

# ランダムフォレストによる マウス脳波時系列を用いた睡眠ステージ判定

松崎 舜<sup>1</sup> 坂口 昌徳<sup>2</sup> 大西 立顕<sup>1</sup>

**概要:** マウスの睡眠ステージ (ノンレム, レム, 覚醒) を全自動で判定することは, 記憶研究の効率化において重要である. 主な判定手法としては FASTER が知られているが, 脳波 (EEG) のデータ以外にノイズの多い筋電 (EMG) のデータを必要とすることやリアルタイムでの判定が出来ないことなどの問題があるため, 現在も人間の手で判定が行われている. そこで本研究ではランダムフォレストと時系列補正を用いた睡眠ステージ判定手法を提案する. 本手法は時系列補正によるタイムラグがあるもののほぼリアルタイムでの判定が可能であり, FASTER より精度の高い判定手法となっている. また睡眠ステージ判定に際して重要な特徴量が何であるかについても考察する.

SHUN MATSUZAKI<sup>1</sup> SAKAGUCHI MASANORI<sup>2</sup> TAKAAKI OHNISHI<sup>1</sup>

## 1. はじめに

睡眠ステージを区別することは臨床や睡眠研究において避けられないステップである. 現在は熟練の判定者による目視で睡眠ステージ判定を行っているが, 大量のデータを処理するには人件費や時間のコストがかかるため睡眠研究の大規模化のボトルネックとなっている. この問題を解決するために人間においては k 近傍法 [12] やランダムフォレスト [10], ニューラルネットワーク [4] を用いた睡眠ステージ判定手法が開発されてきた. これらの手法では特徴量として脳波や筋電のパワースペクトルを用いている. 一方, マウスの睡眠ステージを判定する研究は少ないが, 生物学の研究においてマウスはよく用いられるため重要である.

マウスにおいても睡眠ステージと脳波のパワースペクトルは強い関係がある. 図 1 は脳波の睡眠ステージ毎のパワースペクトルを示したものであるが, ノンレム睡眠は 3Hz 付近のデルタ波の, レム睡眠は 8Hz 付近のシータ波のパワースペクトルが大きい. この性質を用いて砂川らが提案した FASTER [7] はマウスの全自動睡眠ステージ判定手法であり, 24 時間分の睡眠ステージを 10 分程度で判定出来るようにした.

しかし FASTER には, ノイズを含むデータに対しては

精度が大きく下がりレム睡眠の判定が難しくなること, リアルタイムで判定するのは厳しいこと等の問題がある. 特に前者の原因としては, ノイズが乗りやすい筋電のデータを判定に使用していることや睡眠ステージ推移の時系列特性を考慮していないことが考えられる.

そこで本研究では, 脳波のデータのみを用いて時系列情報も考慮した睡眠ステージ判定手法を提案する. 本手法はランダムフォレストを用いて判定した睡眠ステージの時系列特性から修正するものとなっており, FASTER の問題点を解決している. 時系列補正についても 1 エポック分の遅れで判定が可能となっており, FASTER よりも研究で扱いやすい半リアルタイムの判定手法である. またどの特徴量が睡眠ステージの違いをよく切り出しているかについても考察が可能となっており, 脳波のパワースペクトルに代わる新たな特徴量を見つけ, さらなる手法の改良も可能であると考えられる.

本稿の構成は以下のとおりである. 2 章で先行研究の FASTER について述べ, 3 章で提案手法の説明を行う. 4 章で提案手法の評価実験と考察を行い, 5 章でまとめる.

## 2. FASTER 手法

FASTER の睡眠ステージ分類手法は (1) 特徴抽出ステップ, (2) クラスタリングステップ, (3) アノテーションステップから構成されている.

