

敵対的生成ネットワークを用いた マウス EEG のノイズ削減手法の提案

住谷 雄樹[†] 堀江 和正^{††} 塩川 浩昭^{††} 北川 博之^{††}

[†] 筑波大学システム情報工学研究科コンピュータサイエンス専攻 〒305-8573 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 〒305-8573 茨城県つくば市天王台 1-1-1

E-mail: [†]y.sumiya@kde.cs.tsukuba.ac.jp, ^{††}{horie,shiokawa,kitagawa}@cs.tsukuba.ac.jp

あらまし 睡眠に関する基礎研究において、マウス生体信号（脳波・筋電位）からの睡眠ステージ（状態）解析は重要な試験の一つである。この解析を高精度に行うためには、生体信号、特に脳波に含まれるノイズを除去する必要があるが、従来の技師による目視・手作業でのノイズ除去は多くの時間と労力を必要としていた。これらに対し、ノイズの性質等の事前知識を必要としない自動ノイズ除去手法の開発が求められている。そこで本研究では、深層学習による信号生成モデル SimGAN の構成・損失関数を変更し、EEG のノイズ除去モデルを開発した。また、人工的なノイズを除去する評価実験により提案手法が、ノイズに関する事前知識や作成に手間のかかる学習サンプルを用いず、ノイズに合わせて最適化した周波数フィルタとほぼ同等の性能を達成できることを示した。

キーワード 脳波, マウス, 時系列データ, 深層学習, 敵対的生成ネットワーク, ノイズ削減

1 序 論

睡眠に関する基礎研究では、マウスの脳波 (EEG) や筋電位 (EMG) の特徴を元にした睡眠ステージ (状態) の判定が頻繁に行われる。例えば、薬剤やマウスの遺伝子が睡眠に与える影響や、睡眠障害の発生要因の調査する際に、睡眠状態を正確に把握することは非常に重要である。しかし、睡眠状態の判定は非常に多くの時間と労力を要するため、睡眠研究の効率化におけるボトルネックの一つとなっている。上記の問題を解決すべく、これまでに様々な睡眠ステージ自動判定手法 [1, 2] が提案されている。例えば、SOTA である MASC [2] は、マウスの睡眠ステージを 95% 近い精度で推定できることが示されている。これらの手法を用いることで、睡眠研究の効率を改善できる可能性が示唆されている。一方、実用化に向けた課題もまだ残されていて、本研究ではそれらの課題の中でもノイズに対する頑健性の低さに注目する。

従来の睡眠ステージ判定手法は、EEG や EMG の特定の周波数帯の大きさ、それらの比率等の特徴量として各ステージの認識を行う。そのため、ノイズによって周波数成分が乱れた信号に対しては判定精度が低下する。また、一般的な研究で用いられる生体信号、特に EEG では、判定精度に影響を与えるノイズが混入するケースが多くある。例えば、一般的なマウス脳波の計測ではマウスの移動や動作に制限をかけないため、体動に由来する低周波を中心としたノイズが頻繁に検出される。

ノイズによる判定精度の低下に対する最も簡単な解決法は、事前処理によるノイズ除去である。これまでの睡眠研究は、技師が目視でノイズを確認した上で、ノイズの特性に合わせたフィルタを適宜適用することでノイズを除去、判定精度の向上を図っている。このような技師のノイズ除去手順を再現できる

