

ドライバ脳活動データに対する エネルギー地形解析の有効性の検証

日和悟*1 田中佑弥*1 磯嶋真生*2 谷岡健資*1 廣安知之*1

同志社大学生命医科学部*1

同志社大学大学院生命医科学研究科*2

ドライバーの脳活動を計測し、運転中の脳活動パターンのダイナミクスを分析することで、脳・行動・心理の相互関係を明らかにし、より人に快適な運転支援システムの改善に寄与できる。従来の脳計測では、特定の認知機能や心理状態に関連する脳領域の活動を分析していたが、運転のようなマルチタスクでは事前に関係する脳領域を特定することは容易ではない。そこで本研究では、エネルギー地形解析を用いて運転中の脳状態をデータ駆動的に抽出し、脳状態間の遷移ダイナミクスを分析してドライバーの状態変遷を可視化できるかを検証した。

Evaluating the Effectiveness of Energy Landscape Analysis in Driver Brain Activity Data

Satoru Hiwa*1 Yuya Tanaka*1 Shinsei Isojima*2 Kensuke Tanioka*1 Tomoyuki Hiroyasu*1

Department of Biomedical Sciences and Informatics, Doshisha University*1

Graduate School of Life and Medical Sciences, Doshisha University*2

Analyzing drivers' brain activity and its dynamics during driving can elucidate the relationships between the brain, behavior, and psychology. This would lead to the improvement of human-friendly driver assistance systems. Conventional neuroscience studies examine the activity of brain regions associated with specific cognitive processes or psychological states. However, identifying the relevant brain regions before the experiment in situations involving multiple complex tasks, such as driving, is challenging. To address this issue, this study employed energy landscape analysis to extract brain states in a data-driven manner during driving and analyze the transition dynamics between brain states in various driving conditions.

Keyword: energy landscape analysis; brain dynamics; ising model; functional near-infrared spectroscopy.

1. 序論

運転中のドライバの状態を把握することは、安全と快適性の向上に不可欠である。近年、非侵襲脳機能イメージングを用いてドライバの脳活動を計測し、その活動パターンから認知プロセスや心理状態を推定する方法が注目されている[1]。これらの研究は、運転中の認知負荷の把握、漫然運転や疲労の検知につながり、事故防止技術への応用が期待できる。

脳活動を計測する研究には、仮説駆動型とデータ駆動型の2つのアプローチがある。前者は、既存の知見に基づいて仮説を設定し、その検証に重きを置く。対象とする実験条件において、関係する脳領域（関心領域）を実験前に特定しておき、関心領域の脳活動と行動および心理指標の関係を分析する。この関心領域の設定には、同一の認知プロセスを扱った研究事例や探索的実験が必要である。しかし、過去に例のない実験対象においては関心領域の設定が困難であることや、既存の知見によるバイアスが生じ、新たな知見の発掘の障壁となることもある。ドライバの脳活動計測についても、計測領域が前頭部に限られた事例が多いことや、運転という複合的なタスクに関わる認知プロセスが数多く考えられることなどから、関心領域の特定は容易ではない。

このような背景から、データ駆動型研究への期待が高まっている。関心領域を限定せず、できる限り脳全体を網羅するように脳活動データを取得しておき、機械学習や統計解析を用いて、特定の条件における特徴的な活動パターンを抽出し、行動・心理指標と関係する脳領域を特定するものである。

エネルギー地形解析（energy landscape analysis: ELA）は、その方法の一つである。ELAは、多次元時系列データにおいて頻出するパターンを抽出し、イジング・モデルを用いてパターン間の遷移をエネルギー地形としてモデル化する。Ezakiら[2]は、ELAを機能的磁気共鳴画像法（functional magnetic resonance imaging: fMRI）データに適用し、脳活動データにELAを適用するフレームワークを確立した。これ以降、ELAはさまざまな脳活動データに適用され、新たな知見の獲得に貢献している[3]。

本研究では、運転中のドライバの脳活動データにおけるELAの有効性の検証を目的とする。すなわち、運転中に生じる脳活動パターンをELAによりデータ駆動的に抽出することを試みる。さらに、ELAにより得られた脳活動のダイナミクスが、ドライバの状態遷移をどのように反映するかを検証する。