<sup>1</sup> 東京大学  
The University of Tokyo  
<sup>2</sup> 筑波大学  
University of Tsukuba

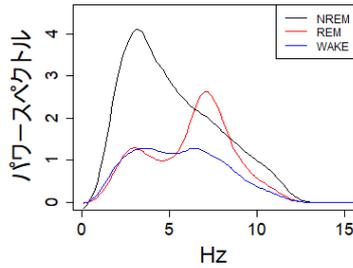


図 1 脳波の睡眠ステージ毎のパワースペクトル

## 2.1 特徴抽出ステップ

特徴抽出ステップではまず、脳波と筋電のデータをエポック単位に分解する。その後各エポックの脳波と筋電のデータをFFT(高速フーリエ変換)によって周波数領域に変換する。最後に変換した脳波と筋電の特徴を主成分分析によって抽出する。実験的に第4主成分まで抽出するのが良いことが確認されている [7]。

## 2.2 クラスタリングステップ

クラスタリングステップではノンパラメトリック密度推定クラスタリング [1] を用いている。具体的には、特徴抽出ステップで抽出した4つの主成分を特徴ベクトルとした座標軸上において、ガウシアンカーネル関数による確率密度推定を用いたクラスタリングを行う。

## 2.3 アノテーションステップ

アノテーションステップではまず各クラスタに属するエポックのEMGパワーとEEGデルタパワーそれぞれの中央値を計算し、それをクラスタのEMGパワーとEEGデルタパワーとする。なおEEGデルタパワーとはEEGのデルタ波の成分の総和である。各クラスタのEMGパワーとEEGデルタパワーを計算した後、閾値  $P_{EMG}$  よりEMGパワーが大きいクラスタを全て覚醒状態に分類し、残りのクラスタで閾値  $P_{delta}$  よりEEGデルタパワーが大きいクラスタを全てノンレム睡眠に分類する。そして、それ以外のクラスタを全てレム睡眠に分類する。

## 2.4 FASTERの問題点

FASTERには複数の改善点がある。1つめは時系列情報を用いていないことである。特にREM睡眠は覚醒状態からは移行しないという性質を反映できていない手法となっている。2つめは多くの良質なデータを学習に要することである。マウスのデータはノイズが混ざっていることも多く、ノイズありマウスの場合レム睡眠の感度が大きく下がることがある。3つめはクラスタリングの際のドロネー三角形分割に時間がかかるため、特徴量数は4つが限界であることである。最後は筋電データと脳波のデータの両方が

必要であるため、実用上手間がかかるということである。

## 3. ランダムフォレストを用いた睡眠ステージ判定手法

ランダムフォレストを用いた睡眠ステージ判定手法は、(1)特徴量抽出、(2)ランダムフォレスト、(3)時系列補正の3ステップから構成されている。本手法で用いるデータは、マウスのEEGの睡眠ステージラベル付き1次元時系列データであり、EMGは用いない。ラベルはレム、ノンレム、覚醒の3状態である。

### 3.1 特徴量抽出

各エポックの脳波時系列(EEG)を  $x_1 x_2 \dots x_n$  とおく。なお脳波時系列はノイズを除去するために、1Hz-12Hzのフィルタをかけたものを用いている。それにハニング窓をかけてフーリエ変換したパワースペクトル列を  $p_1 p_2 \dots p_{n/2}$  とする。本研究で用いた脳波時系列のサンプリング周波数は128Hzである。1エポックは10秒であるため以降  $n = 1280$  とする。そして、 $p_k$  は  $k/10$ Hzのパワースペクトルを表す。以下に用いた特徴量を列挙する。

#### 1Hzから12Hzのパワースペクトル

1Hzから12Hzのパワースペクトル ( $P_1 \dots P_{11}$ ) を以下のように定義する。

$$P_k = \sum_{i=0}^9 p_{10k+i}$$

#### 1Hzから12Hzのパワースペクトル割合

1Hzから12Hzのパワースペクトル割合 ( $R_1 \dots R_{11}$ ) を以下のように定義する。

$$R_k = \frac{P_k}{\sum_{i=1}^{11} P_i}$$

#### パワースペクトルの積分値と標準偏差

パワースペクトルの積分値(IN)と標準偏差(SDP)を以下のように定義する。

$$IN = \sum_{i=1}^{11} P_i$$

$$SDP = \sqrt{\frac{1}{110} \sum_{i=10}^{119} (p_i - \bar{p})^2}, \quad \bar{p} = \frac{1}{110} \sum_{i=10}^{119} p_i$$

#### EEGの最大値、最小値、標準偏差

EEGの最大値(MAX)、最小値(MIN)、標準偏差(SD)を以下のように定義する。

$$\begin{aligned} MAX &= \max x_t, \quad MIN = \min x_t, \\ SD &= \sqrt{\frac{1}{n-1} \sum_{t=1}^n n(x_t - \bar{x})^2}, \quad \bar{x} = \frac{1}{n} \sum_{t=1}^n x_t. \end{aligned}$$

