

片足立ちにおける足底圧分布と姿勢角度に基づいた 粗大運動評価モデルによる ASD 傾向分類

ASD propensity classification by coarse motor assessment model based on plantar pressure distribution and posture angle in one legged standing

瀬田 稀介¹, 大本 義正¹, 熊崎 博一², 岩永 竜一郎², 今村 明², 清水 日智³, 寺田 和憲³

Maresuke Seta, Yoshimasa Ohmoto, Hirokazu Kumazaki, Ryoichiro Iwanaga, Akira
Imamura, Hitomi Shimizu, Kazunori Terada

¹ 静岡大学, ² 長崎大学, ³ 岐阜大学

Shizuoka University, Nagasaki University, Gifu University
seta.maresuke.19@shizuoka.ac.jp

概要

現在の ASD スクリーニングは定性的なデータだけに基づいて判断しているため、効率性に限界があると指摘されている。そこで本論文では、定量的データを用いて定性的基準に基づいた診断結果を予測する方法を提案する。結果として、「片足立ち」という限定的な状況において、本論文で作成した特徴量が先行研究で挙げられた特徴量より効果的である事が分かった。最後に、なぜこのような結果になったのかを議論し、今後の展望について述べる。

キーワード：ASD, 協調運動能力

1. はじめに

近年、自閉スペクトラム症 (Autism spectrum disorder: 以下 ASD と呼ぶ) 診断の需要が高まっている。これに伴い、ASD に対する理解が進み、その症状が社会的に身近なものとなりつつある。しかし、ASD を診断できる医師や医療機関に限られている点や、診断を受けるまでに多くの時間を要する点など、診断の需要と供給のギャップに不満を抱く人も多い [1]。この問題は、主に一般的な ASD 補助診断ツールである ADOS-2 (Autism Diagnostic Observation Schedule Second Edition) や ADI-R (Autism Diagnostic Interview - Revised) などを用いた診断方法に起因している。これらの診断方法は、検査実施者に特別なスキルが求められる上、客観性・再現性を保つために多くの時間を必要とし [2]、結果として診断基準が定量的ではなく定性的となる傾向がある。このため、診断は非常に繊細で長期にわたることが多い。

こうした問題に対処するために、医療現場では ASD スクリーニングと呼ばれる仕組みが採用されている。ASD スクリーニングとは、診断に至る前に特定のプ

ロセスを行うことで、大まかに ASD リスクの高低を判断する仕組みである。これにより、ASD リスクが高い児童を優先的に診断し、リスクが低い児童を診断待ちから除外することで、医療現場および家庭の負担を軽減することができる。しかし、ASD スクリーニングで用いられるデータや診断結果も定性的に生成されるため、診断効率に限界がある。

そこで我々は定量的な判断基準を持つ機械学習アルゴリズムを医療現場の意思決定に導入することで、この課題を解決しようと考えた。具体的には、ASD のスクリーニングプロセスにおいて、機械学習を用いて定量的なデータ分析を行い、診断の客観性と効率性を向上させることを目指す。このアプローチにより、ASD 診断の補助ツールとしての有用性を示し、ASD 診断の長期化問題を解決する事が考えられ、診断の精度と信頼性を更に向上させることが期待できる。

2. 方法

2.1 調査参加者

本分析では長崎県佐々町の 5 歳児健診に訪れた親子を対象とし、ASD スクリーニング受診希望者を調査対象とした。参加者には協調運動能力を評価するスクリーニング項目である「片足立ち」を圧力センサー上で左右 2 回ずつ計 4 回行ってもらい、その様子を動画で撮影した。その間、保護者には ASD リスクの高低の判断に利用される社会的反応性尺度第二版 (Social Responsiveness Scale, Second Edition: 以下 SRS-2 と呼ぶ) と呼ばれるアンケートに回答してもらった。SRS-2 から算出されるスコア (以下 SRS-2 スコアと呼ぶ) は、日本人の場合で男性は 53.5 点、女性は 52.5 点以上であると ASD リスクが高いと判断され

る [3]。そうした中で以下 2 つの条件を満たす場合に分析対象とした。

- ・ SRS-2 アンケートに欠損がないこと
- ・ 「片足立ち」を手順通りに最後まで行えたこと

これらの条件を満たした 2022 年 8 月から 2024 年 5 月までに訪れた親子計 126 名 (男性 66 名、女性 60 名、ASD 高リスク 19 名、ASD 低リスク 107 名) を本研究の分析対象とした。本論文では、以下に記述する定量的データを用いて、SRS-2 スコアに基づいた診断結果の予測を行う。

