ディープラーニングによる 脳波/筋電データを用いたマウスの睡眠ステージ判定

山部 剛士 堀江 和正 場川 浩昭 柳沢 正史 地 北川 博之 地

† 筑波大学 システム情報工学研究科 〒 305-8573 茨城県つくば市天王台 1-1-1 ††† 筑波大学 国際統合睡眠医科学研究機構 (WPI-IIIS) 〒 305-8575 茨城県つくば市天王台 1-1-1 †† 筑波大学 計算科学研究センター 〒 305-8577 茨城県つくば市天王台 1-1-1 E-mail: †{yamabe,horie}@kde.cs.tsukuba.ac.jp, ††{shiokawa,kitagawa}@cs.tsukuba.ac.jp, †††yanagisawa.masa.fu@u.tsukuba.ac.jp

あらまし 睡眠の研究において、マウスの睡眠の状態(ステージ)を脳波や筋電位から判定する作業がよく行われる。このステージを自動判定することができれば、睡眠研究の効率改善が可能となる。本研究では、ヒトの睡眠ステージを高精度で判定できることで知られる DeepSleepNet に着目し、この手法をマウスの睡眠ステージ判定に適用した場合の効果について検討を行った。SVM や LSTM を用いたマウスのステージ自動判定手法との比較の結果、DeepSleepNet が覚醒やノンレム睡眠について同等以上に判定できることが分かった。特に LSTM を用いた手法との比較によって、CNN による特徴抽出がフーリエ変換による周波数成分を特徴量とするよりも良いことが分かった。しかしながら、技師と同程度の一致率での判定はまだ達成できていない。今後は、マウスのデータに対してモデルのパラメタの最適化を行うことで、より高い一致率での判定を目指す。

キーワード 脳波, 筋電位, マウスの睡眠ステージ判定, 時系列信号処理, ディープラーニング

1. はじめに

睡眠に関する様々な研究を行う上でマウスを用いた実験がよく行われている。睡眠解析を目的とした実験では、脳波や筋電位から、睡眠の状態(ステージ)を分類する「睡眠ステージ判定」が重要な検査項目の1つである。現在、信頼性の高い睡眠ステージ判定は、専門家が脳波や筋電図を目視で確認し決定する方法で行われているが、このような方法では、多くの時間と労力を必要である。より少ない時間と労力で信頼できる睡眠ステージ判定を行うことができれば、睡眠研究の効率の改善につながると考えられる。

そこで、睡眠研究の効率化を目的に、これまでにも様々なマウスの睡眠ステージの自動判定手法が提案されている [1-5]. しかしながら、これらの手法では、専門家と同様のステージ判定は達成できていない。一般に、複数の専門家が同一の生体信号に対してステージ判定を行った場合、95%以上判定結果が一致するといわれている。しかし、技師との判定が95%以上一致する自動判定手法はいまだ提案されていない。

本研究では、近年提案されたヒトの睡眠ステージ自動判定手法である DeepSleepNet に着目した。本手法は、ヒトの 1ch の脳波に含まれる波形特徴を Convolutional Neural Network (CNN)を用いて抽出、Long Short Term memory (LSTM)を用いてステージとの関係をモデル化する手法である。約86%の一致率で判定を行うことが可能で、他のヒトのステージ判定手法と比較して優れた性能を示した。本研究では、マウスの睡眠ステージ自動判定手法の開発の一環として、この DeepSleepNet をマウスの生体信号に適用し、その判定結果の検証を行った。

本稿の構成は以下のとおりである。まず2章と3章で、マウスの睡眠ステージやニューラルネットワークなどの基本事項と、既存の睡眠ステージ判定手法など関連研究について述べる。4章、5章で DeepSleepNet によるマウスの睡眠ステージ判定について説明し、実際のマウスのデータを用いた実験の結果を述べる。最後に6章でまとめと今後の課題について述べる。

2. 基本事項

2.1 マウスの睡眠ステージの特性

一般的なマウスの睡眠ステージ判定では、睡眠中の時間を 20 秒 (1 エポック) (図 1) ごとに区切り、各区間がどのような睡眠状態にあるか判定を行う。この睡眠状態を睡眠ステージと呼び、マウスでは、脳波や筋電位の状態から、覚醒、ノンレム睡眠、レム睡眠の 3 つのステージに分類できる (表 1)。本節では各睡眠ステージの特性について説明する。

(1) 覚醒

覚醒は、マウスが眠りについていない状態や、うとうとしている状態を指す. 脳、筋肉ともに非常に活発に働いており、特に EMG の振幅が大きくなる傾向がある. 脳波は、7 11Hz のシータ波がよくみられる.