#### EEGのHjorth Parameters

$x_t$  の一階差分、二階差分数列を  $x'_t, x''_t$  とする。 $\sigma_x, \sigma_{x'}, \sigma_{x''}$  をそれぞれ  $x_t, x'_t, x''_t$  の標準偏差とすると、Hjorth Parameters(HA, HM, HC) は

$$HA = \sigma_x^2, \quad HM = \frac{\sigma_{x'}}{\sigma_x}, \quad HC = \frac{\sigma_x \sigma_{x''}}{\sigma_{x'}^2}$$

と定義される [5].

### Petrosian Fractal Dimension

Petrosian Fractal Dimension(PFD) は以下のように定義される.

$$PFD = \frac{\log_{10} N}{\log_{10} N + \log_{10}(N/(N + 0.4M))}.$$

なお,  $N$  はサンプル数 (1280) であり,  $M$  は EEG の正負が入れ替わる回数である [2].

### 平均周波数

平均周波数 (MP) を以下のように定義する.

$$MP = \sum_{i=10}^{119} \frac{i \cdot p_i}{10}.$$

### Normalized Line Length

Normalized Line Length (NLL) は

$$NLL = \sum_{t=1}^{n-1} |x_{t+1} - x_t|$$

のように定義される [10].

### Power Spectral normalized line length (PNLL)

Power Spectral normalized line length (PNLL) を

$$PNLL = \sum_{i=10}^{119} |p_{i+1} - p_i|$$

のように定義する.

### Log root sum of sequential variations

Log root sum of sequential variations (LRSSV) は

$$LRSSV = \log_{10} \sqrt{\sum_{t=1}^{n-1} (x_{t+1} - x_t)^2}$$

のように定義される [10].

### Normalized Spectral Entropy

Normalized Spectral Entropy (NSE) は

$$s_k = \frac{p_k}{\sum_{i=10}^{119} p_i}, \quad NSE = -\frac{1}{\log_2 110} \sum_{i=10}^{119} s_i \log_2 s_i$$

のように定義される [13].

### Generalized Hurst Exponent

Generalized Hurst Exponent (GHE) は

$$\frac{\langle |x_{t+d} - x_t|^m \rangle}{\langle |x_t|^m \rangle} \propto d^{m \cdot GHE}$$

のように定義される.  $m$  は自然数であり, GHE は上の比例式を満たすように定められる [11].

### ヒルベルト変換に基づく特徴量

$z_t, A_t, \phi_t$  を

$$z_t = x_t + iH(x_t), \quad z_t = A_t e^{i\phi_t}$$

と定義する ( $H$  はヒルベルト変換). このとき特徴量 AM, ASD, PM, PSD を

$$AM = \bar{A}, \quad PM = \bar{\phi}, \quad ASD = \sigma_A, \quad PSD = \sigma_\phi$$

と定義する [10].

### レニエントロピー

レニエントロピー (RE) はパラメータ  $\alpha$  を用いて

$$RE(\alpha) = \frac{1}{1-\alpha} \log \left( \sum_x (Pr(x))^\alpha \right)$$

と定義される.  $Pr(x)$  は  $x_1 \cdots x_n$  から推定される確率分布である [3].

### 自己相関

EEG の平均  $\mu$  と標準偏差  $\sigma$  は

$$\mu = \frac{1}{n} \sum_{t=1}^n x_t, \quad \sigma = \frac{1}{n} \sum_{t=1}^n (x_t - \mu)^2$$

と計算される. これらを用いて自己相関 ( $AR_1 \cdots AR_{31}$ ) は,

$$AR_k = \frac{\frac{1}{n-k} \sum_{i=1}^{n-k} (x_i - \mu)(x_{i+k} - \mu)}{\sigma^2},$$

と計算される. マウスの脳波における睡眠ステージと自己相関の関係を表したのが図 2 であり, 睡眠ステージによって大きく異なることが読み取れる.

