テストデータの MFCC に対して HMM による認識を行い、ブラキシズムか否かを判別する。一方でオートエンコーダでは、ブラキシズムを行っていない正常状態での MFCC のみを学習データとし、テストデータの MFCC に対してオートエンコーダを適用してその出力誤差からブラキシズムか否かを判別する。つまり、HMM はブラキシズムの MFCC も学習データとして必要とする教師あり学習であるのに対して、オートエンコーダはブラキシズムを行っていないデータのみを学習データとする教師なし学習である。よって、HMM は学習データとしてブラキシズムの MFCC を用意できるかどうか重要であり、オートエンコーダは学習データよりもネットワークそのものをうまく調整できるかが重要である。

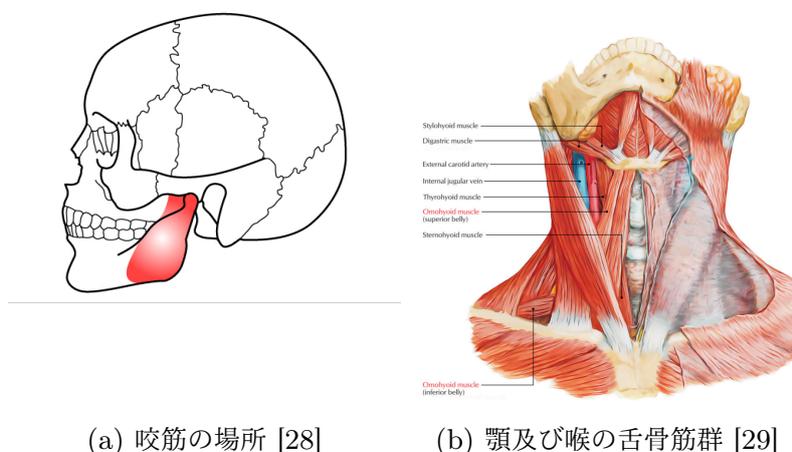
第3章

ブラキシズムデータの計測

3.1 筋電波形の計測箇所の検討

筋電を計測するには、どこの筋肉を選択して計測するかが非常に重要である [30]。PSG などブラキシズム検出において筋電波形を計測するには表面電極と呼ばれる電極を用いる。表面電極は皮膚の表面に貼る電極で、針電極やワイヤー電極といった電極と異なり、貼り付けた近辺の筋繊維全ての複合活動電位を計測できるのが特徴であり、対象の筋肉群の活動を観測するという目的においては最も優れている。表面電極を用いた計測の際は、各電極に一定の間隔をあけて貼ることになり、貼った部分の周りの多くの筋繊維の複合活動電位を計測する。そのため、電極周辺において大きな筋肉群が表面にあることが望ましい。本研究では、咀嚼に関わる頬、顎、喉にある筋肉群のうち、合計 6 カ所に電極を貼付した。

図 3.1a に示される咬筋は頬の部分に存在し、主に咀嚼の際に用いられる咀嚼筋と呼ばれる筋肉群の 1 つである。また、咬筋は主に閉口時の力を加える際に動く。ブラキシズムには、噛み締めるクレンチングや噛み合わせるタッピング、歯を擦り合わせるグラインディングの 3 種類があるが、こ



(a) 咬筋の場所 [28]

(b) 顎及び喉の舌骨筋群 [29]

図 3.1: 筋肉群の配置図

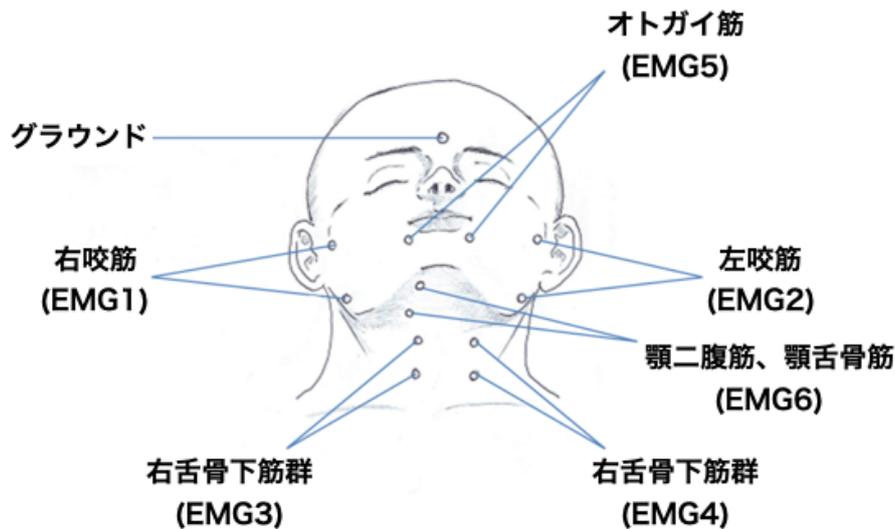


図 3.2: 電極貼付位置

これらのいずれにおいても口を閉じる力が加わる。このことから咬筋は最も重要な筋肉の一つとなることが予想される。また、咀嚼は通常左右どちらか片側で行われ、さらに人によって好んで咀嚼する側が存在することが知られている [31] が、ブラキシズムにおいても同様に左右の偏りがあると考えられることから、左右それぞれの咬筋に電極を貼付した。図 3.1b に示される舌骨筋群は口の開閉に関与する筋肉群である。そのうち、舌骨下筋群は喉周辺の比較的大きな筋肉から成るため、電極の安定性及び入力の大きさから計測対象として適切と判断し、この周辺についても左右それぞれに電極を貼付した。また、舌骨筋群のうち、顎に位置する舌骨上筋群も開口時に大きな力が加わる。よって、開口する筋肉の動きを判別するために有用と考えた。ただし、睡眠時の体動などにより、顎の下の正中部分は、皮膚が動きやすく電極の安定性に欠けると判断した。よって、舌骨上筋群の計測は、口の下で電極でオトガイ筋を、顎の下で電極で顎二腹筋、顎舌骨筋を対象として計測した。

図 3.2 に示すように、1) 右咬筋、2) 左咬筋、3) 右舌骨下筋群、4) 左舌骨下筋群、5) 顎二腹筋と顎舌骨筋、6) オトガイ筋の合計 6 つの位置について 2 つずつ電極を貼り付けることで、電位差として筋電を計測した。以降これらの筋肉から計測される筋電を順番に EMG1,2,...,6 と呼ぶ。ただし、頭部にはグラウンドとして別途 1 つ電極を貼り付けている。

3.2 意識的ブラキシズムデータ

3.2.1 計測概要

本研究は睡眠時ブラキシズムの自動検出を目的とするが、実際の睡眠時データは何時間にも及ぶものであることから、手法の妥当性の確認や特徴量の選定の上では簡易的なデータを別途用意する

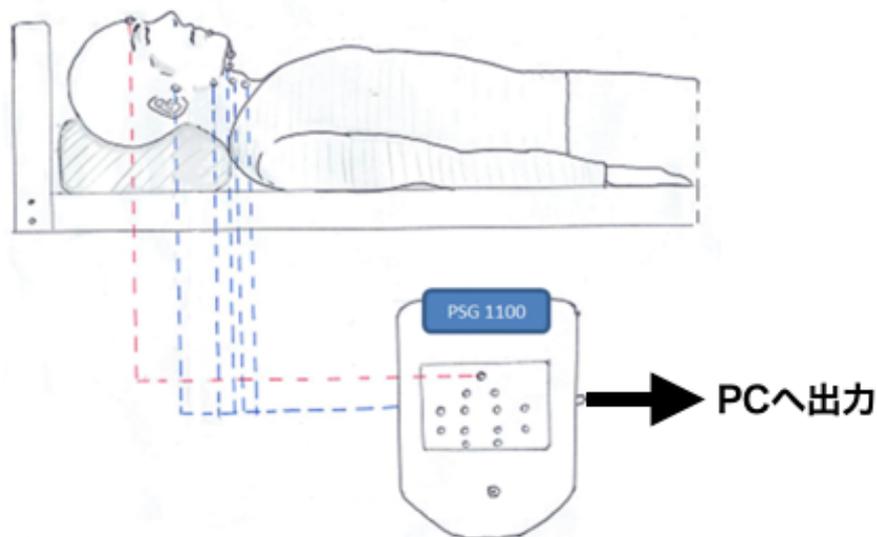


図 3.3: 筋電計測の概要図

のが好ましいと考えた。そこで、ブラキシズム及び体動等の非ブラキシズムを意識的に再現したデータを計測する。このデータを以降「意識的ブラキシズムデータ」と呼ぶ。

意識的ブラキシズムデータの筋電計測時のセットを図 3.3 に示す。本データの収集においては、岡山大学大学院医歯薬学総合研究科の協力を得て、睡眠時ブラキシズムの介入・探索的臨床研究として同大学の臨床研究審査専門委員会の倫理審査を受けている。サンプリング周波数は 1kHz である。EMG1 から EMG6 の 6 つの筋肉群を対象として、表面電極を貼付する。また、グラウンドとして頭部に 1 つ電極を貼付した。ノイズ低減のために被験者の電極を貼る部分に対してアルコールを塗布しインピーダンスを小さくした。

被験者は 20~40 代の健康な男女計 12 名である。被験者にははじめに検査室内のベッドに仰臥位にて安静状態をとってもらう。その後、1) 最大咬合力でのクレンチング、2) 最大咬合力の半分の力でのクレンチング、3) 擬似クレンチング、4) タッピング、5) グラインディング、6) 嚥下（飲み込み）、7) あくび、8) 発話、9) 搔痒（かゆいところを搔くこと）、10) 体動、11) いびきをこの順番で実施した。それぞれの行為は、行為間にとった 5 秒間の安静状態を含めて 1 分間で計測したため、合計 11 分間の筋電波形が得られる。1) から 5) はそれぞれ 5 秒間ずつ 5 回、計 25 秒間実施した。6) から 10) は時間指定はせず、5 回実施した。11) は 10 秒間ずつ、数回行わせた。また、2) の最大咬合力の半分の力については、筋電波形のモニターを被験者本人が確認しながら、おおよそ半分の力を出すようにした。