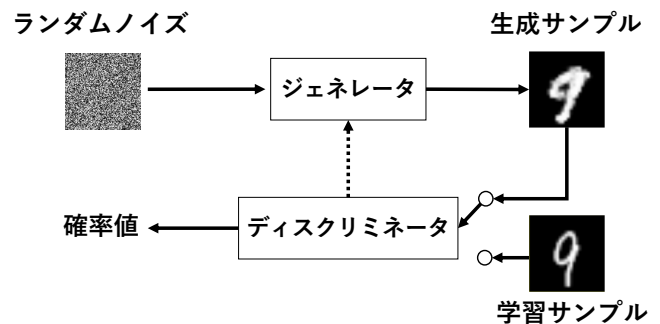


図1 一般的な GAN の構成。

自動ノイズ除去手法を開発すれば、既存の睡眠ステージ判定手法による判定精度を向上させることができるだろう。

マウス生体信号には体動の他、電源に起因するノイズ等、性質が異なるノイズが多数含まれている。また、これらのノイズは計測環境やマウスの個体差といった影響を強く受けるため、性質を事前に全て把握することは現実的ではない。ノイズに関する事前知識なしに、ノイズに適した除去手順を獲得する方法が求められる。一方、近年深層学習による音声ノイズ除去手法が複数提案されている [3, 4]。これらはノイズ入りの音声とそのノイズのない音声部分のペアから、これらの対応関係を学習、モデル化するもので、多種多様なノイズを除去できることが示されている。これらのノイズ除去手法は、十分な信号ペアさえ用意できれば、ノイズに関する事前知識を用いることなく、最適なノイズ除去手順を獲得できる。

しかし、マウス EEG を対象とする場合、十分な数の信号ペアを用意するのは容易ではない。音声信号の場合、車の音や拍手といったノイズは、音声と独立に計測できることから、「ノイズ入りの音声」を容易に作成することができる。この人工的な

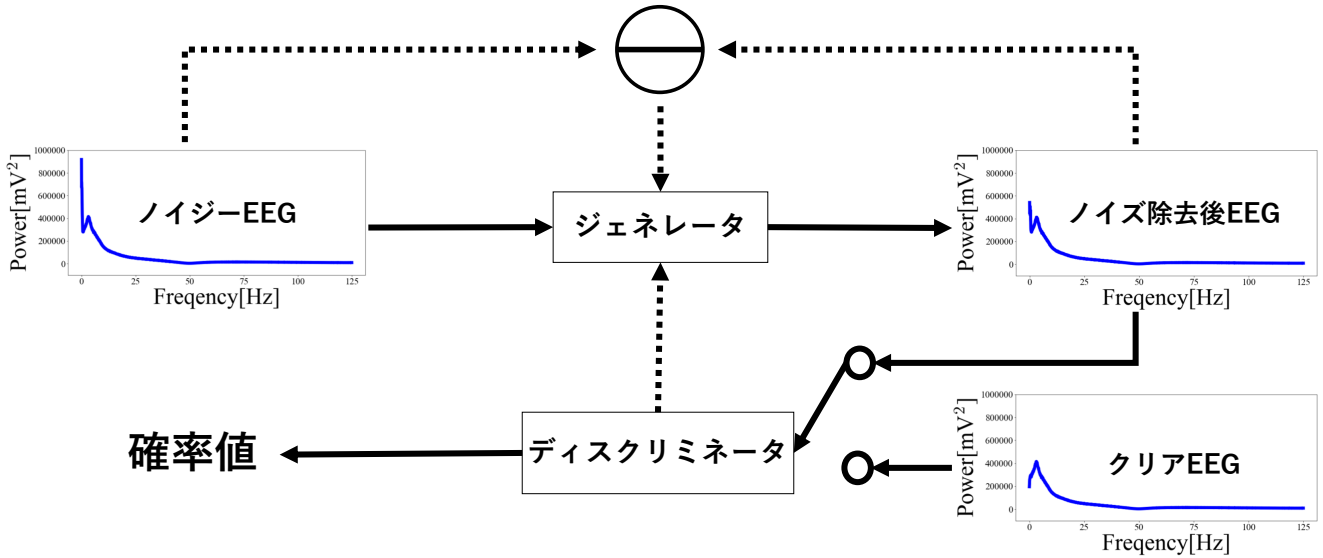


図2 提案手法の構成.




図3 ジェネレータとディスクリミネータの構成.

ノイズ入りの音声と、その元となったクリアな音声をペアとすることで、大量の信号ペアを用意することが可能である。一方、マウス EEG の場合、ノイズはセンサの接触部や信号線、マウス生体内で発生するため、「ノイズのみ分離して計測」するのは不可能である、音声と同様の手順で信号ペアを作成することは困難である。

本研究では、SimGAN [5] と呼ばれる信号変換の深層学習モデルに着目した。これは信号変換用と変換後の信号の質評価用の2つのニューラルネットワークから構成されるモデルである。信号変更用のニューラルネットワークは、「理想的な出力と実際の出力の差分」ではなく、「評価用ネットワークの評価」を元に各パラメータを最適化するため、入出力の信号ペアを必要としない。そのため、SimGAN は信号のペアの生成が困難である本課題に適したモデルである。