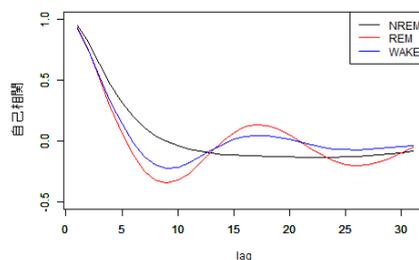


図 2 睡眠ステージと自己相関の関係

### 3.2 ランダムフォレスト

決定木とは機械学習の分類に用いられる手法の一つで, 説明変数を用いてデータを木のように分割し, 各クラスに分類するものである. どの変数が重要ななどの解釈が容易であり, 数値やカテゴリーデータが混在していても問題がないという良い性質を持っている. なお, どの変数を用いて分類を行うべきかを判断するための基準として情報利得という指標があり, 分割前の不純度から分割後の不純度を引いた値となっている. これが大きくなる説明変数と境界を選んでデータの分割を行う.

ランダムフォレストは決定木分析の集団学習のことである [9]. 概要を図 3 に示す. まず学習用データである各エポック毎の特徴量ベクトルから, 適当な個数のエポックをサンプリングで取り出す. さらにどの特徴量を用いて決定木を作成するかもサンプリングする. 次に選ばれたエポックと特徴量に対して決定木を作成する. この操作を繰り返すことで多くの決定木が作成され, これを決定森と呼ぶ. テストデータを決定森に入れると, 各決定木毎に判定された睡眠ステージが得られ, その多数決で睡眠ステージの分類結果が返ってくる.

睡眠ステージはノンレム睡眠と覚醒状態に比べてレム睡眠状態が極端に少ない不均衡なデータである. このような

とき、決定木やランダムフォレストを用いても感度が低くなり、本当はレム睡眠状態にあっても判定することが難しい。このとき、カットオフ値を設定することで、感度と適合度のトレードオフを決めることが出来る。ある葉ノードにおけるレム睡眠、ノンレム睡眠、覚醒状態の確率を  $(p_R, p_N, p_W)$  とする。ここで、カットオフを  $(c_R, c_N, c_W)$  とすると、その葉ノードは

$$\left( \frac{p_R}{c_R}, \frac{p_N}{c_N}, \frac{p_W}{c_W} \right)$$

の最大となるクラスに割り当てられる。

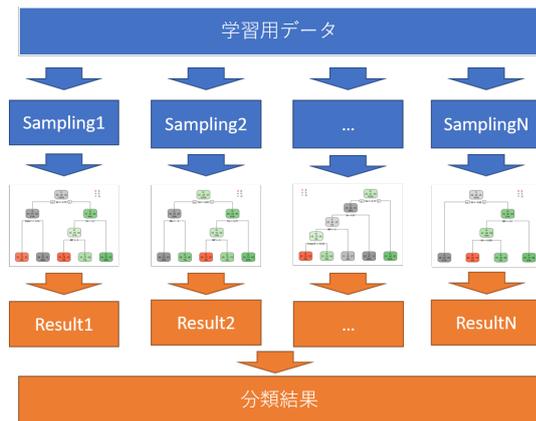


図 3 ランダムフォレスト

### 3.3 時系列補正

学習データとして人に睡眠ステージがラベル付けされたデータを用意する。遷移前の睡眠ステージを a, 遷移後の睡眠ステージを b としたとき、睡眠ステージ間の遷移確率  $p_{ab}$  をデータから最尤法で求める。

表 1 はエポックの時間を 10 秒にした場合の各睡眠状態間の遷移確率を表している。表 1 より、遷移前状態と遷移後状態は同じである確率がノンレム睡眠と覚醒では約 95% になり、レム睡眠においても約 85% になっている。また、覚醒からレム睡眠に直接遷移することはない。よって以下のステップでランダムフォレストによって判別された睡眠ステージを修正する。

- (1) テスト時系列の最初のエポックをレム睡眠と判別していた場合、睡眠状態をノンレム睡眠に修正する。
- (2) 1つ前と1つ後の判定が同じときは、間の判定状態を1つ前の判定に揃える。(大雑把ルール)
- (3) 覚醒からレム睡眠に遷移すると判定される場合、レム睡眠の判定を覚醒に修正する。(レムルール)

このルールを用いると例えば以下のように判定が修正される。S はノンレム睡眠, R はレム睡眠, W は覚醒を表す。

- (1) SSWWRRSRWWSSSSRR
- (2) SSWWRRRRRWWSSSSRR (大雑把ルール)
- (3) SSWWWWWWWWWSSSSRR (レムルール)