3.2.2 計測結果の確認

このようにして計測した筋電波形の例を図 3.4 及び図 3.5 に示す。図の横軸は時間を表し、縦軸は筋電波形の振幅の大きさを表している。また、1) の最大咬合力でのクレンチングは図の 0 分から

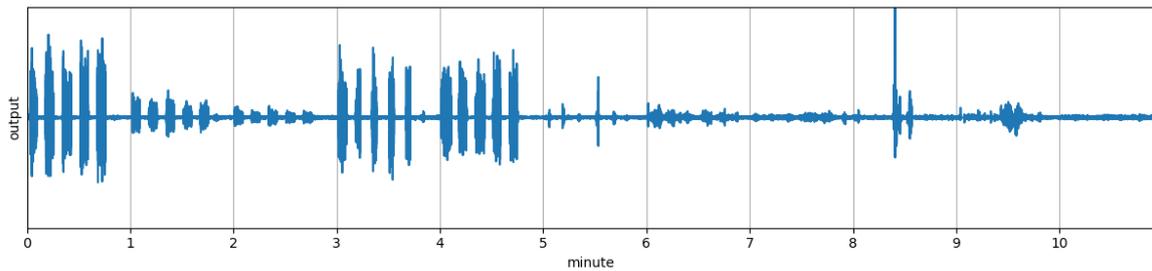


図 3.4: 咬合力が大きい被験者の咬筋で計測した筋電波形の例

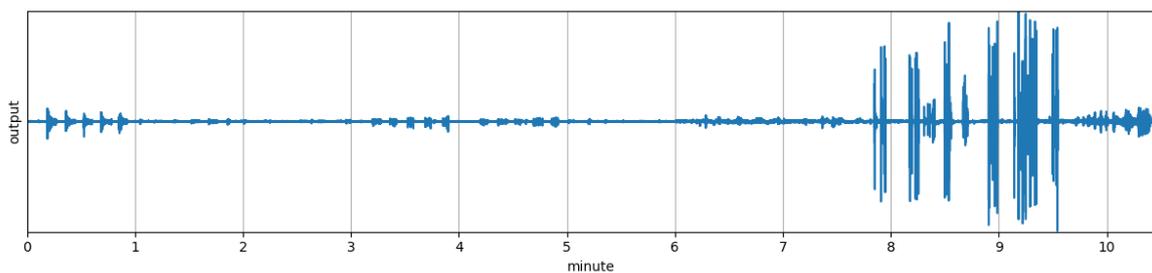


図 3.5: 咬合力が小さい被験者の咬筋で計測した筋電波形の例

1分に、2)の最大咬合力の半分の力でのクレンチングは図の1分から2分というように、1)から11)のブラキシズムやその他の行動が1分ごとに図の波形と対応している。また、いずれも咬筋で計測した筋電波形を用いている。

図 3.4 は咬合力の大きい被験者の咬筋で計測した筋電波形である。全体を通して見れば、ブラキシズムや擬似クレンチングを行っている0分から5分までの間の筋電波形の振幅が、それ以外の嚙下や体動などを行った5分以降の筋電波形の振幅よりおよそ大きい。このような場合には振幅を用いてブラキシズム検出を行った際にも一定の精度が出ると思われる。これに対し、図 3.5 は咬合力が小さい被験者の咬筋で計測した筋電波形であるが、全体を通してブラキシズムとそれ以外で筋電波形の振幅の大きさに差異がない。一方、9)搔痒や10)体動の区間と比較すれば、ブラキシズムの際の数倍の振幅を示している。このような場合は図 3.4 のような筋電波形とは異なり、振幅のみでブラキシズム検出を行った際にはブラキシズム以外をブラキシズムと誤検出してしまう可能性がある。

以上のように、筋電波形の振幅のみを用いてブラキシズム検出を行う場合には被験者の咬合力を考慮する必要があり、その強さが小さい場合にはブラキシズム以外の行動と同等かそれ以下の振幅となり、誤検出の可能性が高くなる。一方で、筋電波形のスペクトルを用いてブラキシズム検出を行う場合、その振幅の大きさにかかわらず周波数成分を比較することから、このような誤検出を減らすことができると思われる。

ここまでは被験者の咬合力による筋電波形全体の違いを確認した。次に同一被験者内での行動ごとの筋電波形の違いを確認する。図 3.6 にそれぞれの行動によって発生した筋電波形に対して、行動ごとに区切ったものを示す。図中の番号1から11は、1)最大咬合力でのクレンチングのような

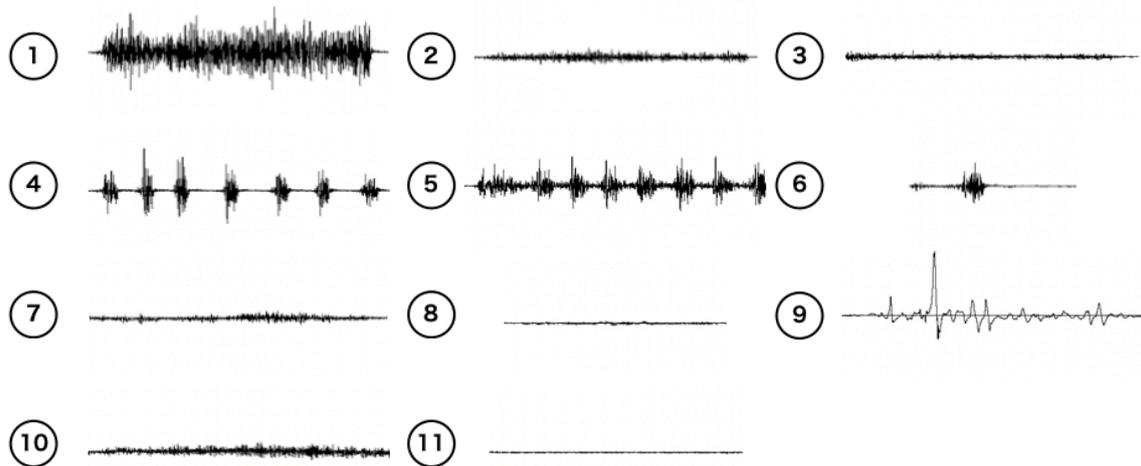


図 3.6: 同一被験者の咬筋で計測した各行動の筋電波形

それぞれの行動の番号と対応している。これら 11 個の筋電波形はいずれも同一の被験者の筋電波形であり、振幅方向の縮尺は全て同一である。また、全体波形を示した際と同様に図 3.6 で示す波形は咬筋で計測した筋電波形である。

図 3.6 を見ると、まず 4) タッピング、5) グラインディング、9) 搔痒の筋電波形が特徴的であると言える。タッピングとグラインディングについては、いずれも口から顎にかけての筋肉を左右あるいは上下に大きく動かすブラキシズムである。そのため、加わる力の大きさが一定ではないことから、最大咬合力で持続的に食いしばる 1) クレンチングとは異なる筋電波形を示していると考えられる。また、9) 搔痒については、搔く動作を伴うため、貼り付けている電極に外部から力が加わることで、他の行動とは大きく異なる波形を示していると考えられる。この点から言えば、10) 体動についても、体全体が動くことで電極に外部からの力が加わるため、独特な筋電波形を示す可能性があると言える。他に 6) の嚙下は、その行動が非常に短い時間で完結するため、他の行動とは波形が異なる。

以上のように筋電波形の形状が行動によって大きく異なることが確認できた。この波形の形状の違いをスペクトルという特徴量にすることで、ブラキシズム検出の精度向上に繋がるか検討する。

3.3 無意識的ブラキシズムデータ

3.3.1 計測概要

睡眠時ブラキシズムの検討のために実際の睡眠時データも収集した。このデータを「無意識的ブラキシズムデータ」と以降記載する。

無意識的ブラキシズムデータの筋電計測時にも意識的ブラキシズムデータと同様に EMG1 から EMG6 に対して筋電計測を行った。ただし、睡眠時データを計測するために電極の上から網状のネットで顎周辺を覆い固定した。被験者は 20 代男性 1 名であり、被験者の自室のベッドで睡眠中

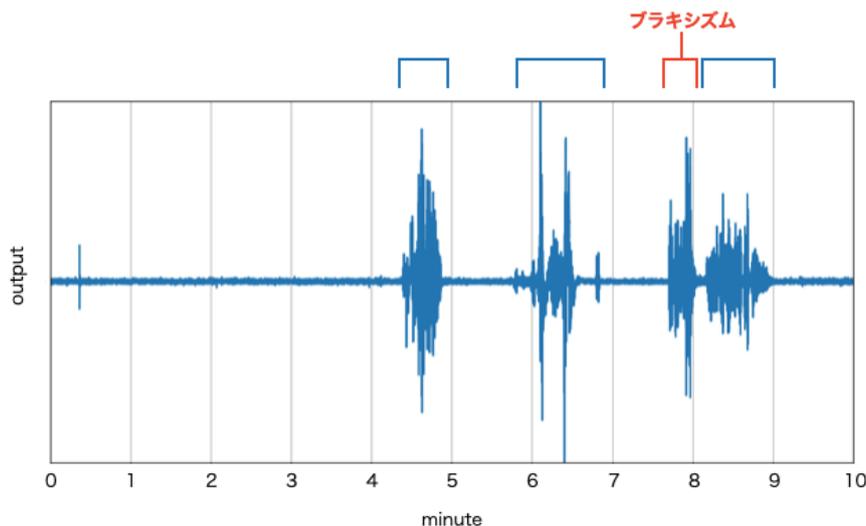


図 3.7: 無意識的ブラキシズムデータにおける咬筋で計測した筋電波形の例

のデータを収集した。

意識的ブラキシズムデータとは異なり、ブラキシズム及びそれ以外の睡眠時の行動を行う時間が決まっていないため、波形やビデオ目視によるラベリングを別途する必要がある。本研究では上述の岡山大学の共同研究者に依頼し、計測したブラキシズムデータについてブラキシズム及びそれ以外の睡眠時の行動を行っている時間を同定した。

