

マウス睡眠ステージ判定課題における深層学習を用いたノイズ分析

住谷 雄樹[†] 堀江 和正^{††} 北川 博之^{††}

[†] 筑波大学システム情報工学研究科 〒305-8577 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: [†]y.sumiya@kde.cs.tsukuba.ac.jp, ^{††}{horie,kitagawa}@cs.tsukuba.ac.jp

あらまし 睡眠医学や脳科学の分野における検査や解析において、外乱に起因するノイズは精度悪化や処理の複雑化の原因となる。脳波信号からこのようなノイズを分離し、その具体的なサンプルを獲得することには、ノイズに対する分析や対策に繋がり、多くの需要がある。しかし、現状ではノイズと脳波信号とを分離する方法は確立されていない。一方で近年、ノイズに対してロバストに脳波解析を行う機械学習モデルが提案されている。モデルの解析対象となる信号は、解析に有用である脳波成分、解析に不要な脳波成分、外乱によるノイズを含んでいるが、ノイズにロバストなモデルは、信号から解析に有用な脳波成分のみを分離し、それ以外を捨てていると考えられる。モデルが捨てている成分を獲得し、そこに含まれる脳波成分とノイズとを分離することで、ノイズのサンプルを獲得できると期待される。本研究は、脳波を対象とした睡眠ステージスコアリング手法である MC-SleepNet に着目し、モデルが捨てている成分からノイズを分離し、そのサンプルを獲得することを目的とする。本稿ではノイズのサンプルを獲得する前段階として、オートエンコーダを用いて脳波からモデルの判定に不要である成分を分離する手法を提案する。

キーワード 生体信号処理, 深層学習, オートエンコーダ

1 序 論

睡眠医学や脳科学の分野では、脳波を対象とした検査や解析が多く存在する。このような解析では、脳波に混入するノイズが精度悪化や前処理の複雑化を引き起こすため、度々問題となっている。例として、睡眠ステージスコアリングというタスクは、一定区間の脳波に対して、その特徴から覚醒・レム・ノンレムといった睡眠ステージをラベル付ける。睡眠ステージスコアリングでは、専門の技師が目視によって脳波を確認し、ノイズの形状に合わせてその都度フィルタを設計し適用するため、専門性と多くの労力を必要とする。またノイズによる影響が大きい区間は、判定不能であるとラベル付けされる場合もある。また、自動でスコアリングを行う手法 [1] [2] も提案されているが、これらの手法はノイズを含む脳波に対する制度が悪化することが知られている。このようなノイズを脳波から分離し、その具体的なサンプルを獲得・分析することは、その環境におけるノイズの特徴を把握することや、事前の対策につながる。

しかし、脳波に混入するノイズは測定環境に依存する非正常なものも多く、事前にそれらの特性を全て把握することは困難である。また、脳波自身についても検体の個体差が存在する。そのため、あらゆる環境で脳波とノイズとを分離する画一的な手法を確立することは困難である。

一方で、近年提案された深層学習を用いたマウスのステージ判定手法である MC-SleepNet [3] は、高いノイズロバスト性を有し、自動判定モデルを実環境で運用する上での最低ラインである判定精度 95% を達成している。MC-SleepNet はノイズを含むマウス脳波・筋電を大量に使用して訓練することで、脳波信号の特徴空間において判定に有用な成分を識別する境界面を

獲得する。そして実際の特徴抽出処理では、有用である成分のみを残し、それ以外の成分を捨てていると考えられる。

本研究では、この MC-SleepNet によって捨てられる成分に着目し、脳波に混入するノイズのサンプルを獲得することを目的とする。MC-SleepNet が捨てた成分は、睡眠ステージ判定には不要である脳波成分と、外乱によるノイズを含んでいると考えられる。マウス脳波の定常性を仮定すると、捨てられた成分から非正常なものを分離することで、脳波信号に混入するノイズのサンプルを獲得することができる。