このうち、最初の状態の判定結果、大雑把ルールのみを適用したときの判定結果、レムルールまで適用したときの

判定結果をそれぞれ 1,2,3 とする。

表 1 遷移確率

遷移確率 $p_{ab}(\%)$		遷移後状態		
		REM 睡眠	NREM 睡眠	覚醒
遷移前状態	REM 睡眠	84.2	4.1	11.7
	NREM 睡眠	2.3	94.2	3.5
	覚醒	0	4.2	95.8

### 3.4 判定結果の評価手法

判定指標としては色々なものが考えられる。例えば睡眠ステージの判定結果と真のラベルが一致している割合である Accuracy などが考えられ、数多くの論文で用いられている。しかし、睡眠ステージはレム睡眠状態が少ない不均衡データであること、記憶実験にはレム睡眠を多く使用していることなどが Accuracy は指標として不適当と考えられる。そこで今回は以下の 2 種類の評価指標を採用することにした。なお判別結果は表 2 のように定義する。また、

$$C_{k.} = \sum_l C_{kl} \quad C_{.k} = \sum_l C_{lk} \quad C_{..} = \sum_k \sum_l C_{kl}$$

と定義する。

なお、

$$\text{Accuracy} = \frac{C_{RR} + C_{NN} + C_{WW}}{C_{..}}$$

であるが、クラスが偏っている場合には全てを多数派のクラスに予測することで高くなるという問題がある。

1 つめの評価指標として、レム睡眠の判別精度を見るために感度 (sensitivity) と適合度 (precision) のトレードオフを考慮した指標である F 値を採用した。以下の 3 式で定義される Fscore が F 値である。

$$\text{sensitivity} = \frac{C_{RR}}{C_{RR} + C_{NR} + C_{WR}} = \frac{C_{RR}}{C_{.R}} = \text{SE.}$$

$$\text{precision} = \frac{C_{RR}}{C_{RR} + C_{RN} + C_{RW}} = \frac{C_{RR}}{C_{R.}}$$

$$\text{Fscore} = \frac{2}{\frac{1}{\text{PR}} + \frac{1}{\text{SE}}}$$

2 つめの評価指標として MCC を採用した。それは以下の式で定義され、不均衡データに対する Accuracy に当たるものである [8]。

$$\text{MCC} = \frac{\sum_k C_{kk} C_{..} - C_{k.} C_{.k}}{\sqrt{\sum_k C_{k.} (C_{..} - C_{k.})} \sqrt{\sum_k C_{.k} (C_{..} - C_{.k})}}$$

表 2 判別性能

判別性能		真のラベル		
		REM 睡眠	NREM 睡眠	覚醒
予測ラベル	REM 睡眠	$C_{RR}$	$C_{RN}$	$C_{RW}$
	NREM 睡眠	$C_{NR}$	$C_{NN}$	$C_{NW}$
	覚醒	$C_{WR}$	$C_{WN}$	$C_{WW}$

## 4. 実験

### 4.1 実験手法

本節では提案手法の性能評価のための実験を行う。本実験では提案手法と FASTER, SVM の判定精度を前節で説明した評価指標を用いて比較する。

本実験で用いるマウスのデータは人の手でエポック毎に

睡眠ステージがラベル付けされた8匹分の脳波および筋電のデータである。なお筋電のデータは提案手法では用いないが対抗手法のFASTERとSVMで用いられるものである。マウスの脳波及び筋電のデータはサンプリング周波数は128Hz、エポックサイズは10秒である。脳波および筋電のエポック数は全てのマウスにおいて6時間分の2160エポックであり8匹のマウス合計で17280エポックである。また、脳に刺した電極の位置によってEEGの大きさが異なるため、各脳波と筋電のデータは平均と標準偏差を用いて標準化されたものを用いる。

本研究では交差検証を用いて実験を行う。各マウスについて残りの7匹のマウスでランダムフォレストの学習を行いテストし、F値とMCCの計算を行う。最終的なF値やMCCは各マウスのテストの平均とする。カットオフを $(c_R, c_N, c_W) = (v, 1, 1)$ として設定し、 $v = 1, 0.5, 0.2, 0.1, 0.05$ の5パターンで検証した。 $v$ の値を0.01ずつ変化させたときのF値やMCCの値を計算し、時系列補正によってどのように変化するのかも確認する。またランダムフォレストにおいてどの変数が有効であるかをImportanceを見ることにより確認する。さらに、パワースペクトルの値と自己相関の値のどちらがより判定精度を上げることが可能であるかを検証するため、提案手法のランダムフォレストに入れる変数の組み合わせをそれぞれ有り無し計4パターンで同じ実験を行う。