また、睡眠時ブラキシズムデータは数時間に及ぶ膨大なデータであるため、後に解析しやすいように 10 分ごとに区切って通し番号をつけた。

3.3.2 計測結果の確認

このようにして計測した筋電波形の一例を図 3.7 に示す。図の横軸は時間を表し、縦軸は筋電波形の振幅の大きさを表している。計測した無意識的ブラキシズムデータについては解析のために 10 分ごとに区切っているため、そのうちの 1 区間を提示している。また、図 3.7 では咬筋で計測した筋電波形を示している。

図 3.7 では、睡眠時の無意識的ブラキシズムデータを示しているため、意識的ブラキシズムデータとは異なり、ブラキシズムをしている区間や体動をしている区間などがはっきりと表れない。示した筋電波形では、8 分手前の大きな塊になっている部分がブラキシズムであり、それ以外の塊は全て体動によるものである。このように、無意識的ブラキシズムデータでは、ブラキシズムとそれ以外の行動との間で、振幅の大きさに大差がないことが多く、振幅のみを用いたブラキシズム検出においてブラキシズムだと誤検出する割合が大きいことがわかる。ただし、波形の形状の差についても意識的ブラキシズムデータと比較すると各動作間の違いは大きくないため、意識的ブラキシズムデータより認識精度が低下することが予測できる。

第 4 章

筋電特徴量の選定

4.1 実験概要

2 章で記載したように、本研究ではマルチストリーム HMM やオートエンコーダを用いる。そのため、3 章で計測した 6 つの筋肉の筋電信号について個別に扱うのではなく、いくつかの筋電信号について同時に扱う。よって、どの筋電信号を同時に用いるかを事前に精査しておく必要がある。そこで、これらの筋電信号に対して、MFCC に変換して特徴量とする。これらの特徴量について、実際に単一の特徴量を扱う HMM を用いてブラキシズムの自動検出を試みることで、以降用いる特徴量の選定を行う。

4.2 意識的ブラキシズムデータに関する検討

3 章で計測した意識的ブラキシズムデータの筋電信号について、ハミング窓を窓長 100ms シフト長 50ms としてかけて MFCC を計算した。MFCC は 0 次項を含む 13 次元及びその Δ 特徴量を合わせた 26 次元を用いた。商用電源に由来するハムノイズはハムフィルタで取り除いている。

本節では出力の確率分布が混合数 10 のガウス分布である 3 状態単一ストリーム HMM を用いる。ブラキシズム、擬似クレンチング、それ以外の 3 つのクラスを用意し、EMG1 から EMG6 のそれぞれの特徴量について、3 つずつ HMM を構築した。表 4.1 に示すように、ブラキシズムにはクレンチング・グラインディング・タッピングが、擬似クレンチングには擬似クレンチングが、それ以

表 4.1: クラス分類

クラス	対応する行為
ブラキシズム	クレンチング、グラインディング、タッピング
擬似クレンチング	擬似クレンチング
それ以外	嚙下、あくび、発話、搔痒、体動、いびき、安静状態

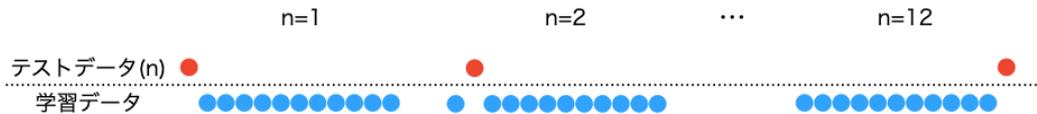


図 4.1: データ配分の概要図

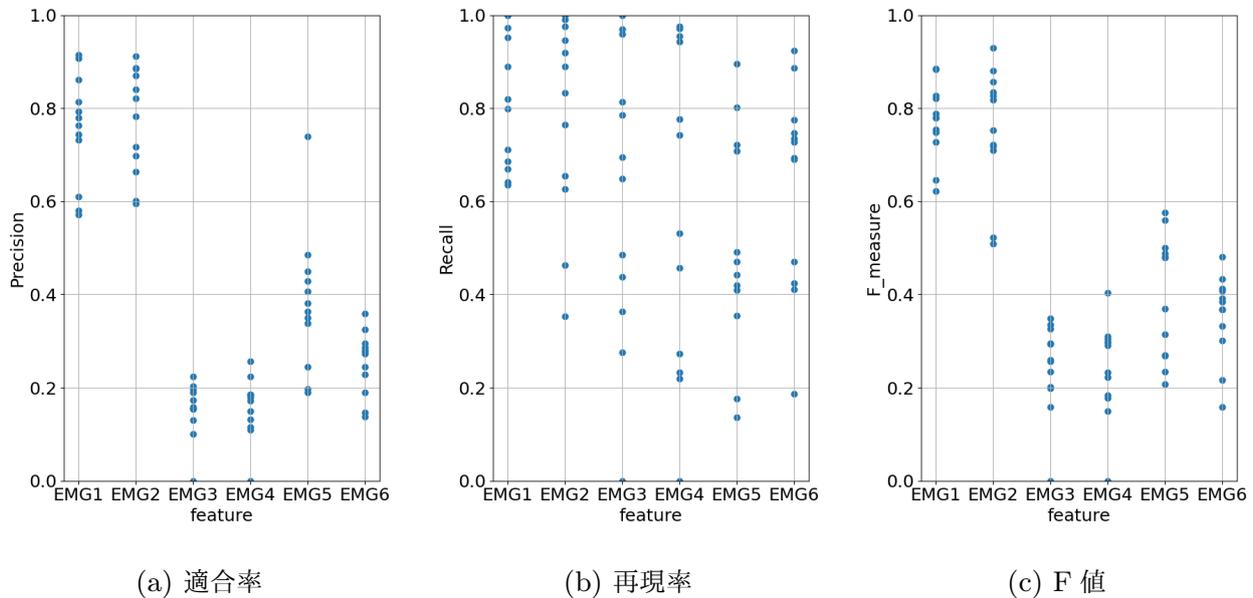


図 4.2: 意識的ブラキシズムデータを対象とし個々の筋電を特徴量とした HMM でブラキシズムを検出した結果。1 つ 1 つの点が被験者それぞれの結果に対応する。

外には嚙下・あくび・発話・搔痒・体動・いびき及び安静状態がそれぞれ該当する。なお、本研究で「検出性能を評価する」と記述する場合、ブラキシズムのクラスについての評価を意味する。

学習データとテストデータは、図 4.1 に示すように 1 人の被験者のデータをテストデータとし、被験者以外の 11 人のデータを学習データとすることを 12 人それぞれに対して行う。検出性能の評価の際には、ブラキシズムと予測したものが正しくブラキシズムとして検出される確率である「適合率」、および本来ブラキシズムであるものがブラキシズムと検出される確率である「再現率」、適合率と再現率の調和平均である「F 値」の 3 つの指標を用いて評価する。

4.3 意識的ブラキシズムデータの結果・考察

結果を図 4.2 及び表 4.2 に示す。縦軸は図 4.2a は適合率、図 4.2b は再現率、図 4.2c は F 値をそれぞれ表しており、横軸はどの表面筋電位 (EMG) を使用したかを表している。図の点 1 つ 1 つが被験者それぞれの結果に対応している。また、表 4.2 はそれぞれの指標について筋電ごとに 12 人の被験者の平均をとったものである。これらの図表を見ると、まず EMG1 及び EMG2 のデータを利用することで、極めて高い検出性能が得られるということがわかる。これは、[17] でも用いた閉口

表 4.2: 意識的ブラキシズムデータを対象とした HMM のブラキシズム検出性能の評価結果 (被験者平均)

	EMG1	EMG2	EMG3	EMG4	EMG5	EMG6
適合率	0.756	0.772	0.153	0.158	0.381	0.250
再現率	0.815	0.784	0.619	0.590	0.502	0.639
F 値	0.772	0.757	0.242	0.239	0.396	0.355

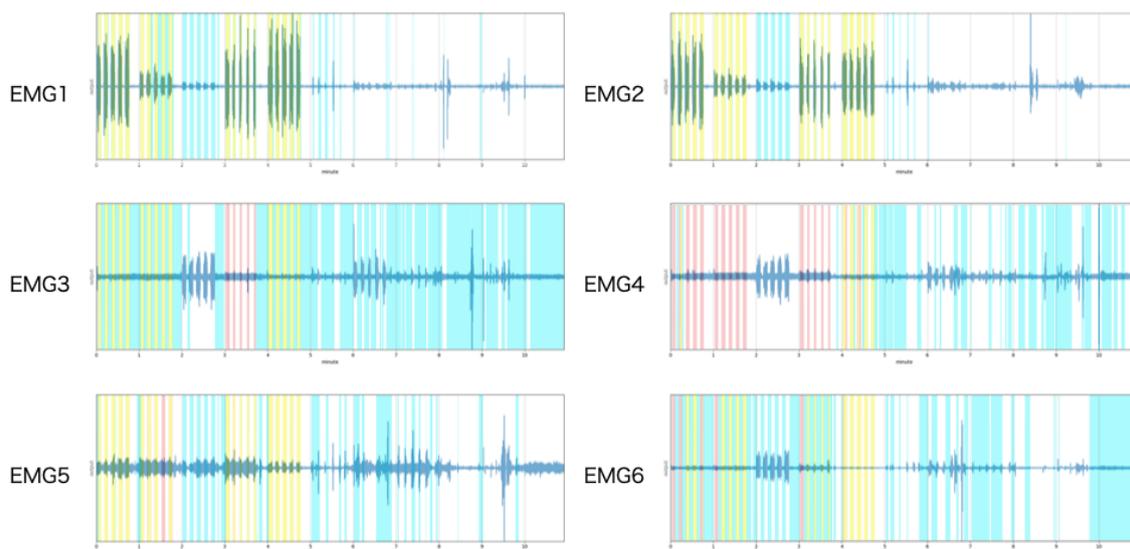


図 4.3: それぞれの EMG での筋電波形及び検出結果

時に用いられる筋肉である頬の咬筋が、最もブラキシズム検出において有用であることを示している。それ以外の電極から得られたデータでは、再現率は平均して 0.5 から 0.6 程度の値を示しているのに対して、適合率は平均して 0.1 から 0.4 の間の値を示しており、総合して再現率の方が適合率より高いという結果が得られた。このことから、偽陽性の割合が高い、つまりブラキシズムではないのにブラキシズムだと検出する率が高いことが示された。