本稿ではノイズサンプルを獲得する前段階として、畳み込みオートエンコーダ (CAE) を用いて、MC-SleepNet が捨てている成分を獲得する方法を提案する。CAE は、教師なし学習により入力 of 低次元特徴を獲得する深層学習モデルであり、時間空間の生体信号から特徴を抽出することができる [4], [5]。提案手法では、CAE を用いて脳波を局所波形成分に分解する。CAE は脳波信号を低次元特徴に分解したのち、その特徴から元の信号を再現するように学習する。このような学習を行うことで、CAE は脳波信号に類出する低次元パターンを抽出する。一方で MC-SleepNet は、大量の脳波データを用いて学習することで、脳波信号からスコアリングに有用な頻出パターンを抽出する。そのため、MC-SleepNet がある脳波信号から抽出した成分の集合は、その脳波信号を CAE で分解した局所波形集合のサブセットになっていると仮定することができ、MC-SleepNet が抽出する成分は CAE によって分解された局所波形成分の組み合わせによって再現できると考えられる。そして局所波形成分のうち、MC-SleepNet の特徴の再現に寄与していないものを特定することで、MC-SleepNet が特徴抽出の過程で捨てている成分を獲得することができる。具体的には、 $\mathbb{R}^{M \times N}$ の重み行列 W を用いて $\mathbb{R}^{N \times d}$ の CAE の局所波形成分 h_{AE} から $\mathbb{R}^{M \times d}$

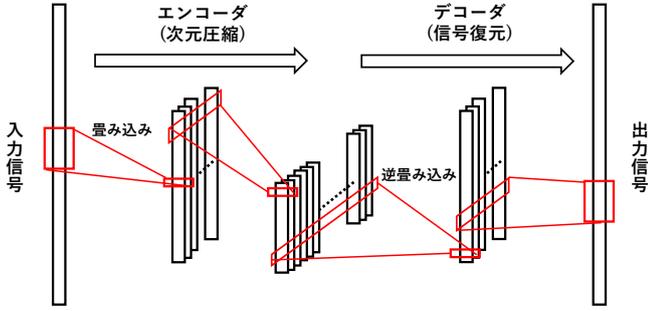


図1 畳み込みオートエンコーダ.

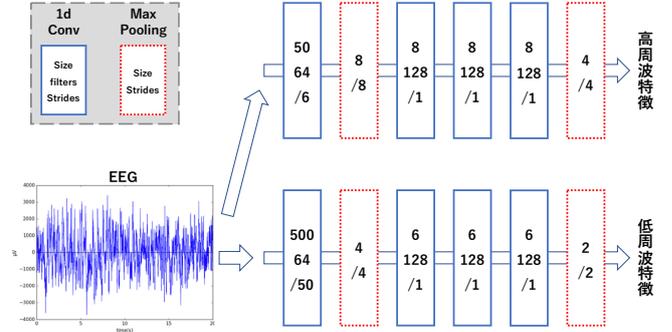


図2 MC-SleepNet の特徴抽出部 (脳波).

の MC-SleepNet の中間特徴 h_{MC} を $h_{MC} = W * h_{AE}$ のように再現する. このとき, 重み行列 W の n 列成分は, h_{AE} の n 行成分がどの程度 h_{MC} の再現に寄与したかを表すため, 値が小さい W の列と対応している h_{AE} の行成分が MC-SleepNet によって捨てられている成分であると考えられる.

本項の構成は以下の通りである. 第二章で前提知識として CAE と MC-SleepNet について述べる. 第三章で本項で提案する手法である, MC-SleepNet が捨てている成分の獲得方法について述べ, 第四章で CAE の波形分解性能を評価する予備実験について述べる. 最後に第五章で結論を述べる.

2 前提知識

2.1 畳み込みオートエンコーダ

畳み込みオートエンコーダ (CAE) は, 局所特徴を元に次元圧縮を行い, 入力信号の低次元表現を獲得する. 図1に CAE の概要を示す. CAE は入力の次元圧縮を行うエンコーダと, 圧縮された低次元表現から入力信号を再現するデコーダという, 2種類のニューラルネットワークで構成される.

エンコーダは, 複数のカーネルによって入力信号を畳み込むことで, 入力を局所波形特徴に分解する. k 次元カーネル K による l 次元信号 I の畳み込みは, 下記の式 (1) で表される.

$$o_i = \sum_{x=1}^k I_{i+x} \cdot K_x \quad 0 < i < l - k. \quad (1)$$

カーネルとそれによる畳み込みの出力にはそれぞれ, 畳み込み波形とその波形に対する各位置毎の反応度合いの情報が記録されている. 一方デコーダは, 逆畳み込み (Deconvolution) と呼ばれる操作で, 低次元特徴から元の信号を復元する.

