

脳血流変化量に対する Deep Learning を用いた 被験者の状態分類の基礎的検討

Fundamental study of the state classification of subjects
with Deep Learning to cerebral blood flow changes

埴 賢哉*¹
Kenya HANAWA

福島 亜梨花*¹
Arika FUKUSHIMA

山本 詩子*²
Utako YAMAMOTO

廣安 知之*²
Tomoyuki HIROYASU

*¹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

*²同志社大学生命医科学部

Faculty of Life and Medical Sciences, Doshisha University

In this paper, the gender of subjects is classified using Deep learning from the cerebral blood flow changes which are measured by fNIRS. It is report that the cerebral blood flow changes are occurred by brain activities. Thus, if this classification has a high searching accuracy, fNIRS data should be related to brain activities. In the experiment, fNIRS data is derived by the subjects who perform a memory task in white noise environment. From the results, the learning classifier which has a high accuracy is derived. This fact suggest that there exists the relation between cerebral blood flow changes and biological information.

1. はじめに

近年、非侵襲である脳機能イメージング装置の一つとして fNIRS(functional Near Infrared Spectroscopy) 装置が注目を集めている。fNIRS 装置は脳血流変化を高い時間分解能でリアルタイムに計測することができ、fMRI(functional Magnetic Resonance Imaging) や PET (Positron Emission Tomography) よりも安価である。また測定時の被験者の拘束が少ないため、自由度の高い実験設計ができる [Takeda 08]。

しかし、fNIRS による計測では脳内の光路長が不明確であるため、脳内のヘモグロビン濃度を定量的に計ることができない。また、fNIRS の信号は複数の要因により変化するため、研究者による解釈が一義的でないことが大きな問題である [Hoshi 05]。これらのことは fNIRS が世界的にまだ fMRI や EEG のように高い信頼性が得られていない一因である。そこでまず脳血流変化量が生体的にどのような意味があるのか、ないしは、意義の有無を確認する必要がある。

本稿では、計測された脳血流変化量が生体的な意味を持つかを検討するために脳血流変化に関係が深いことが報告されている音環境における脳血流データを用いる。音環境が知的活動に与える影響についての研究は数多くある [Yamanaka 89, Yamanaka 04, Souma 05]。先行研究では、音環境が知的作業に及ぼす影響の男女差について検討している。音環境には、静音、ピンクノイズ、ホワイトノイズを用い、知的作業には数字記憶課題を用いている。その結果、ホワイトノイズの音環境において、課題成績への影響に男女差が見られたことが報告されており [Masadumi 13]、課題時の男女の脳機能には何らかの違いがあると考えられる。そこで本稿では、機械学習アルゴリズムの一つで、Neural Network(NN) の一種である Deep Learning を用いて、数字記憶課題時の脳血流変化の時系列データのみで男女の識別を行い、脳血流変化量の生体的意義を検討することを目的とする。

2. Deep Learning

Deep Learning とは、多くの層を持った NN を用いる機械学習のアルゴリズムである。Deep Learning の学習は主に pre-training と fine-training に分かれる。pre-training とは、入力層に近い層から順に各層において教師なし学習を用いて重みの初期化を行う前処理のことである。また、fine-training では主に誤差逆伝搬法 (Back Propagation) を用いる。

前処理を行うことで入力側の特徴量を効率よく出力側に伝搬できると考えられている [Erhan 10]。そして、その後に誤差逆伝搬法を用いたときに出力層の誤差の拡散を防ぎ、より良い解を得ることができる [Rifai 11]。本稿では pre-training の手法として、Denoising Autoencoder を用いる。