また、図 4.3 にある被験者の各 EMG での筋電波形とその検出結果を示す。黄色く網がかかっている部分が、ブラキシズムであると正しくブラキシズムと検出している区間で、赤色の部分はブラキシズムであるところをブラキシズムでないと検出している (偽陰性) 区間で、水色の部分はブラキシズムでないところをブラキシズムと検出している (偽陽性) 区間である。

図 4.3 を見ると、EMG1 や EMG 2 では、正しくブラキシズムを検出している黄色の区間が多く、水色の偽陰性の区間が少ない。また、EMG3, EMG4 では赤色の偽陰性の区間が他の EMG と比較して多い。EMG5, 6 ではブラキシズムの検出の見逃しは少ないもののブラキシズム以外をブラキシズムだと誤検出する箇所は多い。これらの図 4.3 から読み取れる傾向は前述した数値上の傾向と同様のものを示している。つまり、EMG1, 2 においては水色も赤色も少ないので適合率も再現率

も高く、EMG3,4においては赤色が多く見られるため適合率が低く、EMG5,6においては赤色が少ないものの水色は多いため適合率がEMG3,4よりは高く再現率は高くない。

上記のような数値で読み取れる情報の確認とは別に、図4.3からのみ読み取れる情報として、擬似クレンチングに関する検出精度があげられる。擬似クレンチングは、ブラキシズムに類似した閉口筋の力の加わり方をする。そのため、EMG1,2においてはブラキシズムと誤検出してしまっている。一方で、擬似クレンチングはブラキシズムと比較して、開口筋にも強い力が加わるという特性があるため、EMG3,4,6のような開口時に力の加わる筋肉においては誤検出されていない。

意識的ブラキシズムデータのみで考慮した結果としては、EMG1,2を用いることでブラキシズム検出の精度向上に繋がると推測される。一方で、EMG3,4,6のような開口筋を用いる利点も確認できたため、無意識的ブラキシズムデータでの結果次第では、これらの筋肉を用いることも検討すべきことが示された。

4.4 無意識的ブラキシズムデータに関する検討

前節において意識的ブラキシズムデータについてHMMを用いたブラキシズム検出を検討した。本節では無意識的ブラキシズムデータについて同様の検討を行う。

意識的ブラキシズムデータと無意識的ブラキシズムデータの間で主に異なる点として、ブラキシズム全体に占める各データの割合がある。収集したデータのうち、意識的ブラキシズムデータの中では、分析対象になる部分が全体の15%ほど存在するのに対し、無意識的ブラキシズムデータは睡眠中で筋電波形に変化のない時間が多く含まれるため、分析対象になるのは5%程度と非常に少ない。この点を考慮し、学習データとしては意識的ブラキシズムデータを用いつつ、以下に記述されるようにクラスを減らして検出実験を行った。

3章で計測した無意識的ブラキシズムデータの筋電信号について、ハミング窓を窓長100msシフト長50msとしてかけてMFCCを計算した。MFCCは0次項を含む13次元及びその Δ 特徴量を合わせた26次元を用いた。

本節でも前節と同様に、出力の確率分布が混合数10のガウス分布である3状態単一ストリームHMMを用いる。しかし、クラス分類は前節とは異なりブラキシズムとそれ以外の2つとし、擬似クレンチングは個別のクラスを用意しなかった。これは、今回得られた無意識的ブラキシズムデータでは擬似クレンチングを行う区間が非常に少なく、個別のクラスを用意するにはデータが不足していると判断したからである。

学習データは前節で計測した12名の意識的ブラキシズムデータを利用し、テストデータとして無意識的ブラキシズムデータを利用した。評価の際には適合率、再現率、F値を計算した。

4.5 無意識的ブラキシズムデータの結果・考察

結果を表4.3に示す。被験者が1名のためデータ全体における率を計算して表に示している。意識的ブラキシズムデータの際と同様、EMG1及びEMG2はEMG3やEMG4と比べて非常に高い

表 4.3: 無意識的ブラキシズムデータを対象とした HMM のブラキシズム検出性能の評価結果

	EMG1	EMG2	EMG3	EMG4	EMG5	EMG6
適合率	0.678	0.470	0.015	0.023	0.187	0.535
再現率	0.640	0.752	0.280	0.459	0.783	0.687
F 値	0.658	0.578	0.028	0.045	0.303	0.601

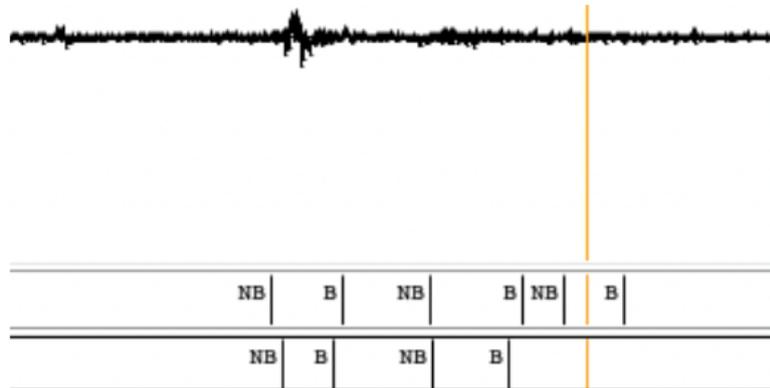


図 4.4: EMG6 における検出結果の例。上段がラベル、下段が検出結果である。

F 値を示している。一方で、EMG6 の F 値が EMG1 と EMG2 の間の値となっている。さらに、図 4.4 に示すように、筋電波形の目視では検出できないようなブラキシズムについても HMM によって検出できていたことから、意識的ブラキシズムデータの場合とは異なり EMG6、つまり開口時に用いられる筋肉であるオトガイ筋についてもブラキシズム検出において有用であることが示された。

意識的ブラキシズムデータを用いた場合でも、EMG6 は擬似クレンチングを考慮した検出における有用性が示唆されたものの、EMG1,2 に比較すれば、その検出性能は大きく劣っていた。しかし、無意識的ブラキシズムデータにおいては EMG6 がブラキシズム検出全体において有用であると示されている。この差の原因としてはいくつか考えられる。まず、意識的ブラキシズムか無意識的ブラキシズムかの違いである。ブラキシズムが無意識に行われるものと意識的に再現したものとの間で力の加わり方に差があるという点に加えて、別の行動でも波形に差が生じるものと考えられる。特に、体動や搔痒といった行動は意識的に行う場合、電極が剥がれないように意識するなどの様々な要因で無意識的な行動と比較して制御される傾向がある。そのため、ブラキシズムと同様に意識的か無意識的かで差が生じてしまった可能性がある。また、電極の付け方の差も原因としてあげられる。無意識的ブラキシズムを計測する際には、睡眠中の長時間の計測に加えて、無意識下の体動や搔痒の影響を考慮して、厳重に貼付する必要がある。一方で、意識的ブラキシズムの計測は、15 分程度と短時間であり、電極が剥がれるリスクは低いことから、無意識的ブラキシズムの計測と比べて貼付方法は簡便であった。どちらにおいても電極が剥がれることはなかったものの、電

極にかかる力が異なることが考えられ、この差が影響を与えた可能性もある。

4.6 まとめ

本章では、ブラキシズムを意図的に行い再現したブラキシズムデータおよび実際の睡眠時にとった無意識的ブラキシズムデータの2種類について、6つの部位から得られた特徴量のうち、ブラキシズムの検出性能を評価するにあたり有用な部位を選定するための検討を行った。結果として、開口時及び閉口時に用いられる頬の筋肉、顎の筋肉の計3箇所 (EMG1,EMG2,EMG6) が最も有用であると示された。以降の章ではこの3箇所の筋肉に着目し、意識的ブラキシズムデータ及び無意識的ブラキシズムデータについてブラキシズム検出の精度を向上させる方法を検討する。

第 5 章

マルチストリーム HMM を用いたブラキシズム検出の検討

4 章ではブラキシズム検出において用いる特徴量の選定を行った。本章ではマルチストリーム HMM によってその特徴量を総合的に利用し、ブラキシズム検出の精度向上を検討する。

5.1 実験概要

マルチストリーム HMM は複数の特徴量を並列に扱うことのできる HMM である。4 章での検討結果から、本章では EMG1,EMG2,EMG6 をマルチストリーム HMM で同時に扱い、意識的ブラキシズムデータ及び無意識的ブラキシズムデータの両方について検討する。

また、本章では先行研究との比較を目的とし、それぞれのエネルギーのみを用いた検出実験も実施する。ここでいうエネルギーとはおよそ筋電波形の振幅に相当するものであり、従来のブラキシズム検出で用いられてきた方法である。そこで、従来型のエネルギーのみを用いた場合と、マルチストリーム HMM を用いた場合の検出精度の比較検討を行う。

5.2 モデル構築

EMG1,EMG2,EMG6 を並列に扱うことから、その特徴量の次元数は通常の MFCC を用いる場合 78 次元、エネルギーのみを用いる場合で 3 次元となる。モデルとしてはいずれの場合にも混合数 10 のガウス分布を出力確率とするストリーム数 3 のマルチストリーム HMM を用いる。クラスについては、意識的ブラキシズムデータではブラキシズム、擬似クレンチング、それ以外の 3 つであり、無意識的ブラキシズムデータではブラキシズムとそれ以外の 2 つである。学習データとテストデータは、意識的ブラキシズムデータでは図 4.1 に示すように 1 人の被験者のデータをテストデータとし、被験者以外の 11 人のデータを学習データとすることを 12 人それぞれに対して行う。無意識的ブラキシズムデータでは学習データは 12 名の意識的ブラキシズムデータを利用し、テストデータとして無意識的ブラキシズムデータを利用した。いずれの場合も検出性能の評価には、適