CAE の学習では, 元信号とデコーダによる再現信号の誤差を最小化する. 具体的には, 下記の式 (2) で表される目的関数 L を最小化するようなパラメータ θ_{enc} , θ_{dec} を誤差逆伝播によって探索する.

$$L = \text{diff}(x, \text{DEC}(\text{ENC}(x|\theta_{enc})|\theta_{dec})), \quad (2)$$

x は入力信号, $\text{DEC}(\ast)$ はデコーダ関数, $\text{ENC}(\ast)$ はエンコーダ関数をそれぞれ表していて, L は入力信号とデコーダによって再構成された信号の差として定義されている. L を最小化するような θ_{enc} によって圧縮された中間特徴は, 入力信号をより低次元で表現している.

2.2 MC-SleepNet

Yamabe ら [3] はニューラルネットワークによる自動マウス睡眠ステージ判定手法である, MC-SleepNet を提案した. MC-SleepNet は, ノイズを含んだマウス脳波・筋電を大量に用いて学習することで, 従来の自動判定手法の課題であった, 判定精度の向上とノイズロバスト性を達成した. マニュアル判定による睡眠ステージは, 着目しているエポックの局所波形と, 前後のエポックのステージを参考にしてルールベースで決定される. MC-SleepNet はこれらのルールを再現するため, Convolutional Neural Network (CNN) で脳波・EMG の波形特徴を抽出した後, bidirectional Long-Short Term Memory (bi-LSTM) で信号の双方向時系列を考慮した判定を行う.

本研究では脳波に対する特徴抽出部に着目する. MC-SleepNet がノイズに対してロバストであるのは, 特徴抽出の過程で判定に不要なノイズを選択的に捨て, 判定に必要な部分のみを残しているためであると考えられる. 図2に MC-SleepNet の脳波に対する特徴抽出部を示す. MC-SleepNet は, Relu を活性化関数とするフィルタ幅の違う2種類の CNN によって, 低周波特徴と高周波特徴をそれぞれ抽出する.

各 CNN は畳み込み層とプーリング層で構成される. 畳み込み層では局所波形特徴の抽出と, ストライドによる次元削減が行われる. ストライドは畳み込みの際のカーネルの移動幅で, この幅が大きい程より多くの情報が削減される. プーリング層では Max-Pooling と呼ばれる操作で次元削減を行う. Max-Pooling は信号を長さ N の区間に分割し, それぞれの区間に対して区間内の最大値を割り当てる. Max-Pooling では, 入力次元が $1/N$ に削減される. 最終的に抽出される特徴はフィルタ波形で信号を畳み込んだ結果で, 時間軸方向についての信号の各領域と CNN のフィルタ波形の類似度である. 図3に, 脳波信号から抽出された低周波特徴と高周波特徴の例を示す.

3 提案手法

本章では, 観測された脳波信号から, 睡眠ステージ判定に必要な成分を獲得する方法について述べる. 本提案手法では, 脳波を局所波形特徴に分解する CAE を訓練する. CAE が脳波信号の再現に成功している時, CAE は脳波信号に類する局所波形特徴を不足なく抽出していると考えられる. 従って, CAE

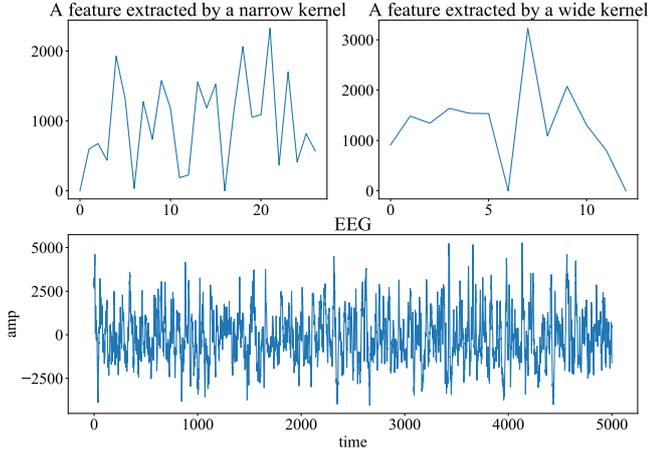


図3 左上: 狭いカーネルで抽出された特徴の例. 右上: 広いカーネルで抽出された特徴の例. 下: 元の脳波信号.