(2) ノンレム睡眠

ノンレム睡眠は、脳、筋肉ともに休んだ状態であり、脳波はデルタ波(1 6Hz)を多く含む。筋電位は覚醒時に比べ振幅が小さくなるが、寝返り等を行うため、0 にはならない。ノンレム睡眠は睡眠全体の約8割を占める主要な睡眠状態であるといえる。

(3) レム睡眠

レム睡眠時は, 脳だけ活動している状態であり, 脳波は覚醒状

態と同様にシータ波を多く含む.筋肉は全身が弛緩しており、 ノンレム睡眠時よりも筋電位が小さくなる傾向がみられる.レ ム睡眠は、一度その状態になっても数十秒から数分程度しか持 続せず、睡眠中に一定の周期で現れるという特徴を持っている.

	主なEEG	EMGの振幅
覚醒	シータ波(7~11Hz)	大
ノンレム睡眠	デルタ波(1~6Hz)	小
レム睡眠	シータ波(7~11Hz)	小

表 1 睡眠ステージと脳波,筋電位の関係

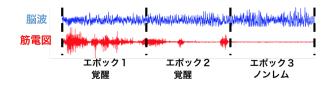


図 1 エポックと睡眠ステージ判定の例

2.2 ニューラルネットとディープラーニング

ニューラルネットは、人の脳内のニューロンやその情報処理を再現した数理モデルの一つで、回帰や分類を行うことができる。一般的なニューラルネットは入力層、中間層、出力層の3種類の層で構成されている(図2)。この中間層を増やし、より複雑な処理を実現したのがディープラーニングであり、その目的に合わせて様々なディープラーニング手法、モデルが提案されている。

本研究では、信号からの特徴量の自動抽出を行う Convolutional Neural Network (CNN) と、時系列信号の処理、モデル化に用いる Recurrent Neural Network (RNN) の2種類を使用する.

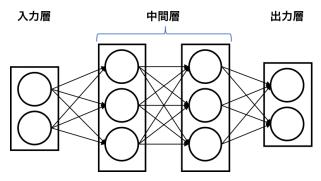


図 2 4 層ニューラルネットワークのイメージ図

2.2.1 Convolutional Neural Netowork(CNN)

CNN は、入出力関係のモデル化(本研究では脳波や筋電図と睡眠ステージの関係のモデル化)に有効な入力の特徴を学習を通じて自動的に抽出するニューラルネットである。主に入力信号に対するフィルタリングである Convolution と位相ずれの補正である Pooling の二つの操作を行う(図3).

Convolution

Convolution では入力データに対してフィルタによる畳込みを行い特徴マップを生成する.特徴マップはフィルタの枚数に応じて生成され,それぞれが異なる特徴を抽出することができる.

Pooling

Pooling では Convolution で生成された特徴マップの圧縮を行う.一定範囲に対して最大値を取り出す Max Pooling などの操作を行うことで特徴マップを圧縮している.これによって位相ずれなどにロバストになるといった効果が得られる.

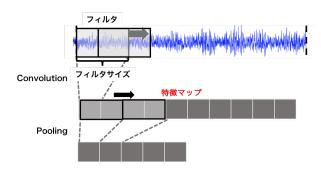


図 3 脳波/筋電位に対する CNN による特徴抽出

2.2.2 Recurrent Neural Network(RNN)

RNN は時系列データの解析に用いられるモデルである。中間層が再帰的な結合を持っており、過去の中間層の状態も考慮した計算を行うことが可能である。これによって時系列性を考慮したデータの解析を可能にしている。

DeepSleepNet では RNN モデルの 1 つである bidirectional LSTM を用いて判定を行っている. LSTM(Long short term memory) とは中間層の素子を LSTM block(図 4) と呼ばれる素子に置き換えたものである.

