

# N-back 課題時における CNN と LSTM を用いた fNIRS 時系列データの識別と関連部位の推定

The classification of fNIRS time-series data during N-back task and the estimation of related regions using CNN and LSTM

玉城 貴也\*<sup>1</sup>  
Takaya TAMAKI

日和 悟\*<sup>1</sup>  
Satoru HIWA

蜂須賀 啓介\*<sup>2</sup>  
Keisuke HACHISUKA

奥野 英一\*<sup>2</sup>  
Eiichi OKUNO

廣安 知之\*<sup>1</sup>  
Tomoyuki HIROYASU

\*<sup>1</sup>同志社大学大学院生命医科学研究科

Graduate School of Life and Medical Sciences, Doshisha University

\*<sup>2</sup>株式会社デンソー

DENSO CORPORATION

We developed a machine-learning algorithm to extract the ROIs of human brain. CNN and LSTM were utilized to classify cerebral blood flow changes measured by fNIRS. The number of units in an input layer was equivalent to that of fNIRS measurement channels, and the units were placed according to the channel location to correspond to the brain surface. fNIRS data during N-back task (N=2,3) were input to our algorithm, and it was optimized to classify the workload of task. We achieved the classification accuracy of 91.4%. Moreover, we input a single channel data to corresponding unit of obtained classifier as well as inputting zero to other channels. This procedure was repeated for all channels, and the ROIs correspond to channels with better classification accuracies were identified as task-related ROIs. We successfully extracted DLPFC and APFC as task-related ROIs.

## 1. はじめに

近年、脳機能計測手段の一つとして fNIRS (functional Near Infrared Spectroscopy) が注目を集めている。fNIRS とは近赤外光を用いて計測した脳血流変化量により、脳の神経活動を推定する脳機能イメージング技術である。

しかし、fNIRS の信号は体動変化や心拍などの影響によるノイズが含まれており、このノイズの除去には明確な基準がなく、現状では解析者の判断に依存している。さらに、得られた信号値は測定開始時からの相対変化であり、被験者間の比較が難しく、課題に関連した特徴量を抽出することは容易ではない。

よって、本研究では脳活動データから特徴量を自動で抽出し、課題に関連した活動を示す脳部位を推定することを目的とする。そのために、脳機能の局在性と fNIRS の信号が時系列であること考慮し、Raw データから計測位置や時系列の関係を保持した特徴量抽出を行う必要がある。そこで着目したのが機械学習アルゴリズムの一種である CNN (Convolutional Neural Network) [LeCun 98] と LSTM (Long Short-Term Memory) [Hochreiter 97] である。CNN は入力データの位置関係を、LSTM は時系列の関係を保持したまま特徴量を自動で抽出することが可能である。この 2 種類のアルゴリズムを組み合わせることで、脳活動データから特徴量を自動抽出する機械学習器を生成する。また、この学習器を用いた課題に関連した活動を示す脳部位の推定方法を提案する。

本稿では提案手法の有用性を示すために、ワーキングメモリ課題の一種である N-back 課題に対して検討を行った。N-back 課題時 (N=2,3) の脳血流変化量を fNIRS 装置により計測し、提案手法を用いて Raw データから課題難易度の識別及び関連する脳部位の推定を行った。

## 2. CNN と LSTM を用いた関連部位の推定

課題に関連した活動を示す脳部位を推定するために、fNIRS データを識別可能な学習器を生成する。そして、生成した学習器に対して、脳部位に対応させた入力データの一部を再度入力した時の識別率を求めることで関連部位を推定する。以下にその具体的な識別方法と関連部位の推定方法を記述する。

連絡先: 玉城 貴也, 同志社大学大学院生命医科学研究科, 京都府京田辺市多々羅都谷 1-3, 0774-65-6130, ttamaki@mis.doshisha.ac.jp