以上を踏まえ、本研究では SimGAN をベースに、マウス生体信号のノイズ除去モデルを開発することを目的とする。また、人工的なノイズを用いた評価実験を通じ、本手法のノイズ除去性能の評価を行った。


2 敵対的生成ネットワーク (GANs)

敵対的生成ネットワーク [6] は、人工的な信号を生成するための深層学習モデルで、ジェネレータ・ディスクリミネータと呼ばれる二つのニューラルネットワークから構成される。これらはそれぞれ異なる役割を持っていて、ジェネレータはランダムノイズを変換して信号を生成する役割を、ディスクリミネータは入力信号が学習サンプル（理想的な出力の例）である確率の計算をする役割を、それぞれ担っている。ジェネレータとディスクリミネータの損失関数 L_g, L_d を式 1, 2 に示す。


$$L_g = \mathbb{E}_{\mathbf{x} \sim p_{\mathbf{x}}(\mathbf{x})} [\log(1 - D(G(\mathbf{x})))], \quad (1)$$

$$L_d = \mathbb{E}_{\mathbf{x} \sim p_{\mathbf{x}}(\mathbf{x})} [\log(D(G(\mathbf{x})))] + \mathbb{E}_{\mathbf{y} \sim p_{\text{data}}(\mathbf{y})} [\log(1 - D(\mathbf{y}))] \quad (2)$$

$\mathbf{x}, G(\mathbf{x})$ はジェネレータの入力と生成信号、 \mathbf{y} と $D(\mathbf{y})$ は学習サンプルとディスクリミネータが計算した入力信号が学習サンプルである確率を示している。ディスクリミネータは、入力が生成信号か学習サンプルかを正確に判定できるように学習する。一方ジェネレータは、自身の出力に対してディスクリミネータが誤判定を起こすように、つまりディスクリミネータが学習サン



(a) 時間空間.



(b) 周波数空間. 青いエリアは各周波数成分が取りうる範囲を示す.

図4 クリア EEG の例.

プルであると判定する信号を生成するように学習する. GAN の学習には, ジェネレータの入力に変換したい信号, 学習サンプルに出力として理想的な信号を用いるが, ジェネレータの損失関数はディスクリミネータが計算した確率のみで定義されているため, これらの信号がペアである必要がない. そこで, ジェネレータの入力にノイズな生体信号, 学習サンプルに「計測したクリアな生体信号」をそれぞれ用いることで, ペアを用いることなくノイズな生体信号をクリアな生体信号に変換するモデルを得ることができる. しかし, 一般的な GANs のジェネレータは, 学習サンプルと似た信号を出力することのみを考慮するため, 必ずしも入力に近い信号を生成するとは限らないという性質がある. この性質は GANs を信号のノイズ除去に適用する上では望ましくない.

2.1 SimGAN

本研究では, GANs の拡張である SimGAN [5] に注目する. これは CG 画像のリアリティ改善に用いられるモデルで, GANs とはジェネレータの損失関数が異なる.

$$L_{s-g} = \mathbb{E}_{\mathbf{x} \sim p_{ns}(\mathbf{x})} [\log(1 - D(G(\mathbf{x}))) + \alpha \|\mathbf{x} - G(\mathbf{x})\|] \quad (3)$$

第二項は入出力の差として定義されている. SimGAN はこの損失関数を学習に用いることで, 入力信号を望ましい信号へ最小の変化量で変換することが可能である. α は, 入出力の差分をどの程度考慮するかを決定するハイパパラメータである. 生体信号においては, 元信号を大きく歪めるようなノイズが混入することは比較的稀であり, ノイズ除去のために入力信号を大きく変化させる必要はないといえる. そのため生体信号のノイズ除去には, 上記のように変化量を抑えつつ望ましい信号に変換できる SimGAN が適していると考えられる.