LSTM block はメモリーセルと3つのゲートから構成される. 入力ゲート/忘却ゲート/出力ゲートによってメモリーセルに保持された内部状態の更新を行う. LSTM では必要に応じて内部状態の忘却や長期保存を行うことができ,長時間の時系列情報の学習にも対応している.

LSTM block はメモリーセルの状態 c_t と次の層への出力 h_t を,前の層からの入力 a_t と過去の出力 h_{t-1} とメモリーセルの状態 c_{t-1} を入力としてそれぞれのゲートで以下の式を用いて計算している.

忘却ゲート:
$$f_t = sigmoid(W_f a_t + U_f h_{t-1} + b_f)$$

入力ゲート: $i_t = sigmoid(W_i a_t + U_i h_{t-1} + b_i)$
出力ゲート: $o_t = sigmoid(W_o a_t + U_o h_{t-1} + b_o)$
 $g_t = tanh(W_g a_t + U_g h_{t-1} + b_g)$
 $c_t = i_t \otimes g_t + f_t \otimes c_{t-1}$
 $h_t = o_t \otimes tanh(c_t)$

DeepSleepNet では、信号を時系列順に処理する LSTM と、 逆順に処理する LSTM の二つを用い、過去と未来両方の変遷 をモデル化できる biditectional LSTM を使用している.

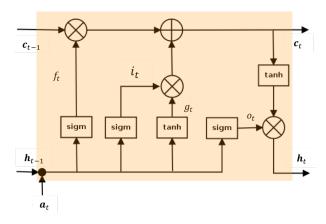


図 4 LSTM block

3. 関連研究

本章では既存のマウスの睡眠ステージ判定手法 [1–5] の中でも特に高い性能を示している MASC [4] と、ディープラーニングを用いた手法である LSTM による判定手法 [6] について説明する.

3.1 MASC

MASC は脳波/筋電位の周波数成分と、睡眠ステージの時系列性からマウスの睡眠ステージを判定する手法である。

まず FFT によって求めた脳波/筋電位の周波数成分に対して、主成分分析によって特徴量の推定を行い、睡眠ステージの特性をよく表現できるような特徴量を作成する。それらの特徴量に加えて判定対象となるエポックの前後のエポックにおける睡眠ステージの占有確率を時系列的な特徴量としてSVM(Support Vector Machine)による判定を行う。さらに確実度の低い判定結果については再判定を行うことでその判定を修正することでより性能を向上させている。

MASC では各睡眠ステージで 95%に近い一致率を達成している.

3.2 LSTM を用いた判定手法

脳波/筋電位の周波数成分に基づく、ディープラーニングを 用いたマウスの睡眠ステージ判定手法である.

睡眠ステージごとに、主要な周波数成分が異なることから、事前に FFT(fast Fourier transform) によって得た、脳波/筋電位の周波数成分を特徴量として利用する。 睡眠ステージの遷移にある程度の規則性があることに着目し、時系列情報を考慮可能な RNN モデルの 1 種である LSTM を用いて判定を行っている.

この手法では覚醒・ノンレムの一致率は 95%を達成したが、レムの一致率が約 82%と実用可能な段階に到達していない.

4. DeepSleepNet によるマウスの睡眠ステー ジ判定

本研究では、サンプリング周波数 250Hz, 20 秒分のマウスの脳波と筋電位各 1ch ずつを入力とし、睡眠ステージの判定を行う。モデルは信号の前処理と DeepSleepNet の二つから構成される。

4.1 信号の前処理

本研究では、筋電位のみ前処理を行っている。先述のように、筋電位は信号の振幅やその変化がステージ判定の重要な指標である。そこで、今回は振幅がより強調された信号となるように、筋電位に対して移動二乗平方根平均をかけている。なお、本前処理の効果については、後述する実験で検討している。