2. エネルギー地形解析

2-1 活動パターンの定義と出現頻度の分析

図1は脳活動データに対して、ELAを適用する流れを示したものである。まずELAでは、各脳領域（あるいは計測点）から得られた脳活動時系列データを二値化する。つまり、ある時点のデータが閾値以上であれば+1（活性化状態）を、それ以外は-1（非活性化状態）を与える。二値化により、各時点における N 個の脳領域の活性化状態を一つの活動パターンとみなすことができる。時刻 t の活動パターン $\sigma(t)$ を

$$\sigma(t) = (\sigma_1(t), \dots, \sigma_N(t)) \in \{-1, 1\}^N \quad (1)$$

を定義すると、 N 個の脳領域で計測された脳活動データは、 2^N 通りのパターンをもつ。この 2^N 通りの活動パターンが計測データ中に何回現れるかを、データポイントの数で出現回数を割ることで出現頻度 $P(\sigma)$ として算出する。ELAでは、この出現頻度分布 $P(\sigma)$ に対してイジング・モデルを当てはめることで、各活動パターンが持つエネルギーを推定する。具体的には、 $P(\sigma)$ を用いてボルツマン分布を推定する。

$$P(\sigma|\mathbf{h}, \mathbf{J}) = \exp[-E(\sigma|\mathbf{h}, \mathbf{J})] / \sum_{\sigma'} \exp[-E(\sigma'|\mathbf{h}, \mathbf{J})] \quad (2)$$

ここで E は活動パターン σ のエネルギーであり、次式で定義される。

$$E(\sigma|\mathbf{h}, \mathbf{J}) = - \sum_{i=1}^N h_i \sigma_i - 1/2 \sum_{i=1}^N \sum_{j=1, j \neq i}^N J_{ij} \sigma_i \sigma_j \quad (3)$$

ここで、 $\mathbf{h} = \{h_i\}$ および $\mathbf{J} = \{J_{ij}\}$ はそれぞれ脳領域 i における活性化の傾向、および脳領域 i と脳領域 j の間の相互作用を示すパラメータである。モデルのフィッティングでは、ボルツマン分布 $P(\sigma|\mathbf{h}, \mathbf{J})$ が観測データに近似するようこれらのパラメータを更新する。その方法として観測されたパターンの出現頻度に基づき、平均と相関行列がモデルと一致するように \mathbf{h} および \mathbf{J} を反復的に更新する疑似尤度最大化法が提案されている。詳細は文献を参照されたい[2], [4]。

イジング・モデルは統計物理学の分野で磁性体の性質を説明するモデルとして一般的であるが、そのモデルを脳活動データに当てはめることは、脳活動がこのモデルで物理学的に説明できるということではない。あくまで脳領域間の相互作用や活動パターンをデータから抽出するための数理モデリングの手段として用いている点に注意が必要である。