提案手法の対抗手法としてはFASTERとSVMを採用した。SVMは脳波と筋電のデータをFFTを用いて周波数領域に変換した後主成分分析を行い、脳波16主成分と筋電4主成分計20主成分でSVMを行っている。また、FASTERとSVMの両方に今回ランダムフォレスト後に用いた時系列補正を行ったものも対抗手法とし、提案手法の時系列補正が他の手法でも有効かどうかの確認を行う。

#### 4.2 実験結果と考察

表3と表4はそれぞれ、 $v$ を変化させたときのランダムフォレストに入れる変数の組み合わせによるF値とMCCを表したものである。ランダムフォレストに入れる変数は、arpowerは自己相関ありパワースペクトルありの場合、arは自己相関のみあり、powerはパワースペクトルのみあり、noは共に変数に入れない場合である。また、 $v = Fm$ は $v$ を0.01ずつ動かしたとき各マウスで最もF値が良かった時を平均したものであり、 $v = mm$ は最もMCCが良かった時を平均したものである。これらは共に理想的に $v$ の最適値を取得できた場合に精度がどうなるかということを示したものである。表3と表4を横軸で見ると $v = 0.2$ と $v = 0.1$ のときにF値とMCCが高い値を示していることが分かる。これは、ランダムフォレストの段階でREM睡眠と甘めに判定することが、その後時系列補正で修正することにより精度が高くなることを示唆している。また縦軸

で見ると、arpowerとar、powerとnoで判定精度が大きく変わらず、arの方がpowerよりF値とMCC共に良いことが分かる。原因としてはパワースペクトルを1Hz毎に区切って今回は判断したが、うまく特徴量をとらえきれなかったことが考えられる。一方自己相関は簡便な処理で睡眠ステージの違いを表現できることが示唆される。

表5は対抗手法と提案手法の精度を比較したものである。提案手法は対抗手法に比べてF値とMCC共に高くなっており、精度の高い手法といえる。FASTERにおいてF値が非常に低くなっているが、レム睡眠が他の2つの睡眠ステージに比べてエポック数が少ないため、ノンパラメトリック密度推定クラスタリングによってうまくレム睡眠のクラスタリングがなされていないことが原因である。本実験では、ノイズが少ないマウスを選択しているわけではないため、ノイズが混ざると既存手法がうまくいかないことがあると思われる。また既存手法においても時系列補正を加えることで判定精度が大幅に改善した。これはこの時系列補正が手法によらず組み合わせて用いると有効であることを示している。

表6はランダムフォレストにおけるImportanceが大きいものから30個並べたものである。ASD,SD,HA,AM等脳波時系列の振幅が大きいほど大きくなる変数でImportanceが大きくなっており、これはノンレム睡眠とそれ以外の睡眠ステージを分離するのに重要な変数であると考えられる。LRSSV,NLLという脳波時系列の1つ前との差の大きさに依存する特徴量も重要であることが読み取れる。また、パワースペクトルに関わる変数よりも自己相関の変数の方がImportanceが高くなっており、自己相関が睡眠ステージを考える上で良い切り口の特徴量であることが考えられる。実際Importanceが特に大きいAR8とAR9とAR17に注目して図2を参照すると、各睡眠ステージの自己相関の値が特に大きく異なる点であることが読み取れる。

図4と図5は $v$ を0.01ずつ動かしたときの時系列補正の効き方について代表的なマウス2匹のグラフである。グラフの凡例の1は時系列補正をかける前、凡例の2は大雑把ルールのみを適用した場合、凡例の3はレムルールまで適用した場合である。8匹のマウスについて時系列補正の効き方は2パターンが観察された。1つめのパターンは $v = 0.2$ 付近で凡例3におけるF値やMCCのピークが存在し、 $v = 0.2$ を超えると急激に凡例3の精度が低下して凡例2や1を下回る。2つめのパターンは常に凡例3が凡例2の判定精度を上回り、レムルールの効果が非常に大きい。どちらのパターンでも大雑把ルールのみを適用させた段階では時系列補正をかけない場合よりもF値,MCCともに上回っている。2つのパターンで判定精度が最良となる $v$ の値が大きく異なるため、 $v$ の最適値を定めることは難しいが、2つめのパターンでは $v$ の値によって判定精度が大きくは異ならないので $v$ を小さめに選ぶことで平均的な