表 5.1: マルチストリーム HMM によるブラキシズムの検出結果

	被験者 ID					
	1	2	3	4	5	6
適合率	0.877	0.611	0.926	0.869	0.910	0.716
再現率	0.641	0.922	0.695	0.908	0.904	0.942
F 値	0.740	0.735	0.794	0.888	0.907	0.813
	被験者 ID					
	7	8	9	10	11	12
適合率	0.899	0.903	0.872	0.820	0.647	0.698
再現率	0.840	0.958	0.989	0.912	0.791	0.999
F 値	0.868	0.930	0.927	0.863	0.712	0.822
	意識的データ平均			無意識的データ		
適合率	0.812			0.623		
再現率	0.875			0.915		
F 値	0.833			0.741		

表 5.2: マルチストリーム HMM によりエネルギーのみを用いたブラキシズムの検出結果

	意識的データ平均	無意識的データ
適合率	0.714	0.270
再現率	0.630	0.911
F 値	0.614	0.416

合率、再現率、F 値の 3 つの指標を用いて評価する。

5.3 結果

結果を表 5.1 及び表 5.2 に示す。表 5.1 において被験者 ID のついているものは意識的ブラキシズムデータの 12 人の被験者の検出結果であり、最下段が無意識的ブラキシズムデータの検出結果である。また、表 5.2 ではエネルギーのみを特徴量とした際の検出結果を記載している。

表 5.1 によれば、意識的ブラキシズムデータ及び無意識的ブラキシズムデータどちらにおいても、全体としては再現率の方が適合率よりも高い傾向がある。また、4.3 節の結果と比較すれば、意識的ブラキシズムデータの平均値は適合率、再現率、F 値のいずれにおいても EMG1,2 の結果より 0.05 ほど高くなっている。一方で、無意識的ブラキシズムデータでは再現率及び F 値が 4.5 節の結

果と比較して非常に高いのに対して、適合率では EMG1 よりも低い。

また、表 5.2 と比較すれば、全体としてエネルギーのみを用いたものよりも MFCC を用いたものの方が精度が高い傾向にあるが、無意識的ブラキシズムデータを用いた場合の再現率のみはほぼ同等の数値である。

5.4 考察

全体として再現率の方が適合率よりも高い傾向がある点については、4.3 節でも言及したが、ブラキシズム以外をブラキシズムと誤検出する傾向が強いということである。この傾向は特に無意識的ブラキシズムデータで強くなっており、実際の睡眠時ブラキシズムと体動等の行動を識別することの難しさを表している。また、エネルギーのみを用いた場合この傾向が特に強くなっており、[16]で記述されていたエネルギーのみで検出すると誤検出が多いということに一致する。

エネルギーのみを用いた HMM と MFCC を用いた HMM での検出結果について、無意識的ブラキシズムデータの再現率はほぼ値が変わらないが、これはエネルギーのみを用いてもブラキシズムの際には一定の振幅の筋電信号が生じることから、ブラキシズムを検出し逃すことは少ないためである。そのため、再現率だけを見ればエネルギーのみを用いても MFCC を用いても同等の検出性能であるようにとれるが、ブラキシズム以外も含めて強い振幅の筋電波形をほぼ全てブラキシズムと判断するわけではなく、その中でブラキシズムでないものを除くという点において MFCC を用いることで精度が向上している。

また、無意識的ブラキシズムデータを用いた場合の適合率が EMG1 のみを用いた場合と比較して減少していることについては、適合率と再現率のバランスをとった結果といえる。

全体的に 4.3 節及び 4.5 節と比較すれば、複数の特徴量を組み合わせることで検出精度の向上に繋がったといえる。

第6章

オートエンコーダを用いたブラキシズム検出精度の向上

6.1 実験概要

これまで単一あるいは複数の特徴量を利用した HMM を用いたブラキシズム検出について検討してきた。これらはいずれも HMM によってブラキシズムとそれ以外を識別することでブラキシズム区間を検出する方法である。しかし、HMM はクラス識別を行うモデルであるため、それぞれのクラスのデータが十分にあることが必要である。無意識的ブラキシズムデータにおいては、実際にブラキシズムを行っている時間が極めて少ないため、ブラキシズム以外のデータが過多になる。

そこで本章ではオートエンコーダを用いたブラキシズム検出について検討する。オートエンコーダは大量の正常データで学習することで、正常データを入力とした場合にはできるだけそのまま出力し、異常データを入力とした場合には入力と大きく異なる値を出力するというネットワークを構築する。ここで、ブラキシズムを異常データ、体動や擬似クレンチングといったブラキシズム以外を正常データとすることでブラキシズムという異常データを検出する手法として扱える。

この際、オートエンコーダは学習時に大量の正常データを必要とするが、睡眠時ブラキシズム検出においてはブラキシズム以外のデータ、すなわち正常データがほとんどであるため、大量の正常データを用意できる。そこで本章では、ブラキシズム以外の大量のデータを用いることのできるモデルとしてオートエンコーダの利用可能性を検討する。

6.2 意識的ブラキシズムデータを用いた検討

オートエンコーダは大量の正常データを用いられる環境で最も性能を発揮するが、ブラキシズムデータに用いることが適当であるか定かではない。そこで、まずは意識的ブラキシズムデータを用いて安静状態からブラキシズムを検出できるのかを確認する。

表 6.1: オートエンコーダの基本パラメータ

損失関数	平均二乗誤差	最適化手法	Adam
学習係数	10^{-4}	入出力次元数	78
バッチサイズ	100	エポック数	20

6.2.1 利用データ

この実験では 3 章で計測した意識的ブラキシズムデータのうち、前半 5 分をテストデータ、後半 6 分を学習データとして利用した。後半 6 分においてはブラキシズムを行う区間がなく、全て正常データとして用いるために被験者 12 人全員のデータを学習データとした。前半 5 分には各種ブラキシズムと擬似クレンジングが行われており、ブラキシズムを擬似クレンジング及び安静状態の中から検出できるかどうかをこの実験では確認する。そのため、被験者 1 人 1 人の前半 5 分をテストデータとして用いた。

6.2.2 モデル構築

オートエンコーダの損失関数は平均二乗誤差を用い、最適化手法としては Adam を用いて、学習係数は 10^{-4} とした。中間層には全結合層を 5 つ用意し、それぞれの層でバッチノーマライゼーションを行った。また、出力層の手前でドロップアウトを $p = 0.2$ で行うことで過学習を抑えた。オートエンコーダであるので入力層と出力層の次元数は同じで、どちらも 78 である。これは、用いるデータが、次元数が 26 である EMG1,2,6 の三つの特徴量を並列に扱うものだからである。中間層の次元数は 2 パターン用意した。まず、最初に次元数を拡大したのちに縮小し、また拡大して縮小するというパターンで、その次元数は順番に (256,128,64,128,256) である。もう一つは最初から次元数を縮小して、最小になってから拡大するというパターンで、その次元数は順番に (64,32,16,32,64) である。バッチサイズ及びエポック数は過学習を抑えるため、100 及び 20 としている。それぞれのオートエンコーダのパラメータを表 6.1 に示す。

6.2.3 評価方法

本研究で扱うデータでは 50ms ごとに MFCC を計算しているため、全てのフレームにおいて出力結果を用いて判断すると過剰に細かく判断され、正確なブラキシズム検出を行えないと判断した。そこで、出力結果である損失の値を 20 フレーム、つまり 1 秒ごとに平均をとった値を出力とする。

検出結果の評価の際にはブラキシズムの再現率、適合率及び F 値を被験者それぞれについて計算した。ここで、オートエンコーダが最終的に出力するのはあくまで損失の値であり、ブラキシズムであるかどうかは設定された閾値を超えるか否かで判断される。つまり、本来は事前に閾値を設定

表 6.2: オートエンコーダによる意識的ブラキシズムの検出結果。上段が次元数 (78 → 64 → 78) の場合、下段が次元数 (78 → 16 → 78) の場合の結果である。

		被験者 ID											
		1	2	3	4	5	6	7	8	9	10	11	12
適合率		0.863	0.816	0.346	0.404	0.835	0.812	0.675	0.672	0.918	0.739	0.604	0.388
再現率		0.870	0.884	1.000	0.784	0.978	0.939	0.819	0.743	0.678	0.663	0.861	0.816
F 値		0.866	0.848	0.514	0.533	0.792	0.871	0.740	0.706	0.947	0.699	0.710	0.526
		被験者 ID											
		1	2	3	4	5	6	7	8	9	10	11	12
適合率		0.830	0.512	0.346	0.434	0.735	0.391	0.537	0.511	0.839	0.640	0.510	0.549
再現率		0.634	0.695	1.000	0.814	0.713	1.000	0.702	0.924	0.793	0.745	0.722	0.575
F 値		0.719	0.589	0.514	0.566	0.724	0.562	0.608	0.658	0.816	0.689	0.598	0.562

すべきであるが、本研究では閾値を任意に設定して F 値を計算し、F 値が最も大きくなった際の閾値を採用する。そのため、閾値設定のために精度が低下することはない。

6.2.4 結果

結果を表 6.2 に示す。次元数にかかわらず全体的に再現率の方が適合率より高く、中には再現率が 1 となっているものも存在する。次元数ごとに見ると上段の次元数 (256,128,64,128,256) の場合の方が 12 名中 9 名で F 値が高い。ただし、被験者 3 においては次元数にかかわらず同じ値を示している。

6.2.5 考察

5 章での結果と同様に再現率の方が適合率より高い傾向がある。ただし、5 章と比較すると、テストデータが本節の実験ではブラキシズム以外の行動が擬似クレンジングしかない区間であり、よりブラキシズムと間違える可能性が低い区間であるにもかかわらず、より顕著に再現率の方が高い傾向がある。そのため、ブラキシズムの誤検出はマルチストリーム HMM と比較して多い傾向にあると考えられる。

F 値が最も高くなるように閾値を設定しているため、次元数の異なる同じ被験者同士で比較した時、適合率と再現率の片方が高く片方が低い被験者も存在する。また、被験者 3 においては F 値が高くなるように閾値を設定した結果、どちらの次元数で検出を試みても、"全てをブラキシズムと検出した時"の F 値が最も高くなってしまったために 3 つの指標全てにおいて同じ値を記録している。

本研究では F 値を指標として重視したためこのような結果となっているが、閾値設定の方法によって適合率と再現率のどちらを重視するかを簡単に選べるのがオートエンコーダによる検出の利