2-2 エネルギー地形と極小状態

前述のイジング・モデルのフィッティングにより、任意の活動パターン σ がもつエネルギーを求めることが可能となった。また、任意のパターン σ の近傍は

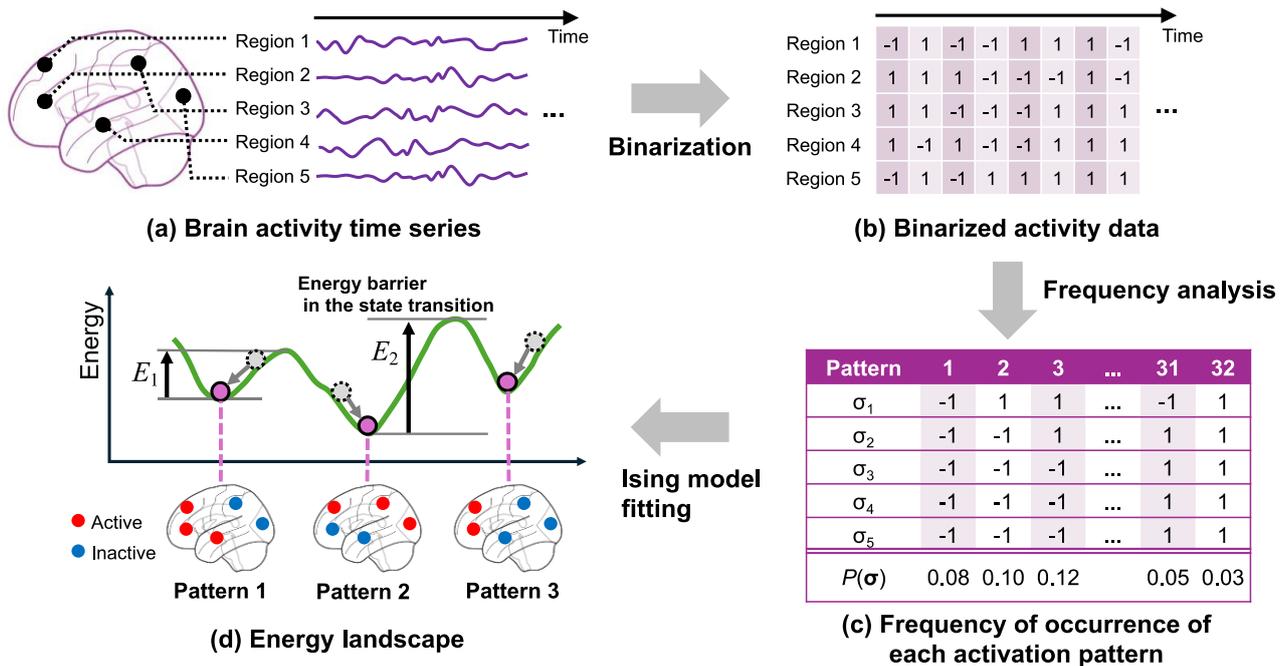


図 1 脳活動データに対するエネルギー地形解析の概要

N 個の隣接する活動パターンによる超立方体グラフで構成されている[5]. すなわち、我々の脳状態はこのような空間の中で時々刻々と遷移しているとみなすことができる. このとき、ある活動パターン σ が近傍内のどのパターンのエネルギーよりも低い場合、活動パターン σ は極小状態にあるといえる. ボルツマン分布に基づき、このような極小状態は出現頻度が高くなる (エネルギーが低い状態ほど出現頻度が高くなる). ELA では、極小状態をデータに存在する代表的なパターンとみなし、複数の極小状態間の遷移ダイナミクスを分析する.

脳活動データを対象とすると、ある実験条件下で計測された脳活動データに対してイジング・モデルを当てはめ、極小状態=代表的な脳活動パターンを推定し、脳状態遷移と実験条件の関係を分析できる.

3. ドライバ脳活動データの取得

3-1 実験デザイン

本研究では、運転の楽しさ (ドライビング・プレジャー) と脳活動パターンの関係を分析する目的で取得された脳活動データを利用した. 本実験は同志社大学「人を対象とする研究」に関する倫理審査委員会に承認されており (承認番号: 23012)、普通自動車運転免許を所有する健康な成人 24 名 (22.8 ± 1.1 歳, 右利き 22 名) のデータを得た.

実験仮説として、ドライビング・プレジャーはカーブの頻度が低い道路よりもカーブ頻度が高い道路

で増加する (仮説 1)、ドライビング・プレジャーは緩やかなカーブよりも急なカーブで増加する (仮説 2) という 2 つが設定された. 図 2 のようなカーブ頻度とカーブ曲率半径の 2 要因による計 4 条件のコースで走行実験が行われた. なお、仮説と実験条件の設定は Takeda らの研究[6]を参考にした.

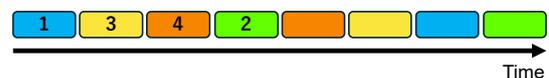
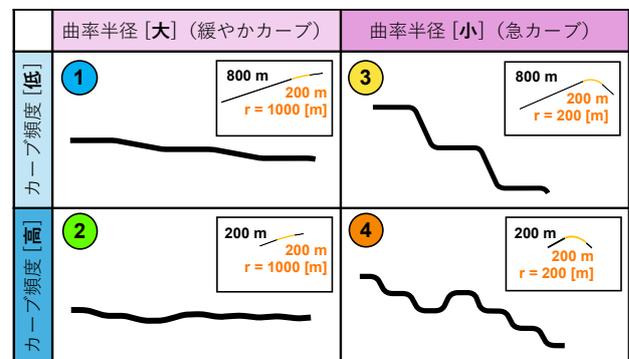


図 2 走行コース

各道路条件のコースの長さは全て 5 km であり、道路は 2 車線で構成され各道路幅は 3.5 m とした. カーブの頻度は直線区間の長さによって調節された.

