

SVMを用いた衝動性パーソナリティの神経生理分類

曾雌崇弘[†] 野田隆政[‡] 安藤久美子[†] 中澤佳奈子^{†‡} 津村秀樹[†] 岡田幸之[†][†]国立精神・神経医療研究センター [‡]国立精神・神経医療研究センター病院

精神保健研究所

精神科

司法精神医学研究部

【背景】近年、社会的問題となっている多様な依存症や暴力的行為の背後には「衝動性」が関与していると考えられており、そのリスクアセスメントは、臨床現場のみならず、一般社会においても重要な課題である[1]。衝動性は複合的な概念であり、「他人への悪影響を熟慮せずに、早急に、無計画に反応、もしくは行動する行動特性」と一般的に定義される[2]。衝動性は、脱抑制、無計画行動、新奇性追求などのさまざまな行動パターンに関係しており、臨床的には、注意欠如多動性障害、統合失調症、境界性人格性障害、物質依存症などの多様な精神疾患に関係している[3]。衝動性の認知神経学的な研究は約20年前から行われているが[4]、最近では、機能的磁気共鳴画像法(fMRI)や事象関連脳電位活動(ERP)を用いて、問題行動パターンの予測や分類を行う研究が報告されている[5,6]。衝動性行動は、大別すると2種類に区別される[7]。1つ目が「衝動性反応」であり、注意散漫性や早急性反応などに関連する。2つ目が「衝動性選択」であり、ギャンブル依存などに関連する非計画的な行動選択に関連する。衝動性反応は暴力性行為などに関連しており、予測・分類研究の研究対象として取り上げられることが多い。衝動性反応に関わる認知機能は「行動抑制」である。感覚刺激が入力された時、反応を抑制する行為であり、挑発にのらないような行動には重要である。実験環境では、Go/Nogo課題のような反応抑制を促す課題を用いて調べる。衝動性が高いと抑制エラーが多くなり、衝動性の行動指標として使われることもある。

本研究は、Go/Nogo抑制課題中の複数の脳電位活動を用いて、非病理的ではあるが多様な衝動性特性を持つ健常群を分類することを目的とした。分類分析には、階層クラスター分析と

サポートベクターマシーンを組み合わせたデンドログラムSVMを用いた[8]。将来的には、臨床群を含めた複数対象群の神経生理分類で効率的に機能する脳活動を抽出することを目標とする。

【被験者】健常成人24名(女性16名、平均年齢31歳;男性8名、27歳)が参加した。被験者の精神状態は構造的臨床面接(SCID-I/NP)で確認した。被験者は、精神疾患既往歴、脳損傷、物質依存、認知異常には該当しなかった。被験者は、当センター倫理委員会規定に遵守した手順に基づき、紙面でインフォームドコンセントを与えた。

【実験方法】被験者は、防音室内において、Go/Nogo課題を行った。19インチ液晶画面(DeLL社製E193FPp、解像度1,280×1,024、RR=74.61Hz)の中央に、高頻度の標準顔刺激と低頻度の顔刺激が擬似ランダム化された順番で呈示され(視角:垂直10.285°;水平:9.211°)、被験者は低頻度のNogo刺激の時にボタン押しを抑制するよう教示された。刺激呈示時間は250msで、SOAは1,400±100msに設定された。実験は6ブロックからなり、各ブロックは120の標準Go刺激(67%)と60のNogo刺激(33%)を含んでいた。顔刺激は、データベースから180刺激を選んだ。

衝動性特性は、2種類の自己評価尺度を用いた。BIS-11は30項目からなり、注意衝動性(AI:8-32点)、運動衝動性(MI:11-44)、無計画衝動性(NPI:10-40)に大別される[9]。BIS/BASは20項目からなり、行動抑制系指標(BIS:7-28)と行動賦活系指標(BAS)は、駆動性(D:4-16)、報酬応答性(RR:5-20)、新奇性追求(FS:4-16)から構成される[10]。両尺度ともに得点が高いほど関連行動特性が高いと解釈される。

【脳電位活動データ収集と解析】脳波(EEG)は、頭皮上の正中線(Fz, Cz, Pz, Oz)に付着したAg/AgCl電極を用いて記録した(日本光電社製Neuro Workbench ver.04-23)。眼球運動は、左右の3電極を用いてモニターした。アース電極は顎部に、基準連結電極は左右の乳様突起に付着した。サンプリング周波数は1,024Hz、帯域周波数は0.1~100Hz、接触抵抗5kΩで記録した。

SVM-based neurophysiological classification of people with various non-pathological impulsivity

Takahiro Soshi[†], Takamasa Noda[‡], Kumiko Ando[†], Kanako Nakazawa^{†‡}, Hideki Tsumura[†], Takayuki Okada[†]

[†]Department of Forensic Psychiatry, NIMH, NCNP

[‡]Department of Psychiatry, NCH, NCNP

CA: t-noda@ncnp.go.jp (TN); ando@ncnp.go.jp (KA)

EEG 解析は、最初に、0.5~40Hz のオフライン帯域周波数フィルター処理を行った。その後、垂直眼球運動データをテンプレートとして用い、線形回帰方式により頭皮上 EEG からアーチファクト削減処理を行った。顔刺激呈示前 100 ms から呈示後 1,000 ms までを、正答 Go 条件と Nogo 条件の EEG エポックとして取り出し、ベースライン修正(-100~0 ms)、アーチファクトエポック除去($\pm 75 \mu V$)を行った後に加算平均した。