表 6.3: オートエンコーダによる無意識的ブラキシズムの検出結果

次元数	(78 → 64 → 78)	(78 → 16 → 78)
適合率	0.173	0.751
再現率	0.782	0.584
F 値	0.283	0.657

点であるといえる。

6.3 無意識的ブラキシズムデータを用いた検討

6.3.1 実験概要

前節において意識的ブラキシズムデータに対して検出精度が確認できたので、本節では無意識的ブラキシズムデータに対してオートエンコーダを用いる。この実験では 3 章で計測した無意識的ブラキシズムデータのうち、ブラキシズムを含まない正常データである 110 分を学習データとし、ブラキシズムを含む 30 分をテストデータとした。このテストデータのうち、ブラキシズムを行っている区間は累計でおよそ 4 分ほどである。本節では前節の結果及びデータ量の増加を考慮し、バッチサイズを 400、エポック数を 40 にした。また、平均をとるフレーム数を 20 から 5 にした。これは、実際のブラキシズムはより短い時間で行われることがあるためである。これらを除いては全て前節と同様のオートエンコーダを構築した。

6.3.2 結果

結果を表 6.3 に示す。前節の意識的ブラキシズムデータと比較して次元数による差が顕著になっており、次元数が (78 → 16 → 78) の方が適合率及び F 値では大きく上回っている。また、適合率の方が再現率よりも大きい。

6.3.3 考察

意識的ブラキシズムデータの時とは異なり、次元数を削減する方が精度が高くなっており、データによって適切な次元数に違いがあることが確認できた。また、適合率の方が再現率よりも 0.17 大きく、これまでのブラキシズム検出実験とは傾向が異なる。これは、無意識的ブラキシズムデータにおいて F 値の大小で閾値設定を行った際に、ブラキシズムと誤検出する量を減らして検出漏れを増やした方が F 値としては大きくなるということである。つまり、体動や擬似クレンジングといったブラキシズム以外の行動の中からブラキシズムを検出することが意識的ブラキシズムデータの時と比較してより困難である、ということである。

表 6.4: テストデータを拡張した場合のオートエンコーダによるブラキシズムの検出結果

	被験者 ID					
	1	2	3	4	5	6
適合率	0.716	0.716	0.165	0.557	0.633	0.460
再現率	0.675	0.874	1.000	0.551	0.683	0.757
F 値	0.695	0.787	0.283	0.554	0.657	0.572
	被験者 ID					
	7	8	9	10	11	12
適合率	0.534	0.508	0.802	0.595	0.516	0.198
再現率	0.737	0.629	0.967	0.704	0.578	0.773
F 値	0.619	0.562	0.877	0.645	0.545	0.340
	意識的データ平均			無意識的データ		
適合率	0.533			0.247		
再現率	0.744			0.336		
F 値	0.595			0.285		

6.4 テストデータの拡張

6.4.1 実験概要

ここまでは意識的ブラキシズムデータ及び無意識的ブラキシズムデータに対して、オートエンコーダを用いてブラキシズムを安静状態や擬似クレンチング、体動といったそれ以外の行動から検出できるかの検討を行った。そこで、次にテストデータを制限せず、ブラキシズム以外の行動の割合を増やしてみることでどれほどノイズ耐性があるのかを確認する。

意識的ブラキシズムデータでは学習データを被験者以外の 11 人の後半 6 分にし、テストデータは被験者のデータ全てを用いた。無意識的ブラキシズムデータでは、学習データを被験者のブラキシズムを含まない部分 110 分のみとし、テストデータは全睡眠時間のデータを用いた。

基本的に構築するオートエンコーダは意識的ブラキシズムデータ及び無意識的ブラキシズムデータを用いた実験のものと同様にした。ただし、次元数についてはそれぞれで精度の高いものを利用した。

6.4.2 結果

結果を表 6.4 に示す。意識的ブラキシズムデータにおいては、再現率の方が高い傾向はそのままに、全ての被験者でテストデータの拡張前と比較して F 値が低下している。無意識的ブラキシズムデータについてはより大きく適合率、再現率、F 値の全てにおいて値が減少している。

6.4.3 考察

テストデータの拡張によってデータ全体の中のブラキシズムの割合が大きく減少するため、ブラキシズム以外をブラキシズムと誤検出する傾向にある場合その F 値は大きく下がることが想定されるが、それが如実に現れた結果となった。特に無意識的ブラキシズムデータについてはその下り幅が大きく、全体的に値が半分になっている。これは、本節のオートエンコーダを用いた場合、睡眠時のブラキシズムをそれ以外の行動から検出することが難しいということである。

この原因として考えられるのが、データ数の不足である。過学習が起らないように用いるデータ数に制限をかけているため、マルチストリーム HMM よりもデータを多く用いることができるという長所を生かせていない。そこで、次節ではデータ数を増やすために新たなデータを収集してオートエンコーダを再構築した。

6.5 非ブラキシズムデータを用いた学習の検討

6.5.1 実験概要

前節でテストデータを拡張した結果、ブラキシズム以外の行動をブラキシズムだと誤検出することが多いとわかった。そこで、学習データの量と種類を増やすことでオートエンコーダの質を上げることがある。そのために本研究ではこれまでの意識的ブラキシズムデータと無意識的ブラキシズムデータに加えて、ブラキシズムを行っていない被験者の睡眠時筋電データを計測した。これを以降「非ブラキシズムデータ」と呼ぶ。

非ブラキシズムデータは無意識的ブラキシズムデータと同様に EMG1 から EMG6 に対して、電極を上から網状のネットで固定し筋電計測を行った。被験者は成人男性 4 名であり、いずれもブラキシズムを普段行わないことを確認した。被験者の自室のベッドまたは専用の睡眠室で睡眠中のデータを収集した。また、無意識的ブラキシズムデータと同様に岡山大学の共同研究者に依頼し、計測したデータについてブラキシズムを行っていないことを確認し、ブラキシズム以外の睡眠時の行動を行っている時間を同定した。

また、無意識的ブラキシズムデータと同様に睡眠時のデータであることから、解析しやすいように 10 分ごとに区切って通し番号をつけた。

こうして計測した非ブラキシズムデータを学習データとして、意識的ブラキシズムデータ及び無意識的ブラキシズムデータに対してオートエンコーダを構築した。4 人の非ブラキシズムデータを

表 6.5: 非ブラキシズムデータを学習データとしたオートエンコーダによるブラキシズムの検出結果

	被験者 ID					
	1	2	3	4	5	6
適合率	0.546	0.586	0.338	0.520	0.266	0.240
再現率	0.626	0.684	0.456	0.541	0.881	0.930
F 値	0.583	0.631	0.388	0.530	0.408	0.382
	被験者 ID					
	7	8	9	10	11	12
適合率	0.410	0.427	0.493	0.366	0.447	0.615
再現率	0.526	0.581	0.750	0.765	0.661	0.852
F 値	0.461	0.492	0.595	0.495	0.533	0.714
	意識的データ平均			無意識的データ		
適合率	0.438			0.074		
再現率	0.688			0.260		
F 値	0.518			0.116		

全て対象とし、バッチサイズ 1000 エポック数 40 で学習した。その他パラメータは前節と同様である。

6.5.2 結果

結果を表 6.5 に示す。意識的・無意識的ブラキシズムデータを学習データとして利用した場合と比較して、再現率が高い傾向は変わらずどの指標も低下している。

6.5.3 考察

非ブラキシズムデータを学習データとすることで学習データの総量を 2.5 倍にし、検出精度の向上を狙ったが、結果としては検出精度の低下に繋がった。これにはいくつかの原因が考えられる。まず、学習データが変わったことに起因するものとして、次元数等パラメータの問題があげられる。前節までのパラメータは全て意識的ブラキシズムデータ及び無意識的ブラキシズムデータに合わせて構成されたオートエンコーダのパラメータであり、非ブラキシズムデータに合わせて構成されていないために検出結果も悪化した可能性がある。また、意識的ブラキシズムデータと非ブラキシズムデータでは睡眠時のデータかどうかという差があり、無意識的ブラキシズムデータと非ブラキシズムデータでは、学習データとテストデータで被験者が同一であるかどうかの差異があり、この差が精度低下に繋がっていることも考えられる。

6.6 まとめ

本章では意識的ブラキシズムデータ、無意識的ブラキシズムデータに対してオートエンコーダを構築することでブラキシズム検出の精度向上を検討した。その中で、非ブラキシズムデータを新たに計測することで、オートエンコーダの特徴である多くの正常データを学習データとできる点を活用した。しかし、結果としてはマルチストリーム HMM を用いた場合と比較して大きく精度が低下し、非ブラキシズムデータを用いたことも逆効果となった。

本章ではできなかったブラキシズム検出精度の向上に向けた検討として、次章ではオートエンコーダをマルチストリーム HMM と合わせて扱うことでそれぞれの利点を有効活用する方法について検討する。

第7章

オートエンコーダの中間層特徴量を用いた HMM によるブラキシズム検出の検討

7.1 実験概要

6章ではオートエンコーダを検出機として用いてブラキシズム検出を検討したが、結果として実用的なブラキシズム検出が行えたとは言い難い。そこで、本章ではオートエンコーダを特徴量生成の用途で使用し、検出機としては HMM を用いることでブラキシズム検出の精度向上に向けた検討を行う。

7.2 次元圧縮としてのオートエンコーダ

オートエンコーダは入力と出力が同じになるように学習するネットワークであるため、6章ではブラキシズム以外の行動で学習することで、ブラキシズム以外は入力をできるだけそのまま出力してブラキシズムでは入力と大きく異なる値を出力するというネットワークを構築してブラキシズム検出の手法として用いた。しかし、オートエンコーダはもう一つ利用方法があり、それが特徴量の次元圧縮である。オートエンコーダの学習の際には一度特徴量の次元数を下げる過程があるため、学習されたオートエンコーダは入力と出力を同じにするために必要な特徴を選出して次元数を下げる、という用途で用いることができる。

本章ではこうしてオートエンコーダから抽出した特徴量を HMM で用いることで、オートエンコーダの多量の正常データで学習できる利点と、HMM の検出精度の良さを合わせてブラキシズム検出の精度向上を図る。