2.1 Denoising Autoencoder

Denoising Autoencoder とは入力の一部をランダムに破損させて、それを元の入力に修復させるために再構築を行うことで訓練される。これは、最初に確率的マッピング $Cr(\tilde{x}|x)$ によって、元の入力 x を $\tilde{x}$ に破損させる事によって行われる。その後、破損した入力 $\tilde{x}$ は、シグモイド関数 f_s を用いて y に写像される。またこの写像は encode と呼ばれる。

$$y = f_s(W\tilde{x} + b) \quad (1)$$

ここで、 W は d' 次元 $\times$ d 次元の重み行列であり、 b は d' 次元ユニットのバイアスである。そして写像された y は再びシグモイド関数を用いて再構築するために z に写像される。この写像は decode と呼ばれる。

$$z = f_s(W'y + b') \quad (2)$$

W' にはよく W の転置行列が用いられる。また、 b' は d 次元ユニットのバイアスである。パラメータ (W , b , b') を再構築した際の z を元の入力 x 近づくような値に設定する。すなわち、学習データによって再構築した際の z と元の入力 x の誤差が最小になるように学習する。誤差関数には交差エントロピー $L_H(x, z)$ が用いられる [Vincent 10]。

$$L_H(x, z) = -x \log z - (1 - x)(1 - \log z) \quad (3)$$

パラメータをランダムに初期化した後、確率的勾配降下法 (Stochastic Gradient Descent) によって誤差が最小になるように最適化される。

連絡先: 埴 賢哉, 同志社大学大学院生命医科学研究科, 京都府 京田辺市多々羅郡谷 1-3, 0774-65-6130, khanawa@mis.doshisha.ac.jp

$$W^{new} = W^{old} - \frac{\eta}{N} \sum_{n=1}^N \frac{\partial L_H}{\partial W} \quad (4)$$

$$b^{new} = b^{old} - \frac{\eta}{N} \sum_{n=1}^N \frac{\partial L_H}{\partial b} \quad (5)$$

$$b'^{new} = b'^{old} - \frac{\eta}{N} \sum_{n=1}^N \frac{\partial L_H}{\partial b'} \quad (6)$$

なお, η は学習係数, N は入力データ数を表している [Vincent 08]. 図 1 に Denoising Autoencoder の処理の流れを示す. また, Denoising Autoencoder を用いて, 全ての層の重みの初期値を設定する手法は Stacked Denoising Autoencoders と呼ばれる. このようにあらかじめ教師なし学習で重みとバイアスを調整することで NN よりも遥かに巧妙な学習を行うことができる.




図 1: Denoising Autoencoder

2.2 Deep Learning の処理の流れ

次に Deep Learning を行う際の処理の流れを示す.

step.1 各層の初期化

任意の K 層のネットワークを構築し, 乱数を用いて各層間の重みを初期化する.




図 2: step1. ネットワークの構築

step.2 pre-training (Stacked Denoising Autoencoders)

初めに, 入力側に最も近い中間層である第 2 層目と第 3 層目の間の重みの調整を行う. 重みの調整には前節で示した教師なし学習である Denoising Autoencoder を用いる. 次に, 第 2 層目と第 3 層目の重みを固定し, 同じように第 3 層目と第 4 層目の間の重みの調整を行う. 第 3

層目の入力信号には, 固定した際の重みを用いた第 3 層目の出力信号を用いる. 以降同じ処理を $K-1$ 層まで行う.

step.3 fine-training (Back Propagation)

最後に誤差逆伝搬法によりネットワーク全体の重みの調整を教師あり学習を用いて行う.

3. Deep Learning を用いた脳血流変化量による男女の識別

本稿では, ホワイトノイズ音環境下における短期数字記憶課題において男女の脳血流変化の違いから機械学習の一種である Deep Learning を用いて男女の分類の検討を行うことを目的とする.

3.1 使用データ

使用する fNIRS データを以下に述べる. fNIRS 装置 (ETG-7100, 日立メディコ製, サンプル周波数: 10Hz) を用いて脳血流変化を計測した. 被験者は成人男性 11 名 (平均年齢: 22.5 ± 1.5 歳, 利き手: 右, 1 名のみ左), 成人女性 11 名 (平均年齢: 22.5 ± 1.5 歳, 利き手: 右) である. なお, 計測は室温 $22.4 \sim 25.1$ °C, 湿度 40~61 % の環境で 11:00 ~ 17:00 の時間帯に行った. fNIRS 装置のプロープは国際 10-20 法に従い配置した. また, 本稿ではホワイトノイズ (音圧レベル 65.0 ± 0.5 [dB]) を音刺激として与えたときの数字記憶課題に対する脳血流変化より男女を分類するため, 先行研究で男女の脳血流変化の違いが報告されている左側頭部の下前頭回 (4CH 分) の酸素化ヘモグロビン濃度変化のデータを使用する [Masadumi 13]. 使用した CH(3,6,7,10) の部位を図 3 に示す. また, データ区間は途中で体動と考えられるノイズが見受けられたので, 比較的安定していた課題開始時から 60 秒間の脳血流変化を用いる.