脳波については、ノンレム睡眠に多く含まれるデルタ波 (1 6Hz) や、覚醒、レム睡眠に多く含まれるシータ波 (7 11Hz) が判定に重要である。これらについては 1 次元の CNN を用いて十分に特徴が抽出できると予想されるため、前処理は行わなかった。

4.2 DeepSleepNet

本来の DeepSleepNet は、脳波 1ch の信号をもとに、睡眠ステージの判定を行っている。本研究では、ヒト睡眠向けのDeepSleepNet に、筋電位を処理する特徴抽出部を追加することで、脳波と筋電位を同時に考慮した判定を行っている(図 5)。以下では、DeepSleepNet を特徴抽出部と、識別部に分け説明する。

4.2.1 特徴抽出部

特徴抽出部は、脳波と筋電位それぞれに対し、睡眠ステージ 判定に必要な特徴の抽出を行う。

まず、脳波は、フィルタサイズの異なる2種類の特徴抽出を行う。フィルタサイズが小さく、波形や振幅の抽出に特化したもの、フィルタサイズが大きく、低周波成分の抽出が得意なものを両方利用することで、睡眠判定に必要な特徴を逃さず拾っている

筋電位については、信号処理の際に高周波成分が落ちているため、フィルタサイズの大きい特徴抽出を用いている(5.3 予備実験参照).

4.2.2 識 別 部

識別部では、抽出した特徴量を二つの経路で処理する。一つは、LSTM素子を用いた、前後エポックの関係性を考慮する経路、もう一つは、全結合素子を用いた経路である。

LSTM 素子では連続した 25 エポックを入力とし, それぞれの エポックについて 1024 次元のベクトルを出力する.

全結合素子では特徴抽出部からの出力を 1024 次元のベクトル に変換している. これは前後のエポックから影響を受けない, 特徴を保持するためである.

エポックの特徴と前後のエポックとの関係性の2つを用いて Softmax 層で各ステージの確率を求めている.

4.3 モデルの学習

DeepSleepNet の学習は事前学習とモデル全体の学習の2段階に分かれている。

事前学習では、特徴抽出部のみを用いてステージ判定の学習を行う。そのために、CNN からの出力を結合した後に、一時的に各ステージに対応した素子を持つ SoftMax 層を入れ、この SoftMax での学習を CNN の層に伝播させる。使用する学習 データに対してオーバーサンプリングを行い、含まれるステージ数を揃える。学習率は 1e-4 とし、バッチサイズ 100 エポックでのミニバッチ学習を行う。事前学習によって、レム睡眠の出現数が少ないことによる偏りの影響や、モデル全体の学習を

ある程度良い初期値で始められるといった効果が得られる. モデル全体の学習では、事前に学習した CNN の特徴抽出部分を含め、モデル全体をファインチューニングする. この時、特徴抽出部の過学習を防止するために、特徴抽出部と識別部では学習率を変えている(特徴抽出部:1e-6、 識別部:1e-4). バッチサイズを連続する 25 エポック×10 とし、ミニバッチ学習を行う.

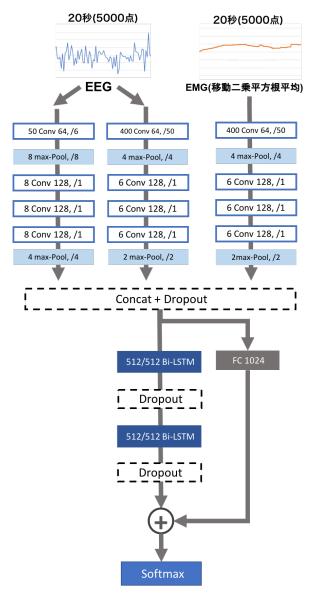


図 5 DeepSleepNet によるマウスの睡眠ステージ判定モデル

5. 実 験

システムのパラメタ決定と評価のためにいくつかの実験を行った.

