

近赤外分光法と深層学習による歩行時の情動判別

Emotions identification from NIRS signals while walking using deep learning

知能機械システム工学コース

ヒューマンメカトロダイナミクス研究室 1225055 矢倉 佳祐

1. 緒言

近年脳機能計測により、情動と脳機能賦活の関係が示されている⁽¹⁾。脳機能計測装置の1つであるfNIRS(functional near-infrared spectroscopy)は、情動を司る神経回路である前頭前野の脳血流変化を計測できる装置である。低い拘束性かつ比較的高い時間分解能で脳機能を計測できることから、情動と脳機能賦活の研究に多く用いられている。このfNIRSを用いて、不快と予測される視覚、聴覚刺激に対する前頭前野の脳血流変化を測定し、快・不快情動との関係を示す研究が今までに他機関にて行われている⁽²⁾⁽³⁾。しかし、歩行といった運動中の情動は、課題の設定が困難であることや体動ノイズ、歩行による脳活動が妨げとなることから、研究があまり行われておらず、未解明な部分が多い。

本研究グループでは、装着者がアシスト装具を装着して歩行した際に、装着者の快・不快情動を基にアシスト力を調節可能な機能を備えた装具の開発を行っている。この中で本研究では、歩行中の快・不快情動を精度良く識別する手法の確立を目指す。

これまでに既報⁽⁴⁾では、歩行中において、同被験者かつ同刺激であっても前頭前野のNIRS信号に大きなばらつきがある。この課題に対し、異なる歩行条件間において複数回の加算平均を得ることで、異なる条件間のNIRS信号に有意な差が存在することを示した。実用的な歩行アシスト装具開発を考えると、1度の歩行で力の調節ができることが望ましいが、その場合は、前述の同被験者、同刺激においてもNIRS信号のばらつきが大きいという理由より、数値的な閾値を設定する方法で歩行者の快・不快情動を識別することは困難であると考えられる。よって本研究では、このばらつきの大きい歩行中のNIRS信号を用いて情動を識別するために、深層学習を提案する。

深層学習にはDBN(Deep Belief Network)と呼ばれる信号解析に有効な学習モデルを用いる。また、データ数の不足を補うため、深層学習にかける前にNIRS信号に対して前処理を行うことで、データの質向上を行う。データの質向上により、学習時間の短縮と、深層学習の識別率の向上が期待できる。

本研究では、快不快情動を想起させる条件として足関節を取り上げ、歩行中に足関節が固定されているか否かによって生じるNIRS信号の差を取得、深層学習により快・不快情動を識別し、提案手法を検証する。

2. 歩行中の快・不快情動の識別手法

2.1 NIRSによる脳信号の取得

NIRSは酸素化Hb(ヘモグロビン)、脱酸素化Hbの吸光スペクトルの違いを利用して、脳機能賦活を測定する⁽⁵⁾。本研究では、脳血流変化と同じ傾向をもつ酸素化Hbの濃度変化を識別に用いる。

測定にはfNIRS(株式会社NeU製、WOT-100)を用いる。この装置は前額部を16chに分割して、サンプリング周波数5Hzで脳機能賦活が測定可能である。2つのバンドで頭部を固定するため、歩行という動きを伴う課題を測定する場合に適し

ていることが選定理由に挙げられる。

2.2 快・不快情動を想起させる歩行条件

本研究では、快・不快情動を想起させる歩行条件として、足関節に着目する。足関節を固定し拘束することで、歩行時に踵や膝に生じる衝撃が大きくなること、歩幅が小さくなることなどが生じる。前述の要因から生じる歩きづらさを歩行時の不快情動と定義する。足関節を固定しない場合は、不快情動と比較して、健常の状態に近い歩行となり、比較的歩きやすいことから歩行時の快情動と定義する。以上の定義の基で本研究の実験を行う。本研究の実験では、図1のような2種類の歩行補助装具を用いることで、装着感を統一しつつ、足関節の固定有無によるNIRS信号の差を取得する。