が抽出した局所波形特徴集合 \mathcal{S}_{CAE} と MC-SleepNet が抽出する特徴集合 \mathcal{S}_{MC} は式 (3) の包含関係であると考えられる.

$$\mathcal{S}_{MC} \subseteq \mathcal{S}_{CAE} \quad (3)$$

ここで, ある脳波信号に対して CAE が抽出する $\mathbb{R}^{N \times d}$ の特徴 F_{CAE} と, MC-SleepNet が抽出する $\mathbb{R}^{M \times d}$ の特徴 F_{MC} を考える ($N > M$). $\mathbb{R}^{M \times N}$ の行列 W を導入すると, 式 (4) のように F_{CAE} から F_{MC} の再現が可能である.

$$F_{MC} = W \cdot F_{CAE} \quad (4)$$

W の i, j 成分 w_{ij} は, F_{CAE} の i 番目の波形特徴が F_{MC} の j 番目の特徴の再現にどの程度寄与しているかを表す. 例えば, F_{CAE} の n 番目の成分が F_{MC} の再現に全く寄与しないとき, W の n 列成分は全てゼロとなる. このように W の列成分の大きさから, 脳波から得られた F_{CAE} のうち F_{MC} の再現に寄与する成分とそうでない成分とを分離することができる. 本手法では上記のようにして, 脳波から睡眠ステージ判定に不必要な成分を抽出する.

提案手法の概要を図4に示す. 提案手法は, 学習フェーズと復号フェーズから構成される. 学習フェーズでは, 脳波を局所波形特徴に分解する CAE の学習と, 分解された特徴から MC-SleepNet の特徴を再現する重み行列 W の学習を行う. 復号フェーズでは学習された W を元に, 脳波の局所波形特徴のうちスコアリングに不要である成分を特定し, それらから信号を復号する.

3.1 学習フェーズ

学習フェーズでは CAE を訓練した後, CAE のパラメータを固定して重み行列 W の最適化を行う.

3.1.1 CAE の学習

本提案手法の CAE の損失関数は以下の式 (5) で定義される.

$$L_{CAE} = \text{diff}(\mathbf{x}, \mathbf{DEC}(ENC(\mathbf{x}|\theta_{enc})|\theta_{dec})) + \alpha(\text{norm}(\theta_{enc})), \quad (5)$$

\mathbf{x} は入力信脳波, $DEC(*)$ はデコーダ関数, $ENC(*)$ はエンコーダ関数をそれぞれ表していて, L は入力脳波とデコーダによって再構成された脳波の差として定義されている. $\text{norm}(*)$ は α で重み付けされた正則化項で, ネットワークパラメータの値の発散を防ぐ. CAE のパラメータ θ は, 式 (6) の確率的勾配降下法で最適化される.

$$\theta \leftarrow \theta - \alpha \frac{\partial L_{CAE}(\theta)}{\partial \theta}. \quad (6)$$

3.1.2 重み行列の学習

重み行列 W は, 脳波信号 x から CAE が抽出した局所波形特徴 F_{CAE} を変換し, MC-SleepNet が x から抽出する特徴 F_{MC} を再現するように学習する. 具体的には, 式 (7) で表される L_W を最小化するように学習する.

$$L_W = \text{diff}(MC(\mathbf{x}) - \text{Relu}(W \cdot ENC(\mathbf{x}))), \quad (7)$$

\mathbf{x} , $MC(*)$, $ENC(*)$ はそれぞれ脳波信号, MC-SleepNet の特徴抽出部, CAE のエンコーダ関数を表す. L_W は MC-SleepNet が抽出する特徴と W によって変換された特徴の差として定義されている. W は, 式 (8) の確率的勾配降下法で最適化される.

$$W \leftarrow W - \alpha \frac{\partial L_W(W)}{\partial W}. \quad (8)$$

3.2 復号フェーズ

復号フェーズでは学習された W を元に, エンコーダが出力する特徴 F_{CAE} のうち MC-SleepNet の特徴再現に寄与しないチャンネルを特定し, それらを元に信号を復元する. そのようなチャンネルのインデックス集合 \mathcal{I} は, 下記の式 (9) で得ることができる.

$$\mathcal{I} = \{j \in \mathbb{Z} \mid \|\mathbf{W}_{:,j}\| < \alpha\} \quad (9)$$

\mathcal{I} は, W の列ベクトルのうち, そのノルムが閾値 α 以下になるようなインデックスの集合である. 脳波信号から CAE が抽出した F_{CAE} の行のうち, \mathcal{I} 以外のインデックスの要素を全て 0 にし, これをデコーダに入力することでノイズ信号の復号する.

4 予備実験

CAE によるマウス脳波の次元圧縮および波形再現が可能であることを確認する予備実験を行う. 学習が終了した CAE で学習データの脳波を再現し, 元の脳波信号に対するエラー率を評価する.