図 1: 提案する学習器の全体構造

### 2.1 fNIRS 時系列データの識別

提案する学習器の全体構造を図 1 に示す。学習器の入力データは fNIRS で計測した時系列の脳血流変化量である。この入力データに対して、前処理なしに CNN の畳み込み処理のみを繰り返し行い、計測時の位置関係を保持しながら識別に必要な特徴量を自動抽出する。プーリング処理を除くのは、脳機能には局在性があり、画像のように多様な幾何的变化を考慮する必要がないためである。そして、抽出した特徴量を LSTM によって、時系列の関係を保持しながら自動で特徴量を抽出する。LSTM により抽出した特徴量を平均化するために、Mean Pooling を行う。出力層では平均化した特徴量を Softmax 関数によって正規化することで識別を行う。平均化する前の層ではなく、平均化した後に正規化を行うのは、特定の時間領域における重要な特徴量が他の時間領域との平均化によって失われるのを避けるためである。最後に、出力と教師信号の差が小さくなるように、最適化アルゴリズムを用いてフィルタの重みや閾値などのパラメータの更新を行う。こうして学習によりパラメータを最適化することで、Raw データから特徴量を自動で抽出することができる。

### 2.2 関連部位の推定方法

2.1 でパラメータの最適化を行った後の学習器を用いて、関連部位の推定を行う。まず、入力するテストデータを学習器の第一層目で畳み込む領域と同じ領域で分割し、1 つの領域のみを新たなテストデータとして、学習終了後の学習器に入力する。そして、選択しない領域の畳み込みの出力値は 0 とする。こうして、分割した領域ごとに再度識別を行う。識別の結果、より高い識別率を示す領域は課題に関連した活動を示す脳部位であると考えられる。以上が関連部位の推定方法である。

### 3. N-back 課題の難易度の識別と関連部位の推定

ヒトの脳には、情報の処理をしつつ、一時的に必要な情報の保持をする働きを担うワーキングメモリと呼ばれる領域が存在する。そして、N-back 課題とはワーキングメモリを用いる想起課題である。本実験では、N-back 課題時の脳活動データに提案手法を適応させ、本手法の有用性を検討した。

#### 3.1 データセット

使用したデータセットは N-back 課題 (N=2,3) 遂行時の fNIRS データである。実験はレスト 15[s], タスク 50[s], レスト 15[s] を 1 セットとして、2-back, 3-back をそれぞれ 4 セットずつ行った。計測装置は fNIRS 装置 (LABNIRS, 島津製作所製, サンプリング周波数: 37Hz) を使用し, 被験者数は 35 名 (年齢:  $23 \pm 1.5$  歳) である。計測部位はワーキングメモリに関わりがあるとされる前頭前野 (全 22CH) とした。

#### 3.2 課題難易度の識別と関連部位の推定

3.1 で示したデータセットを用いて, N-back 課題の難易度の識別を行った。学習器の構造は, 畳み込み層が 2 層, LSTM が 3 層, Mean Pooling 層, Softmax 層が各 1 層の合計 7 層の多層構造である。パラメータの更新回数は 44800 回とした。また, 識別結果の妥当性を検証するために, 5-fold cross validation による交差検証を行った。

学習終了後, 畳み込み処理を行った 8 つの領域のうち 1 つのみを選択し, 2.2 の方法により, 課題の難易度差が影響を及ぼす脳部位を推定した。

#### 4. 結果・考察

識別の結果, 提案手法による課題難易度の識別率は  $91.4 \pm 1.49\%$  となり, 極めて高い精度で識別ができた。つまり, 提案手法により, 脳活動データから課題に関係する脳血流変化の特徴を自動で抽出可能であることがこの結果により示された。