図 3: 左側頭部のチャンネル (CH) の配置

3.1.1 計測の流れ

計測は, 知的作業時にホワイトノイズを提示し, 安静時は静音状態を保つようにした. 課題の提示は, ノートパソコンに接続した液晶ディスプレイで行い, ディスプレイの左右に設置したスピーカを通して音を出力した. 知的作業として行った数字記憶課題は, 被験者により知的作業の終了時間が異なるため, イベントデザインで設定した. 計測の流れを Flow1-6 と図 4 に示す.

Flow1. 安静: 30 秒間画面を注視しながら指を動かす.

Flow2. 作業 (記憶): ランダムに円形に表示される 8 個の数字を 3 秒間で記憶する.

Flow3. 作業 (保持): 1 秒間記憶を保持する.

Flow4. 作業 (入力): 記憶した数字を
順番通りに 7 秒以内に入力する。

Flow5. 作業 (繰り返し): Flow2-5 を 30 回繰り返す。

Flow6. 安静: 30 回秒間画面を注視しながら指を動かす。

ここで、計測の流れにおいての Flow2-5 の課題時をタスク区間、Flow1,6 の安静時をレスト区間とする。ローパスフィルタは 1.0Hz、移動加算平均処理のサンプルは 10 秒間に設定した。




図 4: 数字記憶課題の計測の流れ

3.2 データセット

左側頭部の 4CH 分の酸素化ヘモグロビン濃度変化から全被験者 22 人分の特徴量を抽出した。1 人分の特徴量の抽出には、数字記憶課題時の時系列データにおいて、各チャンネルの課題開始から 60 秒間の 2 秒間隔の平均値 (30 サンプル) 4CH 分を用いた。平均値を 2 秒間隔としたのは学習のための計算コストを少なくするためである。また、各チャンネルごとに min-max 正規化を行った。図 5 に抽出した被験者 1 人分の特徴量の例を示す。また、特徴量に対して識別を行うために男性を 0.0、女性を 1.0 の値でラベリングした。




図 5: 被験者 1 人分の特徴量の例

3.3 Deep Learning を用いた脳血流による男女分類

上記で示した脳血流変化量の特徴量を用いて、男女の識別を行った。入力層の各ニューロンには被験者 1 人分の抽出した特徴量を用い、出力層でラベリングされた値に近づくように重みの学習を行う。その様子を図 6 に示す。

識別する際の妥当性を検証するために被験者 22 人に対して 4-fold cross validation ^{*1}により交差検定を行った。また、課題を行っていないときの血流変化と比較するために安静時に対




図 6: 各ニューロンへの入力の様子

しても同様に特徴量を抽出して男女の識別を行った。そして、ネットワークの構造の違いは学習に影響を及ぼすことが明らかにされているため [A. Coates 11], 本稿では、より良いネットワークの構造を random walk^{*2}により選択できるようにした。本稿で利用した各パラメータ等を表 1 に示す。

表 1: Data information

Type	Parameters
Total dataset	22
Pre-training	Stacked Denoting Autoencoders
Fine-training	Back Propagation
Cross validation	4-fold cross validation
Threshold function	Sigmoid function

3.4 結果・考察

図 7 に最も識別率の高かったネットワークの構造を示す。ネットワークのニューロンの数は入力層では 120、中間層層は 3 層構造で入力側から 50、30、60 となり、出力層では 1 となった。




図 7: Network structure

図 8 に識別率の結果を示す。左側が安静時、右側が記憶課題時の脳血流変化量より男女を分類した際の識別率を示している。記憶課題時の男女の識別率は平均 81.67[%]であった。また、安静時の男女の識別率は平均 62.47[%]となった。このことより、数字記憶課題における脳血流変化量には男女の違いがあったものと考えられた。これにより fNIRS 装置で計測された複雑な脳血流時系列データには生体的な情報が反映されており、計測したデータのみを用いて被験者の分類ができる