4.1 CAE のハイパーパラメタ

エンコーダーは3層の畳み込み層で構成され, 各層のカーネルサイズ, カーネル数, スライドは以下の通りである. (1)conv50, カーネル数=64, スライド=6, (2)conv8, カーネル数=128, スライド=8, (3)conv4, カーネル数=128, スライド=4. 各層の活性化関数には線形関数を用いる. エンコーダのハイパーパラメタは, MC-SleepNet の高周波特徴抽出部の層構成を元に決定されている. 最終的にエンコーダは, 27次元の波形特徴を128個出力する.

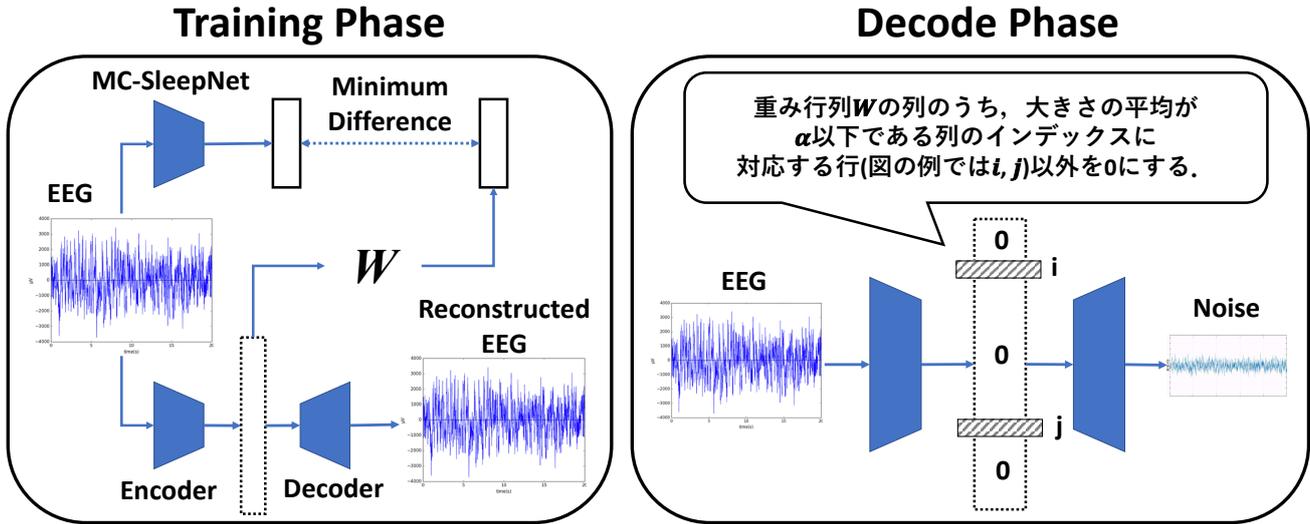


図4 提案手法の概要. 学習フェーズでは CAE と W の学習が行われ, 復号フェーズでは脳波から MC-SleepNet が捨てている成分を特定し, 復号する. なお, これらの操作は MC-SleepNet が抽出する高周波特徴と低周波特徴のそれぞれについて行われる.

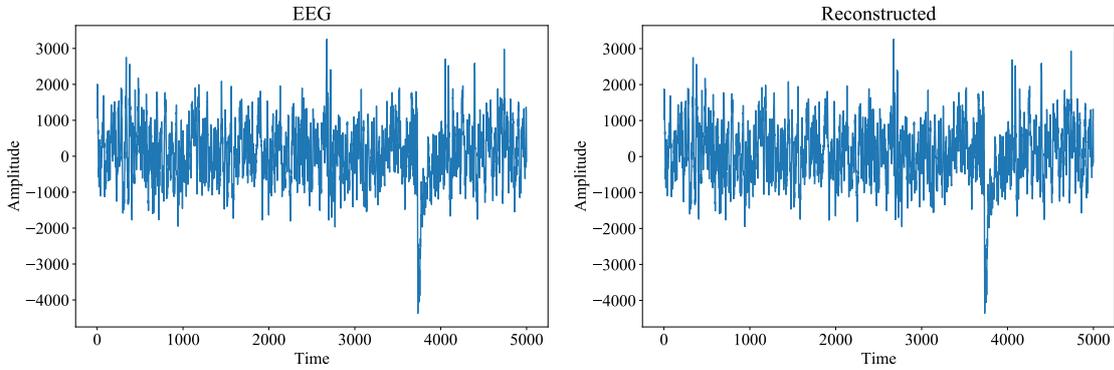


図5 CAE による波形再現の例.