3 提案手法

本章では, 250Hz でサンプリングされた 20 秒の生体信号のノイズを除去する場合を例に, 提案手法の構造や学習方法について説明する. 提案手法は, 一般的な GANs や SimGAN と同様に, 一つのジェネレータとディスクリミネータから構成される (図 2). このうち, ジェネレータがノイズな生体信号とその生体信号部分のモデル化と前者から後者への変換を, ディスクリミネータは入力された信号が「計測されたクリアな生体信号」か, 「ジェネレータによりノイズ除去された信号」かの判断

をそれぞれ行う. 睡眠ステージ判定では, 脳波・筋電位の周波数成分の大きさやこれらの比を特徴量として利用する. そこで本提案手法では, ノイズ除去の対象とする生体信号や学習サンプルを, 周波数成分の大きさのベクトルで取り扱う. 生体信号は以下の FFT に従って周波数成分の大きさに変換される.

$$x(t) = \left| \sum_{z=0}^{4999} X(z) e^{-i \frac{2\pi t z}{5000}} \right|^2 \quad (4)$$

ここで, $\mathbf{X} (= \{X_1, X_2, \dots, X_{5000}\})$ は 250Hz でサンプリングされた EEG である.

3.1 ジェネレータとディスクリミネータの構造

本提案手法のジェネレータは, 中間層が 2 つの畳み込み層, 出力層が全結合で構成される Convolutional Neural Network (CNN) を用いる. まず, 入力されたノイズな生体信号は畳み込み層を経て, 特徴量に変換される. 本モデルの畳み込み層は, 1 層目を幅 15 のカーネル 128 個, 2 層目を幅 5 のカーネル 512 個とした. これらの畳み込み層では, 入力信号とカーネルの畳み込みを計算したのち, 下記の Parametric-Relu function で活性化を行う.

$$f(x) = \max(0.2x, x) \quad (5)$$

抽出された特徴量は, 全結合層に入力され, 生体信号の各周波数成分の大きさに変換される. ディスクリミネータはジェネレータとほぼ同様の構造となっている. ただし, 入力された信号が学習サンプルかジェネレータの出力かを判別するために, 出力層を全結合層ではなく, 2 素子からなる SoftMax 層としている. これらの構造とハイパパラメータは, いくつかの予備実験を通じて試行錯誤的に決定した.

3.2 学習方法


一般的な GAN と同様に, 提案モデルの学習はジェネレータとディスクリミネータの学習を交互に繰り返して行う. まず, ジェネレータは以下の二点を満たすように学習を行う.

- ディスクリミネータが学習サンプルだと誤判定するような信号を出力する
- 入出力の違いをなるべく小さくする


具体的には, 下記の損失関数 L_g を最小化するようにパラメータを調整する.

表 1 提案手法と周波数フィルタの比較.

	モーションアーチファクト		電源ノイズ		混合ノイズ	
	フィルタ	提案手法	フィルタ	提案手法	フィルタ	提案手法
ノイズ除去率	50.9%	52.1%	94.3%	94.2%	64.3%	65.7%
信号変化率	66.4%	44.1%	1.7%	1.7%	3.2%	9.8%



(a) 変換前.



(b) 変換後.

図 5 モーションアーチファクト除去の例. オレンジの線は EEG の 0~0.5Hz 成分を示す.

$$L_g = \mathbb{E}_{\mathbf{x} \sim p_{ns}(\mathbf{x})} [\log(1 - D(G(\mathbf{x}))) + \lambda |\mathbf{x} - G(\mathbf{x})|^2] \quad (6)$$

ここで, $\mathbf{x}, G(\mathbf{x})$ はジェネレータによりノイズ除去される前後の生体信号, $D(G(\mathbf{x}))$ はディスクリミネータが求めた除去後の信号が学習サンプルである確率, λ はハイパパラメータである. L_g の最小化は, SimGAN における Adversarial Loss with Self-Regularization の最小化とほぼ同様である. ディスクリミネータの学習は SimGAN と同様に, 下記の損失関数 L_d を最小化するように進められる.

$$L_d = \mathbb{E}_{\mathbf{x} \sim p_{ns}(\mathbf{x})} [\log(D(G(\mathbf{x}))) + \mathbb{E}_{\mathbf{y} \sim p_{cs}(\mathbf{y})} [\log(1 - D(\mathbf{y}))]] \quad (7)$$

4 人工ノイズを用いた評価実験

提案手法の性能を評価するため, 提案手法を用いて 3 種類のノイズを除去する実験を行った. また, 睡眠ステージ判定でよく行われる, ノイズに合わせた周波数フィルタを用いるノイズ除去結果との比較を行った.