5.1 データセット

本実験では、筑波大学国際統合睡眠医科学研究機構から提供されたマウスの脳波・筋電位 14 匹分を使用する。本データは、脳波と筋電位をサンプリング周波数 250Hz, 4 日分、マウスあたり 17200epoch(1epoch、20 秒)である。実験の前に、各エポックに対して専門家によるステージングが行われている。こ

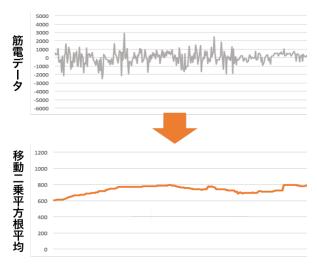


図 6 移動二乗平方根平均による前処理

の時の専門家の判定ステージを、DeepSleepNet の学習時の目標値、評価実験の際の真値として利用した。

5.2 評価指標

本実験で用いた Sensitivity と Specificity, Precision, Accuracy, F-measure の 5 つの評価指標について説明する。これらの指標は表 2 を用いて計算される。

Sensitivity は人間が X であると判定したエポックの中で判定器も X であると判定した割合を示し、Specificity は人間が X でないと判定したエポックの中で判定器も X でないと判定した割合を示す。また、Precision は判定器が X であると判定したエポックの中で人間も X であると判定した割合を示す。これらは以下の式で計算される。以下の数式で、 TP_X は専門家、システムのどちらも X と判定した件数を表しおり、 FN_X 、 FP_X 、 TN_X も同様に X について件数を表している。

$$Sensitivity = \frac{TP_X}{TP_X + FN_X}$$

$$Specificity = \frac{TN_X}{TN_X + FP_X}$$

$$Precision = \frac{TP_X}{TP_X + FP_X}$$

Accuracy は人間と判定器の判定が一致した割合を示し, $FN_{ALL}=FN_{NREM}+FN_{REM}+FN_{WAKE}$, $TP_{ALL}=TP_{NREM}+TP_{REM}+TP_{WAKE}$ とするとき以下の式で計算する.

$$Accuracy = \frac{TP_{ALL}}{TP_{ALL} + FN_{ALL}}$$

F-measure は Sensitivity と Precision の調和平均であり以下の式で計算する.

$$F-measure = \frac{2*Sensitivity*Precision}{Sensitivity+Precision}$$

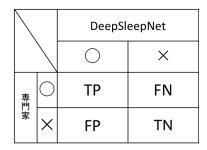


表 2 混同行列

5.3 予備実験:筋電位に対する CNN のフィルタサイズおよび前処理の有無による比較

この実験では筋電位に対する特徴抽出を行う CNN のフィルタサイズの違い、および前処理の有無による一致率を比較し、最も良い一致率で判定可能な特徴抽出部のモデルを検討した。フィルタサイズについては DeepSleepNet では大小 2 種類を使用しているため、大小どちらか片方のフィルタを使用する場合とどちらも使用する場合の3つのパターンを用意した。それぞれについて筋電位の前処理の有無 2 パターンと合わせ、全部で6 パターンのモデルでの比較実験を行った。各モデルは 10 匹分の学習データによる学習を行い、4 匹分のデータで評価した。結果について以下の表 3 に示す。

この結果からいずれの場合でも覚醒/ノンレムは 95%以上 あるいはそれに近い精度で判定可能であり、そこまで大きな 差は見られなかった。しかしレムの一致率への影響は比較的 大きいことが分かる。F-measure を基準にすると、最も高い RMS(large) が 6 パターンの中で最も筋電位からの特徴抽出に 適していると考える。

よって移動二乗平方根平均による前処理を行った上で、大きなフィルタサイズの CNN を用いたモデルによって検証実験や評価実験を行う.

5.4 検証実験:筋電位の有無による一致率への影響

DeepSleepNet によるマウスのステージ判定に筋電位が与える影響を検証するために筋電位の有無による一致率を比較した. 検証実験でも予備実験と同様に、10 匹分の学習データによる学習を行い、4 匹分のデータで評価を行った.

脳波のみを入力とした場合と脳波と筋電位を入力とした場合の それぞれの結果を以下の表 4 に示す.

実験結果から筋電位を加えたことでノンレムの Sensitivity や Accuracy などが若干向上したが、脳波のみの場合と大きな 差は見られなかった.