すなわち、カーブ頻度[低]条件とカーブ頻度[高]条件では、直線区間の長さをそれぞれ 800 m と 200 m に設定した。なお、各条件の曲線区間の長さは 200 m に固定した。結果として、カーブ頻度[低]条件とカーブ頻度[高]条件では、それぞれ 5 回と 12 回のカーブ区間が生じた。曲率半径の大きさは、曲率半径[大]条件では 1000 m, [小]条件では 200 m とした。

実験では、参加者は上記の 4 つの道路条件を 2 回ずつ (合計 8 回) 走行した。各条件を反映したコースをランダムに配置して連結した 1 つのコースとして、全ての参加者が同じコースを走行した (走行順序: 図 2 記載の条件 1 → 3 → 4 → 2 → 4 → 3 → 1 → 2)。参加者は、制限速度 100~120 km/h を守り、左車線を走行するように指示された。走行中、各道路条件の区間が終わるごとにピープ音が呈示され、参加者はその音を認識したタイミングで減速しその場で停車した。停車後、参加者は、その時点でのドライビング・プレジャーを Visual Analog Scale (VAS) を用いて主観的に評価した。評価スケールは「very boring: 非常に退屈」から「very pleasant: 非常に楽しい」と設定され、評価値は 1~100 の値に換算された。VAS による主観評価は、タブレット端末の液晶に表示された評価スケール上で回答した。参加者には 4 つの実験条件の切り替わり地点を予告せず、どの条件で走行しているかを認識できないようにした。

3-2 ドライビング・シミュレータ

実験は Assetto Corsa (<https://assettocorsa.gg>; KUNOS Simulazioni Srl.) を用いたドライビング・シミュレータ上で行われた。23 インチ LCD モニタ (S2319HS; Dell Inc.) を 3 台を表示端末とし (パノラマ表示解像度: 5760×1080, リフレッシュレート: 60Hz), ステアリングホイールおよびアクセル・ブレーキ・クラッチペダル (G27 Racing Wheel; Logicool Co Ltd.), ステレオスピーカー (Companion 2 Series III multimedia speaker system; Bose Corporation) を用いた。

3-3 機能的近赤外分光法

非侵襲脳機能イメージング法はいくつかあるが、運転中のような運動を伴う環境において有効な方法として、機能的近赤外分光法 (functional near-infrared spectroscopy: fNIRS) がある。fNIRS は近赤外光を頭表から脳に照射し、反射光の強度を計測することで、血中酸素濃度 (酸化ヘモグロビン oxy-Hb および脱酸素化ヘモグロビン濃度 deoxy-Hb) 変化を可視化する。脳活動を電位として計測する脳波計と比較して、筋電活動や外部ノイズに強いため、運転のような運動を伴う状況での計測に適している。

本実験における fNIRS (NIRSport2; NIRx Medical Technologies, LLC) のプローブ (source 16 個, detector 15 個) は、前頭前野および運動野を中心に広範囲をカバーするように配置され、結果として計 48 チャンネルの計測点が構成された (図 3)。チャンネル数の制約上、視覚野についてはカバーできていない。なお、fNIRS の各計測チャンネルがどの脳領域の活動を計測しているかを知るために、3 次元デジタルサイザーにより source/detector の 3 次元座標を計測した。計測された 3 次元座標は AtlasViewer [7]に入力され、光学シミュレーションにより各チャンネルが計測している脳領域を特定した。なお、頭部や脳の形状の個人差を考慮するため、この処理は被験者ごとに行われた。