判定精度を向上させることが出来ると考えられる。なお、残りのマウス 6 匹のうち 4 匹が 1 つめのパターンを示し、残りは 2 つめのパターンを示している。

表 3 判定結果 (F 値)

F 値	arpower	ar	power	no
$v = 1$	$0.595 \pm 0.220$	$0.598 \pm 0.225$	$0.484 \pm 0.246$	$0.488 \pm 0.228$
$v = 0.5$	$0.711 \pm 0.146$	$0.739 \pm 0.123$	$0.634 \pm 0.206$	$0.638 \pm 0.202$
$v = 0.2$	$0.810 \pm 0.072$	$0.809 \pm 0.066$	$0.764 \pm 0.069$	$0.747 \pm 0.083$
$v = 0.1$	$0.825 \pm 0.095$	$0.823 \pm 0.096$	$0.786 \pm 0.109$	$0.788 \pm 0.094$
$v = 0.05$	$0.801 \pm 0.113$	$0.797 \pm 0.121$	$0.765 \pm 0.129$	$0.773 \pm 0.111$
$v = Fm$	$0.877 \pm 0.058$	$0.879 \pm 0.056$	$0.862 \pm 0.067$	$0.858 \pm 0.069$
$v = mm$	$0.872 \pm 0.061$	$0.880 \pm 0.055$	$0.859 \pm 0.068$	$0.850 \pm 0.076$

表 4 判定結果 (MCC)

F 値	arpower	ar	power	no
$v = 1$	$0.845 \pm 0.052$	$0.848 \pm 0.052$	$0.824 \pm 0.053$	$0.825 \pm 0.056$
$v = 0.5$	$0.858 \pm 0.049$	$0.865 \pm 0.050$	$0.840 \pm 0.056$	$0.842 \pm 0.053$
$v = 0.2$	$0.873 \pm 0.054$	$0.874 \pm 0.055$	$0.854 \pm 0.057$	$0.852 \pm 0.055$
$v = 0.1$	$0.872 \pm 0.063$	$0.876 \pm 0.061$	$0.853 \pm 0.071$	$0.856 \pm 0.065$
$v = 0.05$	$0.861 \pm 0.072$	$0.864 \pm 0.072$	$0.845 \pm 0.076$	$0.848 \pm 0.072$
$v = Fm$	$0.888 \pm 0.054$	$0.893 \pm 0.053$	$0.876 \pm 0.057$	$0.873 \pm 0.058$
$v = mm$	$0.889 \pm 0.053$	$0.893 \pm 0.053$	$0.876 \pm 0.057$	$0.876 \pm 0.056$

表 5 対抗手法

	F 値	MCC
RF( $v = 0.2$ , 自己相関のみ)	$0.809 \pm 0.066$	$0.874 \pm 0.055$
SVM(時系列補正あり)	$0.726 \pm 0.092$	$0.833 \pm 0.057$
FASTER(時系列補正あり)	$0.400 \pm 0.265$	$0.718 \pm 0.154$
SVM(時系列補正なし)	$0.505 \pm 0.088$	$0.717 \pm 0.080$
FASTER(時系列補正なし)	$0.295 \pm 0.232$	$0.659 \pm 0.117$

表 6 重要な説明変数

	ASD	620	HC	285	SDP	140
	SD	604	AR9	268	AR4	124
	HA	586	AR17	267	AR19	113
	AM	522	AR7	249	P3	109
	LRSSV	481	MAX	182	P2	93
	NLL	473	AR6	173	AR3	91
	PNLL	343	AR18	170	AR27	88
	IN	342	AR16	169	P4	85
	MIN	336	AR10	168	AR11	83
	AR8	320	AR5	151	P7	81