2.2 データ取得

調査参加者は以下の 2 つの条件下で左右 2 回ずつ計 4 回の「片足立ち」を行った。

- ・ カメラに対して正面を向き、「片足立ち」を行う
- ・ 「片足立ち」試行は全て圧力センサーの上で行う

これらの条件のもと、カメラからは身体情報を、圧力センサーからは圧力情報を取得した。カメラと圧力センサーは 20fps で同期しており、撮影された画像と圧力情報は時間的に一致している状況である。

2.3 データ加工

2.3.1 身体情報

本調査では、カメラで撮影した画像データに対して、Openpose を用いることで、各フレームにおける関節点を取得した。このようにして得られた関節点データに対して、分析の統一性を確保するために以下の処理を手順通りに行った。

1. 取得したデータに対して左足の試行の場合だけ左右反転処理を行い、左右の試行による分析の統一性を確保した。
2. 統一性のあるデータ分析を行うために閾値を設定し、Openpose による関節点の誤検出や左右の誤判断に対処した。
3. 先行研究から、全身の協調運動を評価するために身体角度に着目することは効果的であることが分かっている [4]。表 1 に示されている 8 点の角度を算出した。

表 1 算出した角度一覧

名称	参照部位	名称	参照部位
RSide	右尻・右肩・右膝	RKnee	右尻・右膝・右足首
LSide	左尻・左肩・左膝	LKnee	左尻・左膝・左足首
RTrunk	首・腰・右尻	Shoulder	右肩・左肩・水平軸
LTrunk	首・腰・左尻	Head	首・鼻・水平軸

2.3.2 重心情報

本調査では圧力センサーから取得した圧力情報を用いて、タスク試行中における重心動揺の把握を行った。本調査環境では、調査条件を満たしていれば自由度が高く「片足立ち」を試行することができる。そのため、様々な試行がデータとして現れ、分析の統一性を失いかねない状況となった。そこで以下の処理を行うことで、分析に適したデータに加工した。

1. 身体情報同様に左右反転処理を行い、左右の試行による分析の統一性を確保した。
2. 本調査の環境では、参加者によって足の向きに僅かな差異が存在し、重心動揺分析の平等性が欠けてしまう。そのため、圧力分布を楕円近似し、回転角度を用いて圧力分布を再構築した。
3. タスク試行中、バランスを保持するために軸足を微動させたり、片足跳躍を行う参加者が見られた。本調査では、軸足が安定していると推測できる領域を統計的に算出し、その領域外への圧力が確認された場合、それ以前のデータを分析対象とした。

これらの処理により、身体情報と圧力情報共に試行の自由度によって生じるデータのばらつきを抑え、統一性のある分析を行うことが可能となった。

2.4 データ分析

2.4.1 分析対象時点の決定

片足立ちの試行は調査参加者によっても、また試行ごとにも試行時間に差がある。そこで本論文では分析対象時点を試行始めの 2 秒とすることにし、また 4 回試行の中でも 1 番目の試行に焦点を当てた。これには以下 2 つの理由が挙げられる。

- ・ 片足立ちというタスクの慣れが平等性
- ・ 姿勢の不安定性

両足から片足への遷移は姿勢制御における不安定な瞬間の代表例であると考えられているため [5]、4 回試行を行う上で初回における開始 2 秒を、分析対象時点として決定した。

2.4.2 説明変数

取得した時系列データから、分析を行う際の説明変数を作成した。その一覧を表 2 に示す。

これらの説明変数群は大きく分けて 2 種類に分類される。1 つ目は、既存の先行研究で協調運動能力を評価する際に有効と判明した特徴量である。この分類に

表 2 説明変数まとめ

説明変数	概要
Distance	重心変動の軌跡の総和
Len	着目した片足立ちの試行の長さ
entropy	重心変動の複雑性
ConvexHull	重心変動の軌跡を外包する図形の面積
COM-COP	身体重心と圧力重心の関係
COM	身体重心変動の総和
RSideR	重心動揺距離と RSide の相関係数
LSideR	重心動揺距離と LSide の相関係数
ShoulderR	重心動揺距離と Shoulder の相関係数
HeadR	重心動揺距離と Head の相関係数
RTrunkR	重心動揺距離と RTrunk の相関係数
LTrunkR	重心動揺距離と LTrunk の相関係数
RKneeR	重心動揺距離と RKnee の相関係数
LKneeR	重心動揺距離と LKnee の相関係数