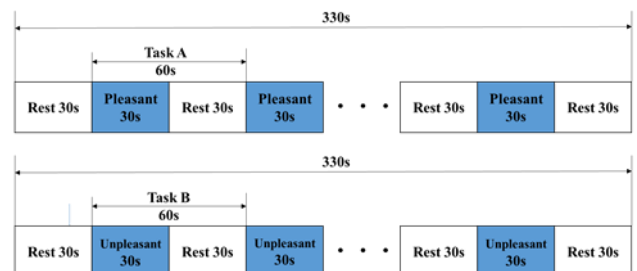


Fig.1 Left: Walking assist device A, Right: Walking assist device B

足関節部がフリージョイントで、足首が固定されていない歩行補助装具Aを右足に履いた状態を快条件歩行(TaskA)、足首が固定された歩行補助装具Bを右足に履いた状態の歩行を不快条件歩行(TaskB)と設定した。両条件ともに、左足は履きなれた靴を履いた状態で歩行している。この快・不快条件歩行の設定は、実際に被験者が装着した状態で歩き、その被験者の意見にも基づいて設定している。



Task A: Pleasant walking and Rest
Task B: Unpleasant walking and Rest
Rest: standing

Fig.2 Experimental design

実験デザインを図2に表す。各条件歩行とレストが交互に

続くブロックデザインになっており、各条件歩行が 30 秒間と各条件歩行後のレスト 30 秒間も合わせて、計 60 秒間のデータを 1 入力データとする。各歩行条件は、1 回の実験を通して 5 つの入力データを取得し、日を分けて計 5 回の実験、計 25 の入力データを取得する。

2.3 前処理

一般的に深層学習における学習データ数が多いほど学習の精度、汎化性が向上する。しかしながら、計測ノイズ、呼吸、Mayer 関連成分による影響を避けるため、歩行課題は 20 秒以上の連続した刺激を与える必要があること、実験を繰り返すことによる慣れを避ける必要があることから、実験データの数を増やすことが実用上困難である。

そこで、数の少ない NIRS 信号より、より精度良く歩行中の快・不快情動を識別するために、深層学習の入力データの質を向上させることを目的とした 3 ステップの前処理を行う。

まず、計測ノイズ、測定中に生じる低周波トレンドなどの影響を除外する目的で、離散ウェーブレット変換による多重解像度解析を行う。

NIRS 信号は歩行中の Hb 濃度変化を時系列データとして取得するが、前述のとおり計測プローブが 16ch 存在するため、一度の歩行時の計測で全 16ch の情報を得ることができる。しかし、この ch 間は、同一の被験者、同一条件であっても値のばらつきが大きいといった問題がある。そのため、ch ごとに Zscore を用いて標準得点化し、ch ごとの値のばらつきを抑制した。ここで、Zscore は平均が 0、標準偏差が 1 になるように変換した得点である。

その後、全 ch の情報を識別に用いるため、ch4-ch19 までの 16ch を図 3 のように、左から ch4-ch19 の順で並べることで 1 つの入力データに全 ch 情報を含ませた。

5Hz のサンプリング周波数で 1 つの入力データが 60 秒間測定した時系列データであるため、1 つの ch に 300、16ch 合わせて 4800 の値が 1 つの入力データに収まっていることになる。




Fig.3 Input data for deep learning

2.4 深層学習

前処理した入力データを、DBN を用いて快・不快条件歩行に識別する。その際、各歩行条件の入力データは学習・評価データが 8:2 になるようにランダムに振り分ける。

DBN の中間層は 2 層、error rate は 0.1 と設定し、error rate が 0.1 以下になるまで学習を繰り返した。

一般的に NIRS 信号は、分割した ch の同一性等の問題のため、被験者による差が大きく表れることがある。そのため、個人学習と集団学習を行った場合には、複数被験者が対象で

ある集団学習の識別率が下がると予測される。しかし、深層学習の前提として、データ数が多いほど学習の精度が上がることで、さらに、複数被験者の NIRS 信号を用いることで汎化性の向上が期待できる。そのため、本研究では、個人学習と集団学習の両識別結果を比較し、集団学習においても高い精度の識別が可能であるかを確認する。

3. DBN による快・不快歩行条件の識別結果

表 1 に個人学習の結果を表す。ここでは、ウェーブレット変換を用いない前処理と、ウェーブレット変換を使った前処理をした場合の結果を示す。個人学習の結果では、被験者 A だけの入力データを用いて学習・評価、B だけの入力データを用いて学習・評価、C だけの入力データを用いて学習・評価を行った場合の各学習における評価データの識別率、被験者 3 名の平均識別率を条件毎に示している。RBM(Restricted Boltzmann Machine)は 1st, 2nd とともに試行錯誤的に決定したハイパーパラメータである。