5.5 評価実験

評価実験として他のマウスの睡眠ステージ判定を行う既存手法との比較を行った。マウスの睡眠ステージ判定において高い性能を示している MASC とディープラーニングを用いた判定を行う LSTM を用いた判定手法を比較対象とした。評価実験でも 10 匹分の学習データによる学習を行い,4 匹分のデータで評価を行った。今回は各サンプルについて事前学習を 100 回,モデル全体の学習を 200 回行った。

実験結果を以下の表 5 に示す。結果から覚醒・ノンレムについては既存手法と同等あるいはそれ以上で判定することが可能であることが分かった。Accuracy も 95%を達成している。LSTM を利用した手法と比較してレムの一致率は向上したが、MASC と比較するとレムの Sensitivity が約 8%ほど低い。レムの Sensitity や Precision が 95%を達成しておらず、実用可能なレベルに到達しなかった。

DeepSleepNet の学習データの Accuracy とテストデータの Accuracy を示す (図 7,8). どちらの学習も学習データの Accuracy は 99%以上であるが、テストデータの Accuracy が、事前学習では 90%未満、モデル全体の学習では約 95%と、汎化性能が低いことが分かる.

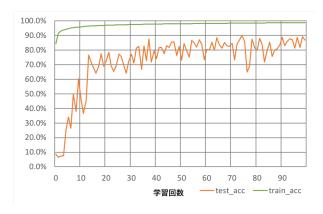


図7 事前学習

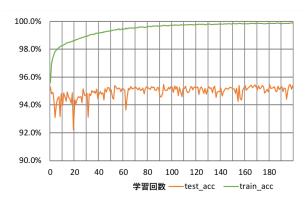


図8 モデル全体の学習

5.6 考 察

検証実験からは、脳波のみの場合と筋電位を加えた場合とで 一致率にほぼ変化が見られないことが分かった。このことから、 脳波に筋電位に準じるような信号が含まれる可能性がある。

評価実験から、DeepSleepNet が覚醒/ノンレムを既存手法より同等かそれ以上の一致率で判定できているが、MASC と比較するとレムの一致率が低いことが分かった。LSTM を用いた手法と比較するとレムの一致率が向上していることから、FFT による特徴量をもとに判定するよりも CNN による特徴抽出の方が適していると考えられる。

しかし、実験では CNN や RNN のパラメタをヒトを対象とした場合と同じように設定しており、マウスに対してパラメタの

	覚醒			ノンレム				レム				Δ	
	Sensitivity	Specificity	Precision	F-measure	Sensitivity	Specificity	Precision	F-measure	Sensitivity	Specificity	Precision	F-measure	Accuracy
EMG(small)	97.12%	96.34%	94.78%	95.94%	93.59%	97.03%	97.26%	95.39%	91.70%	98.38%	75.85%	83.03%	94.88%
EMG(large)	94.34%	97.34%	96.05%	95.19%	95.24%	95.75%	96.17%	95.70%	89.84%	97.96%	73.00%	80.55%	94.46%
EMG(small+large)	92.50%	97.40%	96.08%	94.26%	94.46%	96.43%	96.75%	95.59%	91.59%	96.38%	63.79%	75.20%	93.32%
RMS(small)	95.49%	96.43%	94.86%	95.17%	94.58%	96.15%	96.52%	95.54%	87.39%	98.34%	76.08%	81.34%	94.48%
RMS(large)	96.25%	97.25%	95.99%	96.12%	95.71%	95.65%	96.12%	95.92%	86.33%	99.02%	83.14%	84.70%	95.38%
RMS(small+large)	93.86%	96.99%	95.56%	94.70%	95.27%	95.72%	96.18%	95.73%	85.44%	97.74%	74.57%	79.63%	94.03%

表 3 前処理の有無と CNN のフィルタサイズによる一致率の比較

	覚醒			ノンレム				レム				Accuracy	
	Sensitivity	Specificity	Precision	F-measure	Sensitivity	Specificity	Precision	F-measure	Sensitivity	Specificity	Precision	F-measure	
脳波+筋電	96.25%	97.25%	95.99%	96.12%	95.71%	95.65%	96.12%	95.92%	86.33%	99.02%	83.14%	84.70%	95.38%
脳波のみ	96.97%	96.34%	94.79%	95.87%	94.58%	96.41%	96.75%	95.65%	87.87%	98.98%	82.66%	85.19%	95.16%

