

# 商品選好を用いた Brain Computer Interface の開発

## A Brain Computer Interface using Product Preference

参沢 匡将\*1

Tadanobu Misawa

後藤 かをり\*1

Kaori Goto

宮川 和大\*2

Kazuhiro Miyagawa

下川 哲矢\*3

Tetsuya Shimokawa

\*1 富山大学 大学院理工学研究部

Graduate School of Science and Engineering, University of Toyama

\*2 一橋大学大学院経済学研究科

Graduate School of Economics, Hitotsubashi University

\*2 東京理科大学 経営学部

School of Management, Tokyo University of Science

In recent years, development of functional neuroimaging technology has helped to reveal the activity of sites in the brain. This technology is used both in medicine as well as in the fields of economics and business, leading to studies in neuroeconomics and neuromarketing. The current study created a trial brain-computer interface (BCI) to assist with purchase decision-making. Specifically, the BCI was used in a system to show images of 2 products and show detailed information on the preferred product. Using fNIRS, this system acquires data in real time to measure brain activity, it preprocesses these data with a low-pass filter, and it differentiates preferences with a model using a support vector machine. Results of an experiment indicated that the trial BCI created in this study lacks adequate accuracy for practical use but they did indicate that experimental results could enough show the proposed method has potential performance.

## 1. はじめに

近年、脳画像技術の発展により、報酬予測などさまざまな認知活動に関する研究が行われている [Krajchich 10]。これらは経済活動における意思決定に応用され、ニューロエコノミクスとして研究が行われている [Ariely 10]。また、脳情報を利用した Brain-Computer Interface(BCI) の開発も活発に行われている。

本研究では、このようなニューロエコノミクス、BCI の発展を受けて、購買意思決定補助のための BCI を試作する。具体的には、消費者の脳情報を解析し、商品間の選好関係を認識し、より選好する商品に関する情報を提供するようなシステムである。このようなシステムは脳情報を利用したマーケティング情報の収集や新たなショッピングサイト設計など幅広い応用が視野に入る。また、このような意思決定補助のための BCI の開発は、マーケティング分野ばかりでなく、様々な分野で利用できることが期待される。

しかしながら、このような BCI を作成する際には実務で利用できることも十分考慮しなければならない。つまり、システムは小型かつ利用者に拘束性を課さない必要があり、リアルタイムの処理が必要であると考えられる。現在の脳機能の解明では fMRI を用いることが多いが、fMRI は大型かつ利用者に大きな拘束性を課すものであるため BCI には適していない。そこで、本研究では、fNIRS を用いる。fNIRS は小型であり拘束性が低い利点があり、無線化やさらなる小型化が進んでいる。また、fMRI より時間分解能が優れている。しかし、空間分解能は fMRI より劣っているため、脳情報が適切に取得可能であるかは検討する必要がある。これに関しては文献 [Shimokawa 08] において、fNIRS による選好に関する解析が行われており、fNIRS でも可能であることが示されている。

そこで、本研究では、fNIRS を用いた購買意思決定補助のため BCI の試作品を作成し、今後の可能性を検討する。

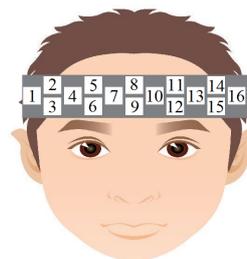


図 1: 測定箇所

## 2. Brain Computer Interface の試作

### 2.1 システム概要

本研究で試作する BCI の概要を述べる。

#### 2.1.1 測定

本研究で試作する BCI では、脳情報の測定に fNIRS (OEG-16: Spectratech 社製) を用い、図 1 に示す前頭前野の oxyHb 濃度変化を測定する (サンプリング間隔は 0.65sec)。前頭前野は頭髪の影響がなく、かつ装着も容易であるため、実務で使用するために適していると考えられる。図 1 では、センサの間隔は 3cm、ch9 が国際 10-20 法の Fpz に相当する。

#### 2.1.2 リアルタイムデータ転送

本研究では、計測された oxyHb 濃度変化データは、UDP (User Datagram Protocol) を用いて、リアルタイムに転送する。実務で使用するためにもリアルタイムでデータ転送できることは重要である。

#### 2.1.3 データ前処理

本研究では、転送された oxyHb 濃度変化データにはノイズ (例えば生体ノイズ) が含まれていることが考えられるため、ノイズ除去が必要である。そこで、データ除去のためのフィルタリング手法として、ローパスフィルタを採用した。

連絡先: 参沢匡将, 富山大学 大学院理工学研究部, 〒 930-8555  
富山県富山市五福 3190, misawa@eng.u-toyama.ac.jp

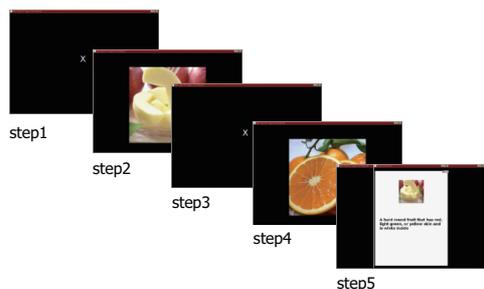


図 2: 商品選好タスク

### 2.1.4 学習

本研究では、被験者の選好を判別するために選好判別モデルを構築する必要があり、oxyHb 濃度変化データを用いた学習が必要である。実務で使用するためには、個人への対応などを考慮すると、学習機能が必要である。そこで、学習手法として oxyHb 濃度変化データを入力とするサポートベクターマシン (SVM) を用いた。SVM は学習データが少ない状態でも高い識別能力を持つため、実務的な面からも早い段階での適応が求められることから適していると考えられる。