該当するのは、表 2 の上 6 つの説明変数である。例えば Graham らの研究では、バランス制御に関する評価方法として、重心動揺の総距離や外包面積が有効であるとしており [6]、これは Distance や ConvexHull が該当している。こうした協調運動能力を評価する指標に関する先行研究を網羅的に調査し [7][8][9][10]、「片足立ち」に適応できるであろう説明変数を 6 つ作成した。

2 つ目は、我々が独自に作成した説明変数である。身体の平衡感覚を維持するためには、複数の感覚系の統合とフィードバックに基づく運動補正が必要であるため、身体と重心の関係性を上手く反映すると考えられる 2 変数間の相関係数を特徴量として考案した。これら計 14 種類の説明変数を、本論文の分析で使用する。

2.4.3 分析手法

先程示した説明変数群を用いて、ロジスティック回帰・ガウシアンナイーブベイズ・SVM(線形カーネル)の 3 つの教師あり機械学習分類器が訓練された。具体的な手順は以下のとおりである。

まず、LOOCV(leave-one-out cross-validation) 形式で学習し、各説明変数の SHAP 値 (予測値への影響度を表す数値) を計算した。その過程で人数分だけ最も SHAP 値が小さい説明変数が得られ、その中で多数決をとり最も影響力の小さい説明変数を決定し削除した。この手順を繰り返し、説明変数の数が少なくなる中で、F1 値が高い値で安定している説明変数の組み合わせを抽出した。最終的に説明変数が 1 つになるま

で、この手順を続けた。

次に、先ほど抽出された説明変数で学習している分類器において、最適なハイパーパラメータをベイズ最適化によって探索し、チューニングした。具体的には、ロジスティック回帰の場合はコスト ($10^{-6} \sim 10^6$)、ガウシアンナイーブベイズでは分散の平滑化 ($10^{-9} \sim 10^{-1}$)、SVM ではコスト ($10^{-6} \sim 10^6$) のパラメータを最適化した。こうして得られた最終的な結果は、各分類器の性能を最大化するために調整されたものである。

3. 結果

以下に分析結果を示す。最初にロジスティック回帰の結果を示す。

表 3 ロジスティック回帰による分析結果

特徴量数	正解率	感度	特異度	F 値	パラメータ
3	0.634	0.631	0.635	0.342	0.032
4	0.658	0.631	0.663	0.358	11100
5	0.634	0.631	0.635	0.342	0.032

ロジスティック回帰のモデル作成に使用した説明変数は、特徴量数が 3 つの場合は LSideR、LKneeR、HeadR であり、それに加えて LTrunkR や Len も併用された。ロジスティック回帰の場合、我々が考案した特徴量が多く採用されていた。

次にナイーブベイズによる分析結果を示す。

表 4 ナイーブベイズによる分析結果

特徴量数	正解率	感度	特異度	F 値	パラメータ
3	0.365	0.789	0.289	0.272	1.909
4	0.412	0.736	0.355	0.274	1.909
5	0.365	0.526	0.336	0.200	1.909

ナイーブベイズのモデル作成に使用した説明変数は、特徴量数が 3 つの場合は Len と HeadR と entropy であり、それに加えて RKneeR や Distance も併用された。ナイーブベイズの場合、既存の先行研究で扱われた特徴量が多く採用されていた。

次に SVM による分析結果を示す。

表 5 SVM による分析結果

特徴量数	正解率	感度	特異度	F 値	パラメータ
3	1.000	1.000	1.000	1.000	4.197
4	1.000	1.000	1.000	1.000	10^{-4}
5	1.000	1.000	1.000	1.000	10^{-6}

SVM で効果的であったと考えられた説明変数は、特徴量数が 3 つの場合は HeadR と LTrunkR と LSideR であり、それに加えて LKneeR や Len も併用された。

SVMの場合、ロジスティクス回帰同様に我々が考案した特徴量が多く採用されていた。また、3種類の機械学習分類の中で、分類精度が最も高かったのはSVMであった。

4. 議論

ロジスティクス回帰とSVMは共に線形分離を行う分類器であるが、2つの間に大きな精度の差が見られた。前者の精度が上がらない原因として、学習アルゴリズムの欠点が挙げられる。ロジスティック回帰は全体のデータを基にして分類結果を予測するのに対し、SVMは境界線付近のデータを重視する傾向がある。そのため、外れ値の影響を受けやすいロジスティクス回帰では、予測結果が伸び悩んだと考えられる。一方で、不均衡データにも関わらず、感度と特異度の値がバランスよく示された点は注目に値する。データ数が増加し、外れ値の影響が減少する場合、より適切な分析モデルが構築される可能性が示唆される。