表 7.1: オートエンコーダの基本パラメータ

損失関数	平均二乗誤差	Optimizer	Adam
学習係数	10^{-4}	入出力次元数	78
バッチサイズ	1000	エポック数	40

7.3 オートエンコーダの構築

オートエンコーダの損失関数は平均二乗誤差を用い、オプティマイザーとしては Adam を用いて、学習係数は 10^{-4} とした。中間層には全結合層を 5 つ用意し、それぞれの層でバッチ正規化を行った。また、出力層の手前でドロップアウトを $p = 0.2$ で行うことで過学習を抑えた。オートエンコーダであるので入力層と出力層の次元数はどちらも 78 である。中間層の次元数は順番に (64,32,16,32,64) である。つまり、特徴量として抽出するものは 16 次元である。バッチサイズは 1000、エポック数は 40 としている。それぞれのオートエンコーダのパラメータを表 7.1 に示す。

オートエンコーダの学習データとしては非ブラキシズムデータを用いた。以上のようにして構築したオートエンコーダに意識的・無意識的ブラキシズムデータを入力し、得られた 16 次元の特徴量を HMM の学習・認識に利用する。

7.4 HMM の構築

特徴量の次元数は 16 次元であり、いずれの場合にも混合数 10 のガウス分布を出力確率とするストリーム数 1 の HMM を用いる。クラスについては、意識的・無意識的ブラキシズムデータともにブラキシズムとそれ以外の 2 つである。学習データとテストデータは、オートエンコーダに意識的・無意識的ブラキシズムデータを入力して得られた特徴量を用いる。意識的ブラキシズムデータでは 1 人の被験者のデータをテストデータとし、被験者以外の 11 人のデータを学習データとすることを 12 人それぞれに対して行う。無意識的ブラキシズムデータでは学習データは 12 名の意識的ブラキシズムデータを利用し、テストデータとして無意識的ブラキシズムデータを利用した。いずれの場合も検出性能の評価には、適合率、再現率、F 値の 3 つの指標を用いて評価する。

7.5 結果

結果を表 7.2 に示す。5 章や 6 章では再現率の方が高い傾向が強かったが、本章では意識的ブラキシズムデータの一部と無意識的ブラキシズムデータにおいて適合率の方が高い。また、6.5 節の結果と比較すれば、特に無意識的ブラキシズムデータでの検出精度が大きく改善された。ただし、5

表 7.2: オートエンコーダで次元圧縮した特徴量を用いた HMM によるブラキシズムの検出結果

	被験者 ID					
	1	2	3	4	5	6
適合率	0.951	0.376	0.994	0.800	0.651	0.498
再現率	0.159	0.596	0.083	0.599	0.836	0.874
F 値	0.273	0.462	0.153	0.685	0.732	0.634
	被験者 ID					
	7	8	9	10	11	12
適合率	0.581	0.665	0.411	0.550	0.425	0.658
再現率	0.651	0.790	0.980	0.793	0.494	0.504
F 値	0.614	0.722	0.579	0.649	0.457	0.571
	意識的データ平均			無意識的データ		
適合率	0.630			0.617		
再現率	0.613			0.389		
F 値	0.544			0.477		

章の結果と比較すると大きく精度を落としていると言える。

7.6 考察

本節と同様に非ブラキシズムデータを学習データとしたオートエンコーダを採用した 6.5 節と比較すると、特に無意識的ブラキシズムデータで大きく性能改善がなされたと言える。オートエンコーダの学習及び無意識的ブラキシズムデータのテストまでは全て同じ過程であることから、その後特徴量を抽出して HMM で扱うことで精度が向上したとみられる。ただし、5 章の結果と比較すれば精度は落ちているため、オートエンコーダと HMM を組み合わせることでその間の性能になったとも考えられる。

第 8 章

結論

8.1 本論文のまとめ

これまでのブラキシズム検出では、高精度だが患者負担の大きい PSG、あるいは筋電の振幅のみを簡便に抽出する装置等が用いられてきた。本研究では、これら従来のブラキシズム検出の弱点を補完する、高精度かつ簡便なブラキシズム検出の手法として、筋電のスペクトルを用いた機械学習によるブラキシズム検出を提案した。より具体的には、意識的あるいは睡眠時のブラキシズムの際に頬や顎の筋電を計測して MFCC を計算し、HMM やオートエンコーダの特徴量として扱いブラキシズムの検出精度向上を試みた。結果として、5 章の HMM を用いた検出では、ブラキシズム以外の筋電波形（体動や疑似クレンチング等）をブラキシズムとして検出してしまう偽陽性がやや多いものの、表面電極 EMG1、EMG2、EMG6 の 3 箇所から得られた筋電を用いたところ、7 割から 8 割程度の精度でブラキシズム検出を行うことができた。従来のエネルギーのみを用いた検出を再現した方法によるブラキシズム検出は 5 割程度だったが、MFCC を計算して HMM を用いた提案手法は、検出性能の向上に貢献した。一方で、6 章や 7 章のようなオートエンコーダを用いたブラキシズム検出では、ブラキシズムのデータが少なくても学習データを用意できるという利点があるものの、結果としては 5 割程度の精度でしかブラキシズム検出を行えなず、5 章において提案した方法のほうがブラキシズムの検出性能が高かった。

ブラキシズムとそれ以外とで識別を行う HMM に対して、ブラキシズム以外の行動が長時間行われる中でのブラキシズムを異常なものとして検出するオートエンコーダの方が用途にあっており適切だと考えていたが、本研究では HMM の方が優れた性能を示した。この原因として、まず従来より用いられてきた HMM では多くの知見がすでにあり、適切な HMM の構築が比較的容易だったのに対して、ネットワークの構成やパラメータで大きく性能が変わってしまうオートエンコーダの適切な構築が困難であったことがあげられる。また、ブラキシズム以外の行動の中でも安静状態と体動とでは特徴量も大きく異なるはずであるが、その両方を学習できる HMM に対して、過学習を抑えるためにデータ量を削ったオートエンコーダではうまく学習できなかったということも考えられる。

以上のような点から、本研究の結論としては、MFCC を計算して HMM を用いたブラキシズム

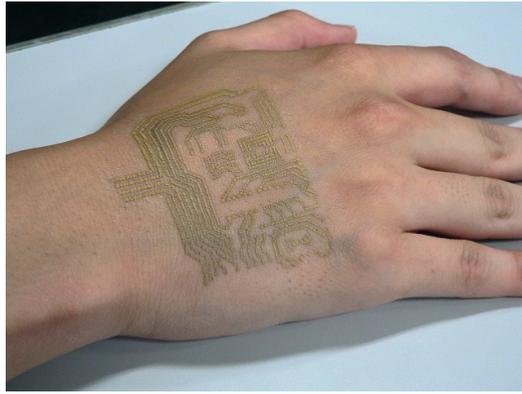


図 8.1: ナノメッシュセンサー [32]

検出方法が、ブラキシズム検出性能の向上に貢献した。

また、オートエンコーダを用いたブラキシズム検出については、本研究では十分な検出性能は得られなかったが、改良の余地はあると思われる。今後の課題としては、過学習を抑えながら多くのデータを扱えるようにネットワークの構築を見直し、別の分野で得られた知見を有効活用する必要がある。

8.2 今後の展望

本研究では、筋電波形の特徴量を用いて睡眠時ブラキシズムの自動検出を試みたが、北海道大学の齋藤らは、睡眠時ブラキシズムにおける筋活動量の評価パラメータとして、波形数に加えて咬筋筋電図波形積分値の有用性を示唆している [33]。将来的には、同じ患者データを用いて、このような積分値を用いた方法と本研究で用いた方法を比較検討したり、あるいは両者を組み合わせることで、ブラキシズム検出の精度向上やブラキシズムの重症度を評価する際の新たな指標になる可能性がある。

本研究で提案したブラキシズムの自動検出技術がさらに向上し、実用化を検討する段階になるとすれば、BiteStrip[®] のように簡易的に筋電を計測する装置を開発する必要がある。本研究では頬の筋肉に加えて顎の下側の筋肉も計測対象としているため、BiteStrip[®] のような小型装置 1 つでは計測場所が不足してしまう。最も適切なデバイスとして、[17] で扱ったナノメッシュセンサー [32, 34] が考えられる。ナノメッシュセンサーは、生体適合性の高いポリビニルアルコール (PVA) を用いたナノメッシュ構造を持つシートの上に、電極となる金を吹きかけることで作られる、水で簡単につけることのできる上に炎症の起きにくい非常に薄い筋電センサーである。つけている間の違和感が少なく持続性にも優れているため、本研究のように複数箇所の筋電を夜間に長時間計測する際に適した筋電センサーの 1 つである。

また、本研究ではより検出困難であるとされる睡眠時ブラキシズムについて検出実験を行ったが、近年では覚醒時ブラキシズムについての検討も盛んである。本研究の技術基盤は睡眠時ブラキシズムのみならず覚醒時ブラキシズムにおいても同様に扱えるものと考えている。上述のナノ

メッシュセンサーもまた日常生活の筋電計測に長けており、これらを組み合わせることで将来的に覚醒時・睡眠時どちらのブラキシズムについても簡便で高精度なブラキシズム検出が期待できる。

謝辞

本研究を進めるにあたり、手厚いご指導をいただいた指導教員の峯松信明教授に心より感謝いたします。本研究は卒業研究を発展させるものでしたが、研究の方向性についての的確な助言を下さり、様々な理論や情報を提供して下さっただけでなく、後に述べる岡山大学の先生方との分野横断的な議論や交渉にも積極的に関わって下さいました。また、本学大学院工学系研究科の齋藤大輔准教授には研究に欠かせない工学的技術の使い方や研究のアイデアを教えていただきました。深く感謝いたします。本学大学院工学系研究科の西村多寿子特任研究員には本研究について医学的な観点から様々な支援をいただきました。峯松・齋藤研究室のメンバーにも様々な場面で助けてもらいました。ありがとうございました。