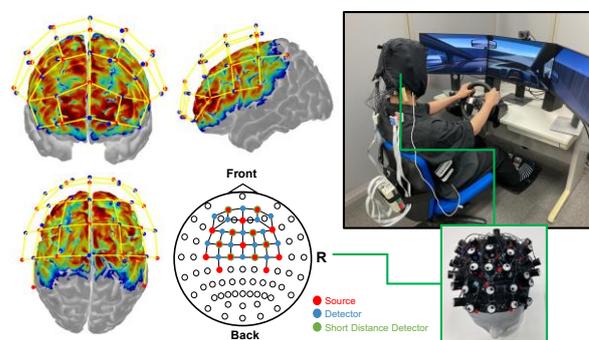


図 3 fNIRS のプローブ配置と実験環境

3-4 fNIRS データの前処理

fNIRS データは通常、光の強度データの形式で得られる。強度データの段階で、Scalp Coupling Index (SCI)に基づいて信号品質を評価し、SCI が 0.75 未満のチャンネルのデータを除外した。次に、強度データを optical density (OD) データに変換し、temporal derivative distribution repair および wavelet filtering (sym8)により体動ノイズを除去した。さらに、modified Beer-Lambert law (partial pathlength factor: 0.10)に基づき OD データを oxy-Hb および deoxy-Hb データに変換した。続いて band-pass filtering (通過帯域: 0.01 – 0.5 Hz) と short separation regression により生理学的ノイズを除去した。以上の前処理には NIRS Brain AnalyzIR toolbox [8]を利用した。最後に、oxy-Hb と deoxy-Hb を加算し total-Hb を求めた。

被験者間で同一の脳領域の活動を比較するために、被験者ごとに同じ脳領域に割り当てられたチャンネルの total-Hb 信号をそれぞれ標準化した後、チャンネル間で平均し、脳領域ごとに一つの時系列データを得た。頭部形状の個人差により、全被験者 24 名で共通して取得できた脳領域が 4 領域のみであったため、より広範囲の脳領域を解析対象とすべく、表 1 に示す 6 領域を含む被験者 14 名を解析対象とした。

表 1 解析対象とした脳領域

領域ラベル	領域名
Frontal_Mid_L	中前頭回 (左)
Frontal_Mid_R	中前頭回 (右)
Frontal_Sup_L	上前頭回背側部 (左)
Frontal_Sup_R	上前頭回背側部 (右)
Precentral_L	中心前回 (左)
Precentral_R	中心前回 (右)

4. 実験

被験者 14 名における表 1 の 6 領域の脳活動データに対して、ELA を適用した。各 total-Hb 信号が標準化されているため、閾値を 0 として信号を二値化した (0 より大きければ+1, 0 未満を-1)。14 名分の時系列データを 4 つの実験条件ごとに連結し、実験条件ごとにイジング・モデルをフィッティングした。カーブ頻度の高/低、およびカーブ曲率半径の大/小に応じて得られる極小状態が異なっているか、条件に固有のパターンが見られるかどうかを検証する。

5. 結果と議論

5-1 ドライビング・プレジャーの主観評価

カーブ頻度の高/低、およびカーブ曲率半径の大/小の要因が、被験者のドライビング・プレジャーを誘発したかを主観評価結果から t 検定により検証した。

その結果、曲率半径[小] (急カーブ) 条件下において、カーブ頻度[低]条件とカーブ頻度[高]条件の間で有意な差が見られた ($p < .05; d = -0.65$)。一方、曲率半径[大] (緩やかなカーブ) 条件下ではカーブ頻度の高/低の差は有意でなかった。また、曲率半径の大/小の差は、カーブ頻度にかかわらず有意であった (頻度[低]条件下: $p < .05; d = -0.59$, 頻度[高]条件下: $p < .05; d = -1.18$)。これらの結果は、急カーブにおいてはカーブ頻度が、また曲率半径の大きさはカーブ頻度の高低に関係なく被験者のドライビング・プレジャーに影響を与えることを示唆している。

5-2 ELA により得られた極小状態

図 4 は、ELA により得られた各実験条件におけるエネルギー地形、極小状態とその活性パターン、極小状態間のエネルギー障壁を示した非連結性グラフである。エネルギー障壁とは、2 つの極小状態を結ぶ最短パスにおいて、最もエネルギーが高くなるポイント (鞍点) を見つけた際、ある極小状態からその鞍点までのエネルギー差を指す。つまり、ある極小状態から別の極小状態に遷移する際に超えなければ

ならないエネルギー障壁があり、これが小さいほど状態遷移が起こりやすいと考えられる。非連結性グラフは、極小状態を頂点とし、頂点間のエネルギー障壁に基づいて、2 つの極小状態がどのように結合されるかを示す樹形図である。エネルギー障壁が低い順に頂点を結ぶことで、どの極小状態がどの程度のエネルギーで結合されるかを視覚化する。