4.1 対象とするノイズ

本研究では, モーションアーチファクト, 25 Hz 電源ノイズとこれらの混合ノイズの 3 種類のノイズを対象とした. これらのノイズは, 睡眠ステージ自動判定で解析する 0-30Hz の範囲内の周波数成分を有していることから, 判定精度の低下につながりやすいノイズといえる. モーションアーチファクトは, 0-0.5Hz の周波数成分を持つノイズで, ネズミが体動や寝返りをした際に発生する. 計測中にネズミが動作しないことはほぼなく, 生体信号中に乗りやすいノイズの一つである. 25Hz 電源ノイズは, 50Hz の交流電源が直流化する際に発生する 25Hz の電磁波をセンサケーブルが拾ったものである. 照明や他の計測機器を使用する場合, これらのノイズが含まれる場合がある.

4.2 使用するデータセット

本実験では, 国際統合睡眠医科学研究機構 (IIIS) より提供さ

れた, マウスの覚醒・睡眠時の脳波データセットを使用した. このデータセットの中から, 比較的ノイズの少ないマウス 7 匹の EEG 24 時間分 (図 4) に注目した. これらの EEG を 20 秒の小区間に分割し, マウス睡眠の専門家によってクリア (ノイズ除去不要) と判断された 3600 個のデータを実験に使用した. 3600 個のデータの内, 1800 個はディスクリミネータの学習サンプル, 残り 1800 個はジェネレータへの入力サンプルとなる人工的なノイジー EEG の作成に使用した. モーションアーチファクトは, マウスの動き方によって周波数傾向が変化するため, ノイズの生成モデルを作成することが困難であった. そこで本研究では, 専門家がノイジーと判断した脳波データの 0-0.5Hz 周波数成分をクリアな脳波データに上書きすることで, モーションアーチファクトの乗った脳波データを人工的に作成した. 25Hz 電源ノイズについては, クリア生体信号の 25Hz 周波数成分を, その大きさが小区間の最大周波数成分と同じになるように加えることで, 再現した. これらのノイズをクリアな EEG と混ぜ, 各ノイズごとに 1800 個, 計 5400 個のノイジー EEG を作成した.

4.3 評価指標

ノイズ除去性能の評価には, 除去できたノイズの割合 (式 8) とノイズの無い部分を変化させた割合 (式 9) の二つの指標を使用した. 除去できたノイズの割合が大きく, ノイズの無い部分は変化させないような手法は, ノイズ除去性能が高いといえる. 各指標の具体的な計算式を以下に示す.

$$1 - \frac{\sum_{i=0}^{1800} \sum_{j \in J} |c_i^{(j)} - G(\mathbf{x}_i)^{(j)}|}{\sum_{i=0}^{1800} \sum_{j \in J} |c_i^{(j)} - x_i^{(j)}|} \quad (8)$$

ここで, $x_i^{(j)}$, $G(\mathbf{x}_i)^{(j)}$, $c_i^{(j)}$ はそれぞれノイジー EEG, ノイズ除去後 EEG, ノイジー EEG の信号部分の j Hz 成分である. J はノイズを含んでいる周波数帯を表している.

$$\frac{\sum_{i=0}^{1800} \sum_{k \in K} |x_i^{(k)} - G(\mathbf{x}_i)^{(k)}|}{\sum_{i=0}^{1800} \sum_{k \in K} |x_i^{(k)}|} \quad (9)$$

ここで, K はノイズを含んでいない周波数帯を表している.




図 6 モーションアーチファクト除去の例




図 7 25Hz 電源ノイズ除去の例.




図 8 混合ノイズ除去の例.

4.4 提案手法によるノイズ除去

本提案手法のモデルを 50 回学習させたのち、学習時に用いていないノイズ EEG1800 サンプルに対してモデルを適用し、ノイズ除去を行った。また、これをモデルの初期値を変えつつ 5 回繰り返し、各指標の平均値を求めた。その結果として、本提案手法は、モーションアーチファクトノイズの約半分、25Hz 電源ノイズのほぼすべてを除去できることが明らかになった (表 1)。また、モーションアーチファクトと 25Hz 電源ノイズが両方含まれる場合であっても、ノイズの性質を把握、6 割以上除去できており、実際の脳波計測で見られるようなノイズについては本提案手法で除去できると考えられる。さらに、ノイズが含まれていない領域については、ノイズが含まれている領域に比べて変化量が少ないことが見て取れる (表 1, 図 6, 7, 8)。これは、本手法がノイズの周波数成分を学習し、これを選択的に除去できることを示している。