岡山大学大学院医歯薬学総合研究科の窪木拓男教授ならびに水口一講師のご協力がなければ、この研究は始めることさえできなかつたと思います。ブラキシズム研究で先駆的な研究を行っている先生方が、私の卒論に興味をもって下さり学術的支援の手を差し伸べて下さったおかげで、工学と歯学をつなぐ共同研究を行うことができました。同研究室に係る歯科医の先生方も、データ収集や筋電波形解読にご協力くださいました。3章で使用した電極貼付位置や筋電計測の概要図のイラストはLoc先生が描いてくださいました。大変感謝しております。

最後に大学院生活を様々な面から支えて下さった両親に感謝いたします。コロナ禍での院生生活で、さまざまな負担をかけましたが、実家の岡山と東京の両方に拠点があったことで、本研究を進めることができました。本当にありがとうございました。

令和4年1月27日

長崎 光弘

参考文献

- [1] 鈴木善貴, 大倉一夫, 松香芳三. 睡眠時ブラキシズムの基礎と最新の捉え方. *睡眠口腔医学*, Vol. 3, No. 1, pp. 10–21, 2016.
- [2] Ben W. Pavone. Bruxism and its effect on the natural teeth. *The Journal of Prosthetic Dentistry*, Vol. 53, No. 5, pp. 692 – 696, 1985.
- [3] 小林義典. 咬合・咀嚼が創る健康長寿. *日本補綴歯科学会誌*, Vol. 3, No. 3, pp. 189–219, 2011.
- [4] Bruxism (teeth grinding) - symptoms and causes - mayo clinic. <https://www.mayoclinic.org/diseases-conditions/bruxism/symptoms-causes/syc-20356095>. (Accessed on 01/20/2020).
- [5] Wataru Yachida, Taro Arima, Eduardo E. Castrillon, Lene Baad-Hansen, Noboru Ohata, and Peter Svensson. Diagnostic validity of self-reported measures of sleep bruxism using an ambulatory single-channel emg device. *Journal of Prosthodontic Research*, Vol. 60, No. 4, pp. 250 – 257, 2016.
- [6] Marc Guaita and Birgit Högl. Current treatments of bruxism. *Current Treatment Options in Neurology*, Vol. 18, No. 2, p. 10, 2016.
- [7] 菱川龍樹, 山口泰彦, 斎藤未来, 三上紗季, 後藤田章人, 岡田和樹. 睡眠時ブラキシズムの筋電図% mvc 表示と最大咬合力の関係. *日本顎口腔機能学会雑誌*, Vol. 19, No. 2, pp. 111–124, 2013.
- [8] G.J. Lavigne, P.H. Rompre, and J.Y. Montplaisir. Sleep bruxism: Validity of clinical research diagnostic criteria in a controlled polysomnographic study. *Journal of Dental Research*, Vol. 75, No. 1, pp. 546–552, 1996. PMID: 8655758.
- [9] Karen G. Raphael, et al. Sleep bruxism and myofascial temporomandibular disorders: A laboratory-based polysomnographic investigation. *The Journal of the American Dental Association*, Vol. 143, No. 11, pp. 1223–1231, 2012/11/08 2012.
- [10] KMC Dutra, et al. Oro-facial activities in sleep bruxism patients and in normal subjects: a controlled polygraphic and audio–video study. *Journal of oral rehabilitation*, Vol. 36, No. 2, pp. 86–92, 2009.
- [11] J Catesby Ware and John D Rugh. Destructive bruxism: sleep stage relationship. *Sleep*, Vol. 11, No. 2, pp. 172–181, 1988.
- [12] Shigehisa Kawakami, Yohei Kumazaki, Yosuke Manda, Kazuhiro Oki, and Shogo Minagi.

- Specific diurnal emg activity pattern observed in occlusal collapse patients: relationship between diurnal bruxism and tooth loss progression. *PloS one*, Vol. 9, No. 7, pp. e101882–e101882, 07 2014.
- [13] Katuska Piquero and Kaoru Sakurai. A clinical diagnosis of diurnal (non-sleep) bruxism in denture wearers. *Journal of Oral Rehabilitation*, Vol. 27, No. 6, pp. 473–482, 2000.
- [14] 大倉一夫. マルチテレメータシステムを用いた睡眠時ブラキシズムの測定と解析. 日本補綴歯科学会雑誌, Vol. 41, No. 2, pp. 292–301, 1997.
- [15] Rubana H. Chowdhury, Mamun B. I. Reaz, Mohd Alauddin Bin Mohd Ali, Ashrif A. A. Bakar, Kalaivani Chellappan, and Tae G. Chang. Surface electromyography signal processing and classification techniques. *Sensors*, Vol. 13, No. 9, pp. 12431–12466, 2013.
- [16] Haruna Miki, Hajime Minakuchi, Mayu Miyagi, Emilio Satoshi Hara, Shuji Shigemoto, Yoshitaka Suzuki, Kenji Maekawa, Yoshizo Matsuka, Glenn T. Clark, and Takuo Kuboki. Association of masticatory muscle activity with sleep arousal and other concomitant movements during sleep. *Journal of Oral Rehabilitation*, Vol. 47, No. 3, pp. 281–288, 2020.
- [17] 長崎 光弘ほか. 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. p. 90, 2020.
- [18] Geoffrey S. Meltzner, Jason Sroka, James T. Heaton, L. Donald Gilmore, Glen Colby, Serge Roy, Nancy Chen, and Carlo J. De Luca. Speech recognition for vocalized and subvocal modes of production using surface emg signals from the neck and face. In *INTERSPEECH-2008*, pp. 2667–2670, 2008.
- [19] Christian Wellekens, Jussi Kangasharju, and Cedric Milesi. The use of meta-hmm in multistream hmm training for automatic speech recognition. In *ICSLP*. Citeseer, 1998.
- [20] Srikanth Vishnubhotla, Raul Fernandez, and Bhuvana Ramabhadran. An autoencoder neural-network based low-dimensionality approach to excitation modeling for hmm-based text-to-speech. In *2010 IEEE International Conference on Acoustics, Speech and Signal Processing*, pp. 4614–4617, 2010.
- [21] Jinwon An and Sungzoon Cho. Variational autoencoder based anomaly detection using reconstruction probability. *Special Lecture on IE*, Vol. 2, No. 1, pp. 1–18, 2015.
- [22] Sergey Ioffe and Christian Szegedy. Batch normalization: Accelerating deep network training by reducing internal covariate shift. *CoRR*, Vol. abs/1502.03167, , 2015.
- [23] Vinod Nair and Geoffrey E. Hinton. Rectified linear units improve restricted boltzmann machines. In *ICML*, pp. 807–814, 2010.
- [24] Nitish Srivastava, Geoffrey Hinton, Alex Krizhevsky, Ilya Sutskever, and Ruslan Salakhutdinov. Dropout: A simple way to prevent neural networks from overfitting. *Journal of Machine Learning Research*, Vol. 15, No. 56, pp. 1929–1958, 2014.
- [25] Diederik P. Kingma and Jimmy Ba. Adam: A method for stochastic optimization, 2017.

-
- [26] Ning Qian. On the momentum term in gradient descent learning algorithms. *Neural Networks*, Vol. 12, No. 1, pp. 145–151, 1999.
- [27] Tijmen Tieleman and Geoffrey Hinton. Lecture 6.5-rmsprop, coursera: Neural networks for machine learning. *University of Toronto, Technical Report*, 2012.
- [28] 咬筋の位置とコリ | 健康・美容 エクササイズコラム | 整体サロン powwow. <https://www.powwow-ginza.com/column/2012/05/000202.shtml>. (Accessed on 02/24/2020).
- [29] omohyoid_muscle [operative neurosurgery]. https://operativeneurosurgery.com/doku.php?id=omohyoid_muscle. (Accessed on 05/10/2020).
- [30] L. Mesin, R. Merletti, and A. Rainoldi. Surface emg: The issue of electrode location. *Journal of Electromyography and Kinesiology*, Vol. 19, No. 5, pp. 719 – 726, 2009.
- [31] 倉知正和, 石神元, 横山佳郎, 山田早苗. 偏側咀嚼の指数表示について. *日本補綴歯科学会雑誌*, Vol. 36, No. 5, pp. 1026–1031, 1992.
- [32] 共同発表：皮膚呼吸が可能な皮膚貼り付け型ナノメッシュセンサーの開発に成功～1週間貼り続けても炎症反応がないため、長期生体計測への応用に期待～. <https://www.jst.go.jp/pr/announce/20170718/index.html>. (Accessed on 01/21/2020).
- [33] 斎藤未来, 山口泰彦, 三上紗季, 後藤田章人. 咬筋筋電図波形積分値による睡眠時ブラキシズムの評価. *日本全身咬合学会雑誌*, Vol. 27, No. 2, pp. 1–7, 2021.
- [34] Akihito Miyamoto, Sungwon Lee, Nawalage Florence Cooray, Sunghoon Lee, Mami Mori, Naoji Matsuhisa, Hanbit Jin, Leona Yoda, Tomoyuki Yokota, Akira Itoh, Masaki Sekino, Hiroshi Kawasaki, Tamotsu Ebihara, Masayuki Amagai, and Takao Someya. Inflammation-free, gas-permeable, lightweight, stretchable on-skin electronics with nanomeshes. *Nature Nanotechnology*, Vol. 12, No. 9, pp. 907–913, 2017.

発表文献

自身が主著のもの

- 長崎 光弘, 西村 多寿子, 峯松 信明, 角 祐太郎, 横田 知之, “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”, 生体医工学シンポジウム, 2020.
- 長崎 光弘, Hoang Dinh Loc, 西村 多寿子, 峯松 信明, 水口 一, 窪木 拓男, “筋電図波形と音響信号を用いたブラキシズム及び擬似クレンチングの自動検出”, 第 60 回日本生体医工学会大会, 2021

共同研究者が主著のもの

- ホアン ディンロック, 長崎 光弘, 水口 一, 三木 春奈, 坂本 和基, 下村 侑司, 大森 江, 西村 多寿子, 峯松 信明, 窪木 拓男, “機械学習を応用したブラキシズムの筋電図波形識別の試み”, 公益社団法人日本補綴歯科学会 第 130 回記念学術大会, 2021