ナイーブベイズによる分析結果を見てみると、感度が高く特異度が低いという結果であった。この結果は、ナイーブベイズが仮定する特徴量の独立性が満たされていないことが一因と考えられる。本分析の説明変数は身体協調に関する特長量であり、これらの間には相互関係が存在する可能性が高い。そのため、特徴量間の独立性を前提とする本モデルにおいては、予測精度の向上が困難であったと推察される。

SVMによる予測は非常に高い精度を示した。SVMにおける特徴量を分析すると、独自で計算した説明変数が多く採用されていた。この結果は、「片足立ち」という限定的な場面において、全身の協調運動能力を測定するためには、身体と重心の関係性に着目した説明変数がより効果的であることを示している。

機械学習による分類を行う上で、全てのデータセットに対して最適な分類器は存在しない。そのため本論文では3種類の分類器を用いてASDリスクの高低を予測したが、「片足立ち」という限定的な状況においては、SVMが有益であるという結果を得る事ができた。また、SVMで採用された説明変数が姿勢角度と足底圧重心の相関であったことから、協調運動能力を評価する際には、これらの要素間関係性に着目する事が効果的である可能性が示唆された。一方で、今回のデータセットと分析結果に基づいて着目すべき特徴量を決定することは、データ数が乏しいという点から難しい。したがって、今後はデータ数を増やすことで、より厳密な議論を行えるような環境や制度の導入が必要であると考えられる。

5. まとめ

本調査論文では、実際に行われているスクリーニングテストから定量的なデータを取得し、それらを用いた分類器によって、ASDリスクの高低を分類する事ができた。一方で、分析対象のデータ数が乏しいため、本調査で判明した特徴量の有益性を断定することは難しい。そのため、今後はASDスクリーニングにおける定量的なデータ取得を促進し、より厳密な議論を行える基盤の構築を目指すべきだと考える。

文献

- [1] Laura Crane, James W Chester, Lorna Goddard, Lucy A Henry, and Elisabeth Hill. Experiences of autism diagnosis: A survey of over 1000 parents in the united kingdom. *Autism*, Vol. 20, No. 2, pp. 153–162, 2016.
- [2] Michael Rutter, A Le Couteur, Catherine Lord, et al. Autism diagnostic interview-revised. *Los Angeles, CA: Western Psychological Services*, Vol. 29, No. 2003, p. 30, 2003.
- [3] Aki Shirama, Andrew Stickley, Yoko Kamio, et al. Emotional and behavioral problems in japanese preschool children with motor coordination difficulties: the role of autistic traits. *European Child & Adolescent Psychiatry*, Vol. 31, pp. 979–990, 2022.
- [4] Adriano Macchietto, Victor Zordan, and Christian R Shelton. Momentum control for balance. In *ACM SIGGRAPH 2009 papers*, pp. 1–8. 2009.
- [5] Bart Dingenen, Bart Malfait, Stefaan Nijs, Koen HE Peers, Styn Vereecken, Sabine MP Verschueren, Luc Janssens, and Filip F Staes. Postural stability during single-leg stance: A preliminary evaluation of non-contact lower extremity injury risk. *journal of orthopaedic & sports physical therapy*, Vol. 46, No. 8, pp. 650–657, 2016.
- [6] Cynthia A Molloy, Kim N Dietrich, and Amit Bhat-tacharya. Postural stability in children with autism spectrum disorder. *Journal of autism and developmental disorders*, Vol. 33, pp. 643–652, 2003.
- [7] Bih-Jen Hsue, Freeman Miller, and Fong-Chin Su. The dynamic balance of the children with cerebral palsy and typical developing during gait. part i: Spatial relationship between com and cop trajectories. *Gait & posture*, Vol. 29, No. 3, pp. 465–470, 2009.
- [8] Yumeng Li, Melissa A Mache, and Teri A Todd. Automated identification of postural control for children with autism spectrum disorder using a machine learning approach. *Journal of biomechanics*, Vol. 113, p. 110073, 2020.
- [9] Ruopeng Sun, Katherine L Hsieh, and Jacob J Sosnoff. Fall risk prediction in multiple sclerosis using postural sway measures: a machine learning approach. *Scientific reports*, Vol. 9, No. 1, p. 16154, 2019.
- [10] Tian Bao, Brooke N. Klatt, Susan L. Whitney, Kathleen H. Sienko, and Jenna Wiens. Automatically evaluating balance: A machine learning approach. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, Vol. 27, No. 2, pp. 179–186, 2019.