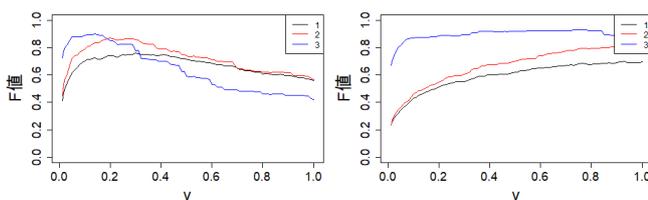


図 4 カットオフによる F 値の変化

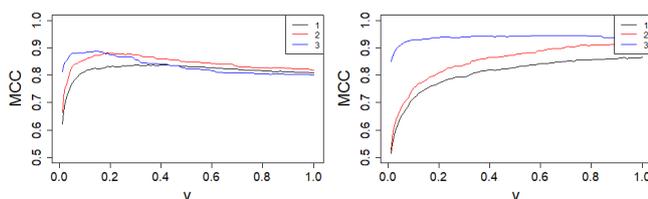


図 5 カットオフによる MCC の変化

## 5. まとめ

本研究では睡眠ステージ遷移の特徴を反映する時系列補正を用いた、ランダムフォレストによるマウスの睡眠ス

テージ判定手法を提案し、既存手法である FASTER を上回る判定精度を出した。提案手法は特に睡眠研究において重要であるレム睡眠の判定精度を大幅に向上し、時系列補正による 1 エポック分の遅れはあるものの半リアルタイムで睡眠ステージを判定可能である。また、FASTER や SVM で一度睡眠ステージ判定を行った後、判定された睡眠ステージに対して本研究で用いた時系列補正を行うことにより判定精度が向上することを確認し、時系列補正の有効性を示した。さらに、睡眠ステージの特徴量として自己相関が有用であり、説明変数に用いることで精度の向上が起きることを確認した。

## 参考文献

- [1] A. Azzalini, N. Torelli: Clustering via nonparametric density estimation. *Stat Comput*, vol. 17 (2007), pp. 71-80.
- [2] A. Petrosian: Kolmogorov Complexity of Finite Sequences and Recognition of Different Preictal EEG Patterns. *8th IEEE Symposium on computer-Based Medical Systems*, 1995, pp. 212-217.
- [3] A. Renyi: On Measures of Entropy and Information. *4th Berkeley Symposium*, 1961, pp. 547-561.
- [4] A. Supratak, H. Dong, C. Wu, Y. Guo: DeepSleepNet: A Model for Automatic Sleep Stage Scoring Based on Raw Single-Channel EEG. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 25 (2017), pp. 1998-2008.
- [5] B. Hjorth: EEG Analysis Based on Time Domain Properties. *Electroencephalography and Clinical Neurophysiology*, vol. 29 (1970), pp. 306-310.
- [6] B. W. Matthews: Comparison of the Predicted and Observed Secondary Structure of T4 Phage Lysozyme. *Biochimica et Biophysica Acta*, vol. 405 (1975), pp. 442-451.
- [7] G. A. Sunagawa, H. Sei, S. Shimba, Y. Urade, H. R. Ueda: Faster: an unsupervised fully automated sleep staging method for mice. *Genes to Cells*, vol. 18 (2013), pp. 502-518.
- [8] J. Gorodkin: Comparing Two K-category assignments by a K-category Correlation Coefficient. *Computational Biology and Chemistry*, vol. 28 (2004), pp. 367-374.
- [9] L. Breiman: Random Forest. *Machine Learning*, vol. 45 (2001), pp. 5-32.
- [10] P. Memar, F. Faradji: A Novel Multi-Class EEG-Based Sleep Stage Classification System. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 26 (2018), pp. 84-95.
- [11] R. Acharya, O. Faust, N. Kannathal, T. Chua, S. Laxminarayan: Non-linear Analysis of EEG Signals at Various Sleep Stages. *Computer Methods and Programs in Biomedicine*, vol. 80 (2005), pp. 37-45.
- [12] S. Gunes, K. Polat, S. Yosunkaya: Efficient sleep stage recognition system based on EEG signal using k-means clustering based feature weighting. *Expert Systems with Applications*, vol. 37 (2010), pp. 7922-7928.
- [13] T. Inouye, K. Shinosaki, H. Sakamoto, S. Toi, S. Ukai, A. Iyama, Y. Katsuda, M. Hirano: Quantification of EEG Irregularity by use of the Entropy of the Power Spectrum. *Electroencephalography and Clinical Neurophysiology*, vol. 79 (1991), pp. 204-210.