表 2 に集団学習の結果を表す。ここでも、ウェーブレット変換を用いない前処理と、ウェーブレット変換を使った前処理をした場合の結果を示す。集団学習の結果では、被験者 A, B, C の 3 被験者入力データを用いて学習を行い、各被験者の評価データの識別率、被験者 3 名の平均識別率を条件毎に示している。表 1 と同様に、RBM は 1st, 2nd とともに試行錯誤的に決定した。

Table 1 Individual learning

	Subject	Hyper parameter		Result(accuracy rate[%])		
		RBM 1st	RBM 2nd	Normal walking (Pleasant)	Ankle fixed walking (Unpleasant)	Average accuracy rate
Not use wavelet translate	A	870	600	60	100	80
	B	300	200	20	100	60
	C	870	620	60	60	60
	Average			47	87	67
Use wavelet transrate	A	870	620	100	100	100
	B	300	200	60	100	80
	C	200	100	60	100	80
	Average			73	100	87

Table 2 Group learning

	Subject	Hyper parameter		Result(accuracy rate[%])		
		RBM 1st	RBM 2nd	Normal walking (Pleasant)	Ankle fixed walking (Unpleasant)	Average accuracy rate
Not use wavelet translate	A	870	620	40	20	30
	B			20	60	40
	C			40	80	60
	Average			33	53	43
Use wavelet transrate	A	500	200	40	80	60
	B			100	100	100
	C			100	80	90
	Average			80	87	83

表 1 の識別結果と表 2 の識別結果を被験者平均より比較すると、ウェーブレット変換を用いない前処理では表 1 の個人学習が、表 2 の集団学習よりも高い精度の識別ができていた傾向にある。ウェーブレット変換を用いた前処理では、どちらの深層学習においても 80%以上と高い精度の識別ができていた。ウェーブレット変換を用いた前処理を入力データに行うことで識別率向上が可能となり、個人学習と集団学習間でウェーブレット変換の前処理を行わない場合で生じてい

た識別率の差を減少させることに成功した。

以上の結果より, ウェーブレット変換と Zscore による前処理を行うことで, 快・不快情動を想起させる歩行条件時の NIRS 信号から, 80%以上の高い識別率で歩行状態を識別可能であると確認された。

4. 結言

本研究では, 歩行時の快・不快情動によって生じる脳機能賦活から情動を識別する手法を確立するという目的で, 快・不快情動を想起させる歩行条件を設定し, 各歩行条件時の NIRS 信号から深層学習を用いて, 快不快情動の識別を行った。その結果, ウェーブレット変換と Zscore を用いた前処理を行うことで, 被験者ごとの NIRS 信号, 全被験者の NIRS 信号のどちらを用いても, 80%以上の識別率で快不快情動の識別が可能となった。以上のことから, 深層学習による歩行時の情動識別は, 多くの学習データを取得することが困難かつばらつきの大きい NIRS 信号を用いた歩行時の情動識別に有効であるという見通しを得た。

参考文献

- (1) 野村 理朗 情動 脳科学辞典 DOI : 10. 14931/bsd. 3050
- (2) 浅野 裕俊, 弘重 暁, 井出 英人, ”機能的近赤外分光法を用いた快-不快音聴取時の脳活動評価”, 電気学会論文誌. C, 電子・情報・システム部門誌 Vol 131, No. 1, pp. 70-75(2011)
- (3) 山本修一, 柳沢一機, 綱島均, ”NIRS を用いた快・不快画像呈示時の脳活動の評価に関する研究”, 日本大学生産工学部 第 45 回学術講演快概要, pp173-176(2012/12/1)
- (4) 矢倉佳祐, 芝田京子, 園部元康, 井上吉雄, ”光トポグラフィを用いた歩行における快・不快情動の推定システム”, 日本機械学会 中国四国学生会 第 48 回学生員卒業研究発表講演会, S112
- (5) 酒屋薫, NIRS -基礎と臨床- 株式会社新興医学出版社 (2012)