4.5 周波数フィルタとの性能比較

ノイズに合わせて最適化した周波数フィルタとの性能比較を行った (図 6, 7, 8)。本実験では、モーションアーチファクト

については、カットオフ周波数 0.5 Hz の 2 次オーダーのハイパスフィルタを、25Hz 電源ノイズについては、2 次オーダーの 25Hz バンドストップフィルタを使用した。なお、これら周波数フィルタの最適化は、ノイズの事前知識を使用し、試行錯誤的に行っている。比較の結果、本提案手法は最適化した周波数フィルタとほぼ同様のノイズ除去性能を有することが分かった。


4.6 クリアな信号に対してノイズ除去を実行した場合

クリアな信号に対して、モーションアーチファクト除去に最適化した提案手法と周波数フィルタを適用し、信号がどのように変化するか比較した (9)。入力信号にはノイズが含まれていないので、入力をそのまま出力するのが理想的な処理といえるが、本提案手法はモーションアーチファクトと同じ 0-0.5Hz の周波数成分を除去してしまった。このことから提案手法は、ノイズの有無を判別し、除去手順を変化させるということではできていないことがわかる。しかし、周波数フィルタと比較すると、変化量を抑えることができた。ノイズな EEG とクリアな EEG が両方入力される可能性がある場合、例えば、自動ステージ判定手法の前処理として使用する場合には、周波数フィルタよりも本手法が適しているといえる。本課題については、Gated Convolutional Neural Network 等、入力信号に合わせて処理を“切り替える”ことのできるネットワークを採用することでより適切なノイズ除去処理を達成できる可能性がある。

5 関連研究

5.1 睡眠ステージ自動判定手法

これまでにも、マウス生体信号からの睡眠ステージ自動判定に関する様々な手法が提案されている。特に FASTER [1] や



(a) ノイズエリア (0~0.5 Hz).

(b) 全体.

図9 クリア EEG に対するモーションアーチファクト除去の例.

表2 クリア信号・ノイズ信号のそれぞれに対する MASC のステージ判定精度 [2]

	ノンレム睡眠		レム睡眠		覚醒		accuracy
	sensitivity	specificity	sensitivity	specificity	sensitivity	specificity	
クリア信号	94.37 ± 1.44%	96.63 ± 1.30%	94.74 ± 2.86%	97.37 ± 0.94%	95.42 ± 2.25%	98.09 ± 0.93%	94.76 ± 1.02%
ノイズ信号	94.19 ± 5.47%	93.71 ± 2.07%	92.95 ± 7.11%	92.95 ± 7.11%	91.10 ± 4.98%	99.50 ± 0.34%	92.40 ± 3.31%

MASC [2] といった手法は、これまでの手法の中でも精度が良く、睡眠ステージを 90%以上の精度で推定することができる。しかし、これらの手法はマウス生体信号の 0-30 Hz 周波数成分を特徴量として利用しているため、これらの周波数成分を持つノイズに対して弱い。表 2 は、MASC を用い、クリアな信号、ノイズな信号それぞれに対してステージ判定を行った際の精度を示している。この表を見ると、MASC はクリアな信号については 94 % と非常に高い精度での推定を達成している。一方で、ノイズな信号では判定精度が 2 % 下がっている。睡眠ステージの自動判定手法が実用化されるには、専門技師間の判定一致率が約 95%であることに基づき、95%以上の判定精度が必要だと言われているため、ノイズな信号に対して MASC を用いて睡眠ステージを判定を行うことはできない。また、これらノイズな信号は計測される生体信号の 90 % 以上を占めることから、これらの信号を精度よく推定できないことは、手法の実用性を大きく損ねている。なお、これら信号がクリアであるかの判定は、マウス睡眠を専門とする技師が行なっている。

