

# リーマン幾何学に基づく特徴抽出を用いた 脳波と近赤外分光法によるハイブリッドBCI

平山 義樹<sup>†</sup> 佐久間 拓人<sup>†</sup> 加藤 昇平<sup>†</sup>

<sup>†</sup>名古屋工業大学工学部情報工学科

## 1 はじめに

運動想起や外部刺激に由来する脳活動を読み取り、コンピュータの操作信号に活用する技術として Brain-Computer Interface (BCI) がある。BCI により外部機器を直接制御することで、他者との意思伝達が実現できるため、BCI は重度の運動機能障害者のリハビリテーション等への応用が期待されている。近年では、精度や操作コマンド数において優位であることから、複数のモダリティを組み合わせた BCI が報告されており、Shin ら [1] は脳波 (EEG) と近赤外分光法 (NIRS) に基づいたハイブリッド BCI を提案した。Shin らの手法の判別性能は EEG-BCI に比べ 8.6% 向上した。しかしながら、生体信号にはノイズに脆弱かつ非定常といった問題がある。こうした問題に対し、Fang ら [2] はリーマン幾何学に基づいた EEG-BCI の有効性を報告している。そこで本研究では、リーマン幾何学の持つ空間表現能力に着目し、共分散行列からの特徴抽出手法を適用した EEG と NIRS によるハイブリッド BCI を提案する。

## 2 方法

### 2.1 データセット

本研究では、EEG と NIRS によるハイブリッド BCI のためのオープンデータセットを使用する。このデータセットには、健常者 29 名 (男性 14 名, 女性 15 名, 年齢  $28.5 \pm 3.7$  歳) を対象とした EEG 信号と NIRS 信号が含まれている。サンプリングレートはそれぞれ 1000 Hz, 12.5 Hz である。図 1 に国際 10-5 法に従った電極およびプローブの配置を示す。本データセットでは、30 個の EEG 信号用電極と 14 個の照射プローブ、16 個の受光プローブを用いて計測された。左手あるいは右手の 1 秒周期の開閉運動を 10 秒間 (計 10 回) 想起し、それら 10 回ずつの試行を 1 セッションとする全 3 セッションのデータが取得された。1 セッションのデータは、EEG 信号が 32 次元, 120436 サンプル, NIRS 信号は 72 次元, 7192 サンプルで構成されている。全試行に対して、左手の運動想起あるいは右手の運動想起の 2 値ラベルが付与されている。計測された EEG 信号, および NIRS 信号はそれぞれ 200 Hz, 10 Hz へとダウンサンプリングされた。

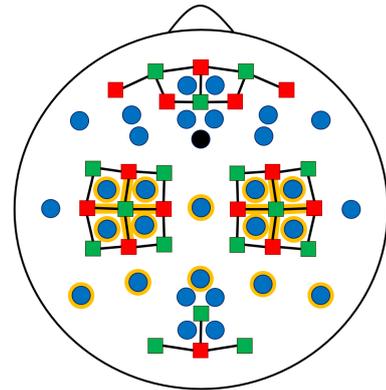


図 1: 国際 10-5 法に基づく計測電極・プローブ配置

### 2.2 前処理

EEG 信号には、まず電極全体に共通して発生するノイズの影響を取り除くために共通平均基準法と 0.5 ~ 50 Hz のバンドパスフィルタ (BPF) を適用した。その後、独立成分分析に基づき、眼球運動に伴って生じるアーチファクトを除去した。また、8 ~ 30 Hz の BPF 処理を適用し、手の運動想起に関連する  $\mu$  波と  $\beta$  波の帯域を含む周波数成分を抽出した。