図 4 より、急カーブ・高頻度条件において、最も多い 4 つの極小状態が得られている。6 領域すべてが活性しないパターンはすべての条件で共通していることから、この極小状態は実験条件に依存しないものと考えられる。緩やかなカーブ・低頻度条件では、前頭部左右 (Frontal_Mid_L/R, Frontal_Sup_L/R) のみが活性するパターンが存在している。これを基準に考えると、曲率半径を小さくしたり、カーブ頻度を高くしたりすると、一次運動野 (Precentral_L/R) が加わり 6 領域すべてが活性するパターンが現れる。このことは、走行コースの複雑度が上がることで、より複雑な運動制御が必要とされたことを示唆する。

急カーブ・高頻度条件では、他の条件に存在しない二つの極小状態 State 3/4 が検出されたことに注目したい。ただし、State 4 は、他の 3 つの状態と比較してエネルギー値が高く、State 3 とのエネルギー障壁も小さいことから、State 3 をこの実験条件特有のパターンと考える。State 3 では、一次運動野に加えて、前頭部右側のみ (Frontal_Mid_R, Frontal_Sup_R) が活性していることが特徴的である。これらの領域は、ネガティブな感情をポジティブに捉え直す感情再評価に重要や役割を果たすとされている[9], [10]。急カーブ・高頻度条件という 2 つの要因が強く作用する条件において、これらの 2 領域が特異的に活性していることは、State 3 がドライビング・プレジャーに特有のパターンである可能性を示唆している。ただし、今回は探索的解析の結果を示しているのみであり、実際にこの活性パターンがドライビング・プレジャーに固有のものであるかは、独立したデータセットでの検証が必須である。

6. 結論

ドライバ脳活動データに対する ELA の有効性を検証するために、著者らが取得したドライビング・プレジャーを誘発する走行実験における fNIRS データに ELA を適用した。極小状態として検出される活性パターンが実験条件の差異を反映するか、また、条件に固有のパターンが観察できるかを検証したところ、カーブの曲率半径と頻度という 2 要因に応じ