### 2.2 タスク

本研究で用いるタスクは以下の手順に従う (図 2)。

#### 商品選好タスク

##### step1: レスト

oxyHb 濃度変化を安定させるため、5 秒間 'X' を表示する。

##### step2: 商品表示

2 種類の商品 (商品 1, 商品 2) の内、商品 1 を 5 秒間表示する。

##### step3: レスト

oxyHb 濃度変化を安定させるため、5 秒間 'X' を表示する。

##### step4: 商品表示

商品 1 とは別のもう 1 つの商品 2 を 5 秒間表示する。

##### step5: 詳細情報表示

被験者が選好すると思われる商品 (商品 1 または商品 2) についての詳細情報を 5 秒間表示する。表示された情報が不適切である場合には、変更することが可能であり、またどちらも選択しないことも可能である。

上記の step1 から step5 までを 1 タスクとし、本研究では 1 試行当たり 25 タスク行った。

上記タスク中において 2.1 で述べた機能がどのように動作しているか具体的に説明する。まず、測定は随時行われているが、oxyHb 濃度変化データの転送は step4 終了後に過去 64 サンプル分の oxyHb 濃度変化データを転送する。この転送された 64 サンプルの oxyHb 濃度変化データに対してローパスフィルタによりノイズ除去を行う。ノイズ除去された oxyHb 濃度変化データの内、商品 (商品 1 および商品 2) が表示されていた時の特定のチャンネルの oxyHb 濃度変化データを入力し、2 つの商品の内、どちらが好みかを SVM を用いて判別し、詳細情報を表示する。詳細情報表示終了後、表示した結果に対する被験者のレスポンスと、判別に用いた oxyHb 濃度変化データを



図 3: 実験の様子

表 1: 実験結果

Participant	Accuracy
A	0.57
B	0.53
C	0.53
D	0.87
E	0.53
F	0.53
G	0.67
Average	0.60

用いて SVM により学習を行う。この時、SVM はスレッド化されており、タスクの実行と並行して行われる。

### 3. 実験

2. で述べた試作 BCI を用いて実験を行った。被験者は、富山大学工学部の学生 7 名とし、商品画像は、好き嫌いがあり、またイメージが喚起しやすい食べ物を用いた。選好判別に用いるチャンネルは先行研究 [Shimokawa 08] を参考に、ch8, 9 とした。実験の様子を図 3、実験結果を表 1 に示す。表 1 は、タスク全 25 回の内、後半 15 回分の各被験者の判別精度である。表 1 より、被験者 D は 87% と高い判別精度となっているが、被験者 B, C, E, F は 53% と低い判別精度であり、平均すると 60% の判別精度であるため、十分な結果であるとは言えない。そのため、判別精度向上が必要であると考えられ、4. において考察を行う。

### 4. 考察

#### 4.1 oxyHb 濃度変化データ

まず、各被験者において実際にどのような oxyHb 濃度変化データが得られているかを図 4 に示す。図 4 は、横軸は画像表示時間、縦軸は好みの画像が表示された時の oxyHb 濃度変化データから好みでない画像が表示された時の oxyHb 濃度変

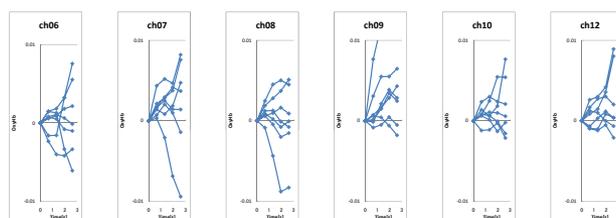


図 4: oxyHb 濃度変化

表 2: チャンネルの組み合わせによる判別結果

(1) 1 チャンネルの組み合わせ							(3) 3 チャンネルの組み合わせ			
Participant	Ch6	Ch7	Ch8	Ch9	Ch10	Ch12	Participant	Ch9,10,12		
A	0.38	0.46	0.78	0.53	0.41	0.76	A	0.37		
B	0.60	0.88	0.64	0.60	0.52	0.80	B	0.60		
C	0.52	0.40	0.40	0.40	0.76	0.40	C	0.68		
D	0.56	0.60	0.56	0.72	0.64	0.52	D	0.76		
E	0.28	0.52	0.52	0.64	0.40	0.76	E	0.52		
F	0.52	0.56	0.56	0.40	0.68	0.52	F	0.84		
G	0.60	0.72	0.68	0.72	0.64	0.56	G	0.88		
Average	0.48	0.59	0.59	0.57	0.58	0.62	Average	0.66		