NIRS 信号には、まず modified Beer-Lambert 則を適用してヘモグロビンの濃度変化を算出した。また、0.01 ~ 0.1 Hz を通過帯域とする BPF 処理によりノイズを除去した。前述の処理を実行した両信号に対し、10 秒間の運動想起タスク開始時刻の 5 秒前から 11 秒後の範囲でセグメント化処理を施した。また、ベースライン補正のために、各セグメントのタスク開始 5 秒前から 2 秒前の間の平均値を減算した。解析には運動想起に関連したチャンネル [1] を選択して使用した。

### 2.3 リーマン幾何学に基づいた特徴量抽出

本研究では、リーマン幾何学に基づき特徴量を抽出する。リーマン幾何学とはリーマン多様体に関する研究分野であり、複雑な分布をもつデータの表現や分析に有用とされている [3]。リーマン多様体は対称正定値 (SPD) 行列の集合から構成され、各点における接空間により局所的なユークリッド空間の構造を持った多様体である。図 2 に多様体と接空間の関係を示す。多様体から接空間への写像により、多様体上の非線形なデータに対し従来の数学的手法が適用可能となる。式 (1) に示す対数写像により多様体上の点である SPD 行列は接ベクトルとして表現でき、また式 (2) に示す指数写像により接空間から多様体上の点へ戻すことも可能である [3]。

### Hybrid EEG-NIRS BCI using Feature Extraction Based on Riemannian Geometry

Yoshiki HIRAYAMA<sup>†</sup>, Takuto SAKUMA<sup>†</sup>, Shohei KATO<sup>†</sup>

<sup>†</sup>Dept. of Computer Science and Engineering, Faculty of Engineering, Nagoya Institute of Technology

<sup>†</sup>Gokiso-cho, Showa-ku, Nagoya 466-8555, Japan  
{hirayama, sakuma, shohey}@katolab.nitech.ac.jp

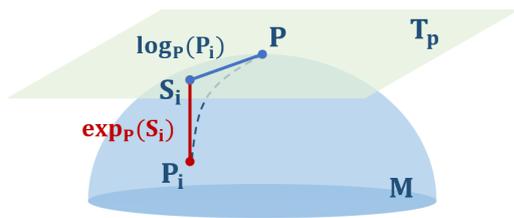


図 2: リーマン多様体と接空間

$$\log_P(P_i) = S_i = P^{\frac{1}{2}} \log(P^{-\frac{1}{2}} P_i P^{-\frac{1}{2}}) P^{\frac{1}{2}} \quad (1)$$

$$\exp_P(S_i) = P_i = P^{\frac{1}{2}} \exp(P^{-\frac{1}{2}} S_i P^{-\frac{1}{2}}) P^{\frac{1}{2}} \quad (2)$$

特徴量抽出には対数写像を利用する。多様体上で信号を扱うためにまず前処理後の EEG・NIRS 信号より共分散行列を算出する。算出された共分散行列は SPD 行列として表現できることから、求めた共分散行列の集合はリーマン多様体となる。次に SPD 行列集合の平均となるリーマン平均を反復アルゴリズムにより求め、リーマン平均における接空間へ各 SPD 行列を対数写像し、接ベクトルを算出して特徴量とする [4]。1 つのセグメントから、EEG 信号は 105 次元、NIRS 信号は 72 次元の特徴量を抽出し、それらを連結した 177 次元を特徴量として使用する。

## 2.4 判別モデルと性能評価

本研究では、RBF カーネル付き Support Vector Machine (SVM) を用いてモデルを学習し、運動想起課題の種類を判別する。ハイパーパラメータ  $C$  および  $\gamma$  は  $[10^{-2}, 10^{-1}, \dots, 10^2]$  でグリッドサーチによりチューニングする。モデルの性能評価は 6-fold Cross Validation (CV) により正解率、適合率、再現率、F 値を算出する。6-fold CV は、29 名のデータを 5 つの 5 名一組のデータと 1 つの 4 名一組のデータの 6 グループに分割して交差検証する。