推定結果を図 2 に示す。畳み込み処理を行った 8 つの領域において, 領域 ⑧ に近づくにつれて識別率が高くなり, 反対側に位置する領域 ① では, 最も低い識別率となっている。このことから, 学習器は識別するにあたって, 全てのチャンネル情報を用いているのではなく, 選択的に入力データの特徴を多く含む重要なチャンネルを捉えて識別をしたのだと考えられる。提案手法を用いることにより課題に関係する重要な領域を順位付けてみるのが可能となった。そして, 最も識別率が高い領域 ⑧ では識別率  $91.4 \pm 1.34\%$  であった。この結果から N-back 課題の難易度差により脳活動に最も影響を受けた部位は領域 ⑧ であると考えられる。そして, この領域 ⑧ は, 左脳の前頭前野背外側皮質 (Dorsolateral Prefrontal Cortex: DLPFC) と前部前頭前野 (Anterior Prefrontal Cortex: APFC) にあたる部位である。DLPFC は多くのワーキングメモリ課題や認知課題で活性化し, 情報の処理と保持をワーキングメモリ容量の制約の中で調整したり方略を適応することなど認知的制御の心的機能に関わることが知られている。特に左脳の DLPFC は言語性ワーキングメモリの注意保持, 思考, 判断や問題の解決などで活性化することが多くの研究から示されている [Smith 97]。そして, APFC は極めて抽象的な情報が脳内表現されている領域であり, 二重課題で DLPFC と同様の活性化を示すことが明らかになっている [Narender 04]。N-back 課題についても, 課題難易度差において DLPFC と APFC で賦活の差があると報告された事例が数多く存在することから [Owen 05, Katrin 14], 提案手法による推定結果は妥当であることが示された。以上の




図 2: 畳み込み処理を行った領域ごとの識別率

ことから提案手法が fNIRS データの脳機能解析手法として有効であることが示された。

#### 5. まとめ

本研究では脳活動データから特徴量を自動で抽出し, 課題に関連した活動を示す脳部位を推定することを目的とした。そのために, 脳活動データから特徴量を自動抽出する機械学習器およびその学習器を用いた脳部位の推定方法を提案する。

本稿では提案手法を用いて N-back 課題 (N=2,3) の難易度の識別と関連部位の推定を行った。識別の結果, 特徴量を自動で抽出し,  $91.4\%$  という極めて高い識別率で識別が可能になった。そして, 学習終了後の学習器に入力の一部を再度入力することで, N-back 課題の難易度差に対する関連部位の推定を行った。その結果, 課題難易度差により脳活動に最も影響を受けたのは DLPFC と APFC にあたる部位であった。さらに, N-back 課題の難易度差において DLPFC と APFC で賦活の差があると報告された事例が数多く存在することから, 提案手法による推定結果は妥当であることが示された。

以上のことから, 提案手法を用いることで, 特徴量を自動で抽出し, 課題に関連した活動を示す脳部位を推定することが可能であり, fNIRS データに対する脳機能解析手法として有効であることが示された。

#### 参考文献

- [LeCun 98] Y.LeCun: Gradient-based learning applied to document recognition, Proceedings of the IEEE, Vol. 86, pp. 2278-2324 (1998)
- [Hochreiter 97] S.Hochreiter: Long short-term memory, Neural computation, Vol. 9, pp. 1735-1780 (1997)
- [Smith 97] Edward E.Smith, J.Jonides: Working memory: A view from neuroimaging, Cognitive psychology, Vol. 33, pp. 5-42 (1997)
- [Narender 04] R.Narender, Adrian M.Owen:Anterior prefrontal cortex: insights into function from anatomy and neuroimaging, Nature Reviews Neuroscience, Vol. 5, pp. 184-194 (2004)
- [Owen 05] Adrian M.Owen: N-Back Working Memory Paradig:A Meta-Analysis of Normative Functional Neuroimaging Studies, Human Brain Mapping, Vol. 25, pp. 46-59 (2005)
- [Katrin 14] C.Katrin: Increased neural activity during high working memory load predicts low relapse risk in alcohol dependence, Addiction biology, Vol. 19, pp. 402-414 (2014)