デコーダは3層の逆畳み込み層で構成され, 各層のカーネルサイズ, カーネル数, ストライドは以下の通りである. (1)conv4, カーネル数=128, ストライド=4, (2)conv8, カーネル数=64, ストライド=8, (3)conv50, カーネル数=1, ストライド=6. 各層の活性化関数には線形関数を用いる.

損失関数の誤差関数 $diff(*)$, 正則化項 $norm(*)$ にはそれぞれ, 二乗誤差と L2 ノルムを用いる.

4.2 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 (IIIS) より提供されたマウスの脳波データセットを使用する. データセットには約 4300 匹のマウスの 4 日分の脳波が, 20 秒を 1 エポックという単位として記録されている. 本実験では, データセットから 10 匹分のデータ (84300 エポック) を選択し, CAE の学習に使用する.

4.3 実験結果

300 回の学習が終了した CAE に学習データの脳波を入力し, 波形の再現を行なった例を図 5 に示す. また式 (10) によって,

脳波信号の振幅に対する再現信号の絶対誤差の比率 R_{error} を算出した.

$$R_{error} = \frac{\sum_{i=1}^{84300} \|x_i - CAE(x_i)\|}{\sum_{i=1}^{84300} \|x_i\|}, \quad (10)$$

x は脳波信号, $CAE(x)$ は CAE による再現信号を表す. R_{error} は約 1.5% であり, CAE は非常に高い精度で信号再現を行なっている. このことから, CAE は波形情報を損なうことなく脳波を局所波形特徴へ変換していると考えられる.

5 結 論

本研究では, 脳波信号から外乱によるノイズを分離しその具体的なサンプルを獲得することを目的としている. 我々は, ノイズにロバストな自動睡眠ステージスコアリングモデルである MC-SleepNet が, 入力された脳波信号から判定に不要である成分を捨てていることに着目した. 捨てられる成分を判定に不要な脳波成分と外乱によるノイズとに分離することで, ノイズのサンプルを獲得できると考えた. 本稿ではノイズサンプルを獲得する前段階として, 脳波信号を構成する成分のうち,

MC-SleepNet が捨てている成分を特定し抽出する方法を提案した。提案手法は脳波の波形特徴分解を行う畳み込みオートエンコーダ (CAE) と、CAE の波形特徴から MC-SleepNet の特徴を再現する重み行列で構成される。予備実験によって、CAE による脳波の次元圧縮と波形再現が可能であることを確認した。学習データに対する波形再現の誤差は非常に小さく、このことから CAE は波形の情報を損なわずに脳波の波形特徴分解を行なっていると考えられる。

今後は、CAE の中間特徴を MC-SleepNet の特徴に変換する行列 W を訓練した後、 W を元に脳波からステージスコアリングに不要な信号を復号し、その妥当性を評価する。また、得られた信号を脳波と外乱によるノイズとに分離する方法を検討する。

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、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

- [1] Genshiro A Sunagawa, Hiroyoshi Séi, Shigeki Shimba, Yoshihiro Urade, and Hiroki R Ueda. Faster: an unsupervised fully automated sleep staging method for mice. *Genes to Cells*, Vol. 18, No. 6, pp. 502–518, 2013.
- [2] Yuta Suzuki, Makito Sato, Hiroaki Shiokawa, Masashi Yanagisawa, and Hiroyuki Kitagawa. Masc: Automatic sleep stage classification based on brain and myoelectric signals. In *Data Engineering (ICDE), 2017 IEEE 33rd International Conference on*, pp. 1489–1496, 2017.
- [3] Masato Yamabe, Kazumasa Horie, Hiroaki Shiokawa, Hiro-masa Funato, Masashi Yanagisawa, and Hiroyuki Kitagawa. Mc-sleepnet: Large-scale sleep stage scoring in mice by deep neural networks. *Scientific reports*, Vol. 9, No. 1, pp. 1–12, 2019.
- [4] Tingxi Wen and Zhongnan Zhang. Deep convolution neural network and autoencoders-based unsupervised feature learning of eeg signals. *IEEE Access*, Vol. 6, pp. 25399–25410, 2018.
- [5] Ozal Yildirim, Ru San Tan, and U Rajendra Acharya. An efficient compression of eeg signals using deep convolutional autoencoders. *Cognitive Systems Research*, Vol. 52, pp. 198–211, 2018.