## 3 結果と考察

表 1 にセグメントごとの判別における性能指標（正解率、F 値）の平均値を示す。EEG と NIRS へリーマン幾何学に基づく特徴抽出手法を用いたことにより、2 種の運動想起課題の判別においてチャンスレートを超える結果が得られたが、ここで表 1 に示したモダリティごとの平均正解率に注目する。EEG のみの特徴量とした場合が 0.643、NIRS のみの場合が 0.501 であった。この結果から、特徴量として EEG のみを使用した場合に最も高い判別性能を記録した。また NIRS のみの場合の判別性能がチャンスレート程度であり、EEG のみの場合と比べて 0.1 以上の差があることから、リーマン幾何学に基づく特徴抽出手法によって NIRS 信号から判別に寄与する特徴量が得られていないと考えられる。NIRS は EEG と比較して時間分解能が低く、脳活動後に信号へ反応が現れるまでにタイムラグが存在する。そのため今回 1 セグメントとして切り出したデータには、反応が現れる前の区間も含んでおり、リーマン幾何学に基づく手法による有効な特徴量の抽出を困難にしている可能性がある。これを改善するためには、NIRS 信号から特徴量を抽出するのに適切な区間を特

表 1: 性能評価

	本研究	EEG のみ	NIRS のみ
正解率	0.618(± 0.044)	0.643(± 0.050)	0.501(± 0.034)
適合率	0.627(± 0.065)	0.651(± 0.037)	0.501(± 0.036)
再現率	0.619(± 0.101)	0.629(± 0.201)	0.602(± 0.191)
F 値	0.616(± 0.051)	0.621(± 0.108)	0.536(± 0.074)

(上記の値は平均 (± 標準偏差) を表す)

定する必要があると考える。また解析対象とする区間を EEG と NIRS で統一していたが、それぞれの特性を考慮し、同一運動想起タスクにおける解析対象区間を EEG と NIRS で分けて設定することで、両方のモダリティからより判別に有効な特徴量を得ることができるようになると考える。

## 4 まとめと今後の展望

本研究では、リーマン幾何学に基づく特徴抽出手法を適用した EEG と NIRS によるハイブリッド BCI を提案した。今後の課題として、解析対象とする区間の変更などにより NIRS 信号から有効な特徴量を抽出する手段を模索し、提案手法におけるマルチモダリティの有効性について検証する。また本研究では、177 次元の特徴量を抽出したが、その全てが判別に有効であるかについて未検証である。そこで特徴量選択を用いて有効な特徴量を調査し、判別性能の向上を目指す。

## 謝辞

本研究は、一部、文部科学省科学研究費補助金（課題番号 JP19H01137、および、JP20H04018）、ならびに、国立研究開発法人情報通信研究機構委託研究の助成により行われた。

## 参考文献

- [1] Jaeyoung Shin, Alexander von Lühmann, Benjamin Blankertz, Do-Won Kim: Open Access Dataset for EEG+NIRS Single-Trial Classification, IEEE Transactions on Neural Systems and Rehabilitation Engineering, Vol. 25, pp. 1735-1745 (2016)
- [2] Hua Fang, Jing Jin, Ian Daly, Xingyu Wang: Feature Extraction Method Based on Filter Banks and Riemannian Tangent Space in Motor-Imagery BCI, IEEE J Biomed Health Inform, Vol. 26, No. 6, pp. 2504-2514 (2022)
- [3] Alexandre Barachant, Stéphane Bonnet, Marco Congedo, Christian Jutten: Multiclass Brain-Computer Interface Classification by Riemannian Geometry, IEEE Transactions on Biomedical Engineering, Vol. 59, No. 4, pp. 920-928 (2012)
- [4] Tingnan Qu, Jing Jin, Ren Xu, Xingyu Wang, Andrzej Cichocki: Riemannian distance based channel selection and feature extraction combining discriminative time-frequency bands and Riemannian tangent, space for MI-BCIs, Journal of Neural Engineering, Vol. 19, No. 5, pp. 1-10 (2022)