^{*1} 標本群を 4 つに分割し、そのうちの 1 つをテスト事例とし、残る 3 つを訓練事例とする。そして、4 つに分割された標本群をそれぞれテスト事例として 4 回検証を行い、4 回の結果を平均して 1 つの推定を得る

^{*2} 次のパラメータを確率的にランダムに決定する方法




図 8: Comparison of identification rate

と考えられる。また、被験者の分類手法の一つとして、Deep Learning を用いる方法が有効であることも示唆された。

4. まとめと今後の展望

近年、脳機能イメージング装置の一つとして fNIRS 装置が注目を集めている。しかし、fNIRS 装置で計測された脳血流データは結果の解釈が一義的でないことや光路長の問題が解決されていないため、現状では脳血流変化量が脳機能を正確に反映しているのか判断することは難しい。そこで、本稿では、音環境時の数字記憶課題においての男女の違いを機械学習の一種である Deep Learning を用いて脳血流変化量によって識別することで脳血流変化量が脳機能を反映しているかの検討を行った。その結果、課題時において、約 81.67[%] の精度で fNIRS 時系列データのみを用いて男女の分類を行うことができ、課題時の男女の脳血流変化には違いがあるということが示された。このことより、計測された脳血流変化量は生体的な意味を持ち、NIRS 装置により脳機能を計測できる可能性が示唆された。今後は、異なる課題時における fNIRS データに対しても同様に被験者を分類することで fNIRS により計測された脳血流データの信頼性について検討していく。

参考文献

- [Takeda 08] 武田 湖太郎: 近赤外脳機能計測のリハビリテーション領域への応用における信号処理, 国際医療福祉大学紀要, Vol. 12, pp.72-78,2008.
- [Hoshi 05] 星 詳子: 機能的近赤外分光法: 限界と可能性, J Jpn Coll Angiol, Vol. 45, pp.61-67,2005.
- [Masadumi 13] A. Masadumi: Gender differences in influence of sound environments on performance of the memorizing numerical string task and cerebral blood flow changes, NeuroScience, 2013.
- [Erhan 10] D. Erhan, Y. Bengio, A. Courville, P. Manzagol, P. Vincent, and S. Bengio: Why Does Unsupervised Pre-training Help Deep Learning?, The Journal of Machine Learning Research, Vol. 11, pp.625-660,2010.
- [Rifai 11] S. Rifai, G. Mesnil, P. Vincent, X. Muller, Y. Bengio, Y. Dauphin, and X. Glorot: Higher Or-

der Contractive Auto-Encoder, Machine Learning and Knowledge Discovery in Databases Lecture Notes in Computer Science, Vol. 6912, pp.645-660,2011.

- [Vincent 10] P. Vincent, H. Larochelle, I. Lajoie, Y. Bengio, and P. Manzagol: Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion, The Journal of Machine Learning Research, Vol. 11, pp.3371-3408,2010.
- [Vincent 08] P. Vincent, H. Larochelle, Y. Bengio, and P. Manzagol: Extracting and composing robust features with denoising autoencoders, ICML '08 Proceedings of the 25th international conference on Machine learning, Vol. 307, pp.1096-1103,2008.
- [Yamanaka 89] 中山実, 清水康敬: 音環境が与える音読速度への影響と瞳孔面積変化, 日本音響学会誌, Vol. 45, pp.368-373,1989.
- [Yamanaka 04] 中山実, 清水康敬: 数字記憶課題における脳波への音環境の影響, 電子情報通信学会論文誌, Vol. J87-D-I, pp.420-423,2004.
- [Souma 05] 相馬洋平, 松永哲雄, 曾我仁, 内山尚志, 福本一朗: 音楽環境の違いによる作業効率に関する人間工学的基礎研究, 電子情報通信学会技術研究報告, Vol. 105, pp.43-46,2005.
- [A. Coates 11] A. Coates, H. Lee, and A.Y. Ng: An analysis of single-layer networks in unsupervised feature learning, The Journal of Machine Learning Research, Vol. 15, pp.215-223,2011.