5.2 深層学習によるノイズ除去手法

これまで、深層学習を用いて音響ノイズの除去する手法が盛んに開発、提案されている。例えば、Yong Xu らは、ディープニューラルネットワークを用い、ノイズな音声とその音声部分の関係を学習、前者を後者に変換する手法 [3] を提案し、車や拍手の音等の様々なノイズに対応可能であることを示した。また Michelsanti らは、pix2pix という SimGAN とは異なる GANs アーキテクチャを用いたノイズ除去手法を提案 [4] し、高いノイズ除去性能を有していることを示した。この pix2pix は、ディスクリミネータにジェネレータの入力と出力の両方を入力することで、出力信号の出来と入出力の対応関係を同時に学習可能にしたものであり、GANs に信号の変換を学習させる場合に用いる典型的なアーキテクチャの一つである。先にも述べたように、これらの手法は様々な種類のノイズを学習・除去することができるが、変換前後の信号のペアを学習時に必要とするため、これらのペアを用意できない生体信号には適用でき

ない手法である。

5.3 その他の信号変換用 GANs

SimGAN や pix2pix の他にも、信号変換に適した GANs が提案されている。例えば、CycleGAN [7] や DiscoGAN [8] は、信号の変換とその逆変換を学習する二つの GANs を組み合わせることで、入出力の直接的なペアを用いることなく、入出力の対応関係を維持した変換を獲得できるモデルである。入力された女性の写真の髪の色だけ変更するという、複雑な変換を比較的容易に獲得できる。しかし、本研究では、信号部分に対して複数のノイズな信号が考えられることから、ノイズ除去の逆変換を設定することが困難であるため、これらの GANs ではなく SimGAN を採用した。

6 結論

本研究では、マウス生体信号ノイズ除去用の深層学習モデルの開発・提案を行った。本モデルは SimGAN の構造をノイズ除去に適するように変更したもので、生体信号において作成が困難なノイズ信号とその信号部分のペアや、ノイズに関する事前知識を必要としない実用性の高い手法である。性能評価の実験では、体動や電源に起因するノイズ、これらの混合ノイズを半分以上除去可能であることが示された。ノイズの性質についての事前知識を用いて最適化した周波数フィルタと比較してもほぼ同等の性能であった。また、ノイズを含まない周波数成分については周波数フィルタよりも変化量が少ないことから、本手法によって生体信号のノイズ除去を実現できたといえよう。

一方、今回の研究で残された課題も多い。評価実験では、体動や電源ノイズのような狭い周波数成分しか持たないノイズだけでなく、周波数帯全域に乗るホワイトノイズ等についての検証が必要だと考えられる。また、ジェネレータやディスクリミネータの構造についても、修正の余地があると考えられる。例えば本手法では、ジェネレータは生体信号の生成のみを行うが、ノイズ部分も直接学習・生成するようなアーキテクチャを採用

すると、ノイズの特徴をより直接的に利用することができ、より高精度なノイズ除去を実現できる可能性がある。本手法が睡眠研究の効率の改善につながることに期待する。

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. IEEE, 2017.
- [3] Yong Xu, Jun Du, Li-Rong Dai, and Chin-Hui Lee. A regression approach to speech enhancement based on deep neural networks. *IEEE/ACM Transactions on Audio, Speech and Language Processing (TASLP)*, Vol. 23, No. 1, pp. 7–19, 2015.
- [4] Daniel Michelsanti and Zheng-Hua Tan. Conditional generative adversarial networks for speech enhancement and noise-robust speaker verification. *arXiv preprint arXiv:1709.01703*, 2017.
- [5] Ashish Shrivastava, Tomas Pfister, Oncel Tuzel, Josh Susskind, Wenda Wang, and Russ Webb. Learning from simulated and unsupervised images through adversarial training. In *The IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Vol. 3, p. 6, 2017.
- [6] Ian Goodfellow, Jean Pouget-Abadie, Mehdi Mirza, Bing Xu, David Warde-Farley, Sherjil Ozair, Aaron Courville, and Yoshua Bengio. Generative adversarial nets. In *Advances in neural information processing systems*, pp. 2672–2680, 2014.
- [7] Jun-Yan Zhu, Taesung Park, Phillip Isola, and Alexei A Efros. Unpaired image-to-image translation using cycle-consistent adversarial networks. *arXiv preprint arXiv:1703.10593*, 2017.
- [8] Taeksoo Kim, Moon-su Cha, Hyunsoo Kim, Jungkwon Lee, and Jiwon Kim. Learning to discover cross-domain relations with generative adversarial networks. *arXiv preprint arXiv:1703.05192*, 2017.