表 4 筋電位の有無による一致率の比較

		覚醒			ノンレム					
	Sensitivity	Specificity	Precision	Sensitivity	Specificity	Precision	Sensitivity	Specificity	Precision	Accuracy
DeepSleepNet	96.25%	97.25%	95.99%	95.71%	95.65%	96.12%	86.33%	99.02%	83.14%	95.38%
LSTM	96.17%	96.27%	94.92%	95.07%	95.22%	95.81%	82.89%	99.28%	85.46%	94.89%
MASC	95.42%	98.09%	Į	94.37%	96.63%	J	94.74%	97.37%	ļ	94.76%

表 5 既存手法との一致率比較

最適化を行っていない。学習データとテストデータの Accuracy から汎化性能が低いことが分かったため、特徴抽出部や識別部 の素子数と層数を少なくするようパラメタを調整することでより性能が向上すると考えられる。

6. まとめと今後の課題

本稿では高精度なマウスの自動睡眠ステージ判定手法開発のための一検討として、ヒトの睡眠ステージ判定手法でディープラーニングを用いて優れた性能を示した DeepSleepNet のマウスの睡眠ステージ判定への適用を行った。実験を通して覚醒・ノンレムの判定については DeepSleepNet が既存手法と同等以上の一致率であることを確認した。特にレムの判定も含めてLSTM を用いた手法と比較すると一致率は向上しており、フーリエ変換による周波数成分を特徴量とするより、CNN による特徴抽出が有効であることが分かった。

しかし、MASCとの比較するとレムの一致率が低く、モデルのパラメタがマウスに対して最適化されていなことがこの要因と考えられる。

今後は DeepSleepNet をもとに、マウスの睡眠時の脳波、筋電位の特徴をより拾いやすいように、モデルの構造やパラメタを調整を行い、一致率の改善を目指す。

謝 辞

本研究の一部は、文部科学省・地域イノベーション・エコシステム形成プログラム、ならびに科学研究費補助金・新学術領

域研究"宇宙に生きる"「超ストレス環境・宇宙を見据えた新規 睡眠覚醒制御手法の開発」によるものである。

文 献

- Jurij Brankacka, Valeriy I. Kukushka, Alexei L. Vyssotski, Andreas Draguhn, "EEG gamma frequency and sleep-wake scoring in mice: Comparing two types of supervised classifiers", BRAIN RESEARCH, vol. 1322, pp.59-71, 2010.
- [2] Genshiro A. Sunagawa, Hiroyoshi Sei, Shigeki Shimba, Yoshihiro Urade, Hiroki R. Ueda, "FASTER: an unsupervised fully automated sleep staging method for mice", Genes to Cells 18, pp. 502-518, 2013.
- [3] Michael J Rempe, William C Clegern, Jonathan P Wisor, "An automated sleep-state classification algorithm for quantifying sleep timing and sleep-dependent dynamics of electroencephalographic and cerebral metabolic parameters", Nature and Science of Sleep, vol. 7, pp.85-99, 2015.
- [4] 鈴木悠太, 佐藤牧人, 塩川浩昭, 柳沢正史, 北川博之, "マウスの 脳波/筋電図を利用した睡眠ステージ判定", 第9回データ工学 と情報マネジメントに関するフォーラム (DEIM2017),E6-1.
- [5] 山部剛士, 佐藤牧人, 塩川浩昭, 柳沢正史, 北川博之, "ディープラーニングを用いたマウスの睡眠ステージ分析", 情報処理学会第79回全国大会, 5K-03.
- [6] Akara Supratak, Hao Dong, Chao Wu, Yike Guo, "Deepsleepnet: A model for automatic sleep stage scoring based on raw single-channel eeg", IEEE transactions on Neural System and Rehabilitation Engineering, vol. 25, no. 11, 2017
- [7] F.A. Gers, J. Schmidhuber, F. Cummins, "Learning to forget: continual prediction with hstm", Neural Computation, vol. 12, pp. 2451-2471, 2000.