【デンドログラム SVM】 衝動性尺度の 7 成分を各項目ごとに標準化し、被験者間の類似性をユークリッド距離で求めた後、Ward(重心)法によりクラスター化を行った。被験者の 2 クラスターが得られたので(図 1)、SVM に学習させる 2 項分類ラベルとした。2 群を分ける超平面を求めるために 10 個の特徴を用いた。社会人口学的特性として「年齢」と「性別」を用いた。EEG は、早期抑制活動の「N2」(刺激呈示後 200 ms ぐらいに現れる陰性電位)と後期抑制の「P3」(刺激呈示後 300 ms 以降で現れる陽性電位)、さらに、著者らの先行研究により観察された、抑制エラーに関わる「Ne」(エラー反応後 200 ms あたりで現れる陰性電位)と「Pe」(エラー反応後 200 ms 以降で現れる陽性電位)、ならびにエラー直後の正しい Go 反応で現れる「post-error N2」(4 活動)の ERP を用いた[11]。これらの特徴は標準化した後、放射基底関数を用いて SVM-REF によりランク化し[12]、最も精度が高い分類器を特定した。分類精度の算出は、一個抜き交差検定(L00CV)を用いた。最適モデルの有意性検定は、分類ラベルをランダムに 1,000 回生成し、permutation L00CV により得られたランダム分布において 95%信頼区間外に実際分類精度が位置する場合に α 水準 5%で有意とした。

【結果と考察】 衝動性自己評価高群(14 名)と評価低群(10 名)が、図 1 に見られるように分類された。高群は、低群に比べ注意衝動性などの衝動性関連の 5 項目で得点が高かった(t 検定: 全て $p < 0.025$)。高低群の分類を SVM-REF により学習させたところ、上位 3 特徴を含む分類器が最も精度が高かった。図 2 に見られるように、「エラー後第 1 Go 刺激の N2(Fz)とエラー後第 2Go 刺激の N2(Fz, Cz)」による分類器が約 80%の分類精度を示し(範囲:0.125~0.833)、 α 水準 5%の閾値(分類精度 70.8%)より高く有意であった($p = 0.014$)。これらの結果から、衝動性特性を精度よく分類するためには、単一の特徴ではなく、抑制エラー回復の脳活動を用いた複合特徴分類モデルが有効であることが示唆された。

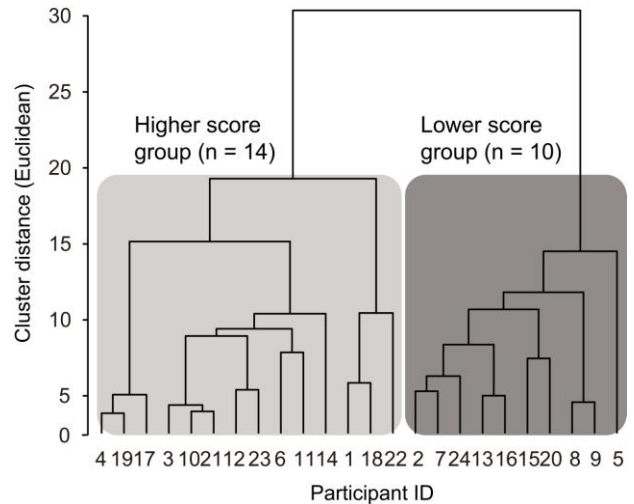


図 1. 階層クラスター分析による被験者分類

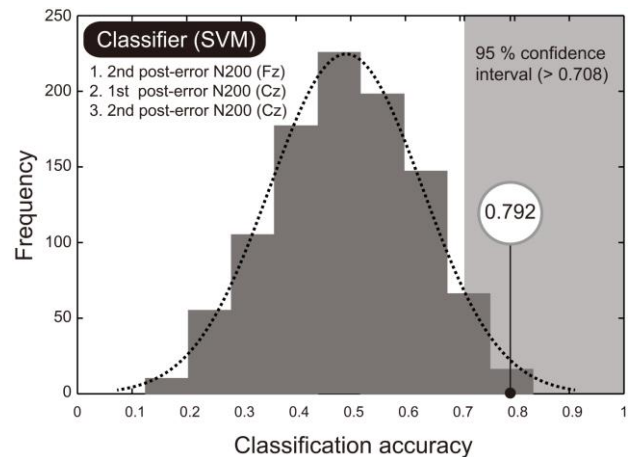


図 2. SVM による被験者分類の正答率検定

引用文献

- 1 安藤ら (2015). H24-26 年度 NCNP 研究報告書.
- 2 Moeller et al. (2001). Am J Psychiatry 158.
- 3 Evenden (1999). Psychopharmacology 146.
- 4 Harmon-Jones et al. (1997). Person Individ Diff 22.
- 5 Aharoni et al. (2013). PNAS 110.
- 6 Steele et al. (2014). Biol Psychiatry 76.
- 7 Bari & Robbins (2013). Prog Neurobio 108.
- 8 Lajnef et al. (2015). J Neurosci Methods 30.
- 9 Someya et al. (2001). Psychiatry Clin Neurosci 55.
- 10 Takahashi et al. (2007). Japanese Journal of Personality 15.
- 11 Soshi et al. (2015). Front Hum Neurosci 26.
- 12 Guyon et al. (2002). Machine Learning 46.