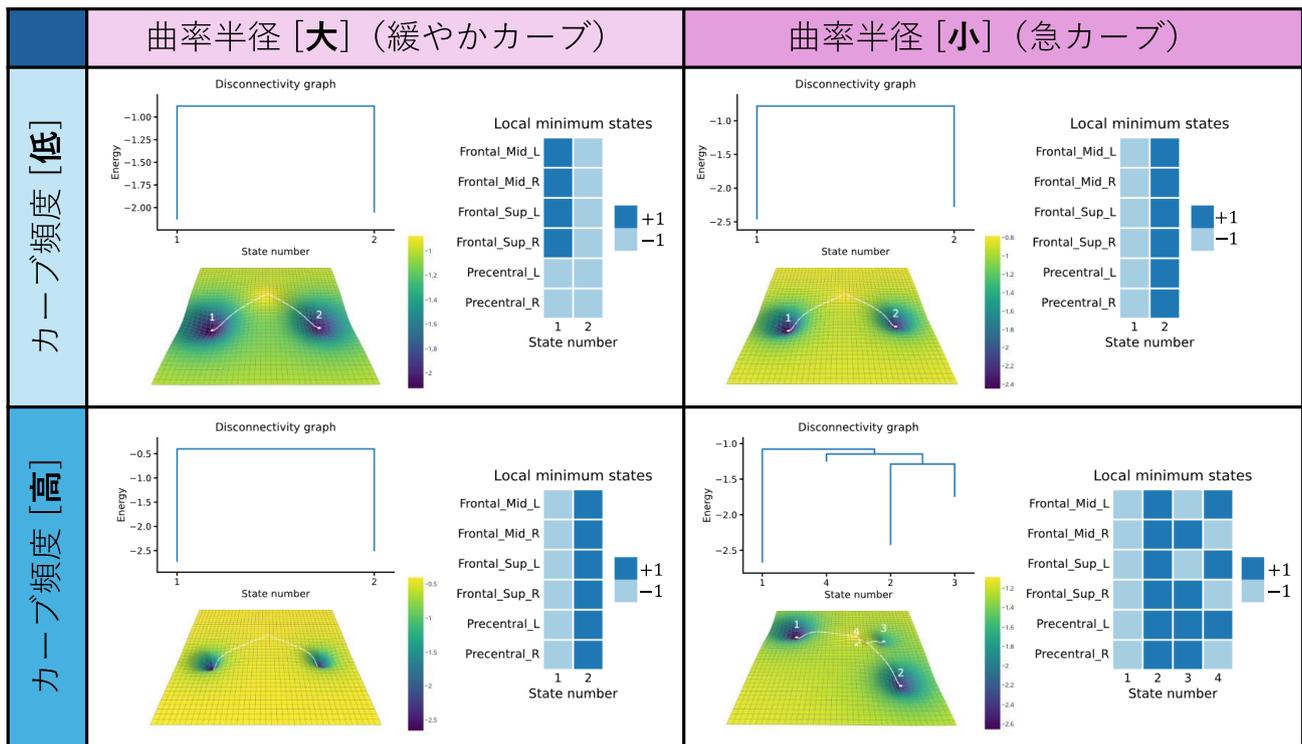


図 4 ELA により得られた各実験条件におけるエネルギー地形と極小状態

て出現する極小状態が変化すること、また、2つの要因が強く作用する条件において特有の極小状態が観察されることがわかった。本研究は ELA がドライバ脳活動データ解析に有用であることを示唆した。

参考文献

- [1] S. Balters, J. M. Baker, J. W. Geeseman, and A. L. Reiss, “A Methodological Review of fNIRS in Driving Research: Relevance to the Future of Autonomous Vehicles,” *Front. Hum. Neurosci.*, vol. 15, Apr. 2021, doi: 10.3389/fnhum.2021.637589.
- [2] T. Ezaki, T. Watanabe, M. Ohzeki, and N. Masuda, “Energy landscape analysis of neuroimaging data,” *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, vol. 375, no. 2096, p. 20160287, May 2017, doi: 10.1098/rsta.2016.0287.
- [3] P. R. Regonia *et al.*, “Modeling Heterogeneous Brain Dynamics of Depression and Melancholia Using Energy Landscape Analysis,” *Front. Psychiatry*, vol. 12, p. 780997, Nov. 2021, doi: 10.3389/fpsy.2021.780997.
- [4] J. Kang, C. Pae, and H.-J. Park, “Graph-theoretical analysis for energy landscape reveals the organization of state transitions in the resting-state human cerebral cortex,” *PLOS ONE*, vol. 14, no. 9, p. e0222161, Sep. 2019, doi: 10.1371/journal.pone.0222161.
- [5] 増田直紀, “エネルギー地形解析 (特集 データサイエンスの数理: 数理で読み解くデータの価値),” *数理科学*, vol. 57, no. 6, pp. 51–57, Jun. 2019.
- [6] Y. Takeda, K. Inoue, M. Kimura, T. Sato, and C. Nagai, “Electrophysiological assessment of driving pleasure and difficulty using a task-irrelevant probe technique,” *Biological Psychology*, vol. 120, pp. 137–141, Oct. 2016, doi: 10.1016/j.biopsycho.2016.09.009.
- [7] C. M. Aasted *et al.*, “Anatomical guidance for functional near-infrared spectroscopy: AtlasViewer tutorial,” *NPh*, vol. 2, no. 2, p. 020801, May 2015, doi: 10.1117/1.NPh.2.2.020801.
- [8] H. Santosa, X. Zhai, F. Fishburn, and T. Huppert, “The NIRS Brain AnalyzIR Toolbox,” *Algorithms*, vol. 11, no. 5, Art. no. 5, May 2018, doi: 10.3390/a11050073.
- [9] R. Falquez *et al.*, “Detaching from the negative by reappraisal: the role of right superior frontal gyrus (BA9/32),” *Front. Behav. Neurosci.*, vol. 8, May 2014, doi: 10.3389/fnbeh.2014.00165.
- [10] C. Morawetz, S. Bode, J. Baudewig, A. M. Jacobs, and H. R. Heekeren, “Neural representation of emotion regulation goals,” *Human Brain Mapping*, vol. 37, no. 2, pp. 600–620, Feb. 2016, doi: 10.1002/hbm.23053.