(2) 2 チャンネルの組み合わせ										
Participant	Ch7,8	Ch7,9	Ch7,10	Ch7,12	Ch8,9	Ch8,10	Ch8,12	Ch9,10	Ch9,12	Ch10,12
A	0.58	0.50	0.33	0.47	0.44	0.70	0.54	0.45	0.67	0.59
B	0.76	0.68	0.80	0.68	0.64	0.68	0.72	0.48	0.56	0.60
C	0.40	0.60	0.72	0.56	0.36	0.48	0.40	0.48	0.76	0.68
D	0.56	0.68	0.64	0.68	0.72	0.48	0.52	0.56	0.68	0.56
E	0.36	0.52	0.44	0.56	0.56	0.56	0.52	0.44	0.56	0.60
F	0.60	0.52	0.56	0.40	0.32	0.72	0.48	0.84	0.60	0.64
G	0.64	0.56	0.48	0.56	0.64	0.40	0.64	0.60	0.68	0.84
Average	0.56	0.58	0.57	0.56	0.53	0.57	0.55	0.55	0.64	0.64

化データを引いた場合の平均値である。この時、画像が表示された時の oxyHb 濃度変化データを 0 として基準化している。また、先行研究より、選好に関係すると思われるチャンネル (ch6,7,8,9,10,12) のみを表示している。図 4 より、好みの画像を見たときの方が oxyHb 濃度変化データが減少する被験者もみられるが、全体として増加している傾向があることがわかる。よって、選好判別が oxyHb 濃度変化データから可能であると考えられるが、oxyHb 濃度変化の大きさなど被験者ごとに異なることから、判別精度向上のためには、個人差への対応が必要であることがわかる。

#### 4.2 オフライン分析 (1)

次に、被験者ごとにどのチャンネルが有効であるかを検証するために、各チャンネルのを SVM の oxyHb 濃度変化データを入力とした場合の判別精度について、オフラインで 5-fold cross validation にて分析を行った。具体的には 1 チャンネルを組み合わせさせた場合、2 チャンネルを組み合わせさせた場合、3 チャンネルを組み合わせさせた場合の 3 種類の組み合わせ方法について分析を行った。結果を表 2 に示す。表 2 (1) より、1 チャンネルを組み合わせさせた場合をみると、図 4 において最も特徴がみられにくいと考えられる ch6 は平均判別精度が 48% と 50% に満たないが、その他のチャンネルでは 57% 以上の平均判別精度が得られており、最大平均判別精度は ch12 の場合で 62% であることがわかる。そこで、6 チャンネルを除いた 2 チャンネルを組み合わせさせた場合について分析する。表 2 (2) より、2 チャンネルを用いた場合をみると、ch9,12 と ch10,12 以外の組み合わせは 1 チャンネルのみを用いた場合の最大平均判別精度 (62%) よりも平均判別精度が低下していることがわかる。よって、チャンネル数を増やすことによって必ずしも、判別精度が向上するわけではなく、どのチャンネルを用いるかの組み合わせが重要であることがわかる。次に、2 チャンネルの場合に平均判別精度の高かった 3 チャンネル (ch9,10,12) を用いて分析する。表 2 (3) より、3 チャンネルを組み合わせさせた場合をみると、平均判別精度は 66% となり、さらに判別精度が向上していることがわかる。1 チャンネルを組み合わせさせた場合

表 3: 3 種類の組み合わせによる判別精度の比較

Participant	Ch12	Ch9,12	Ch9,10,12	Max
A	0.76	0.67	0.37	0.76
B	0.80	0.56	0.60	0.80
C	0.40	0.76	0.68	0.76
D	0.52	0.68	0.76	0.76
E	0.76	0.56	0.52	0.76
F	0.52	0.60	0.84	0.84
G	0.56	0.68	0.88	0.88
Average	0.62	0.64	0.66	0.79
Std	0.15	0.07	0.18	0.05

と 2 チャンネルを組み合わせさせた場合を比較するとわかるように、不適切なチャンネルを用いた場合は平均判別精度の向上は期待できないため、本研究では判別に用いるチャンネル数は 3 チャンネルまでが適切であると考えられる\*1。上記で得られたチャンネル (測定部位) (ch9,10,12) は、先行研究 (文献 [Asano 11]) の結果と類似しており、妥当な結果であると考えられ、図 4 の結果とも整合性があると考えられる。

#### 4.3 オフライン分析 (2)

次に、被験者ごとの傾向をみるために、表 2 において、組み合わせ方法ごとの最大平均判別精度をまとめたものが表 3 である (2 チャンネルを組み合わせさせた場合は ch9,12 と ch10,12 が同じであるが、分散値の小さい ch9,12 とした)。表 3 では、3 種類の組み合わせ方法の最大値、および各組み合わせ方法の分散値 (std) もまとめている。表 3 から、まず被験者ごとの傾向をみると、組み合わせるチャンネル数が増加することに判別精度も増加する被験者 (D, F, G) と逆に組み合わせるチャンネル数が増加すると判別精度が減少する被験者 (A, B, E) に大きく分けられることがわかる (被験者 C は 2 チャンネル

\*1 小型化や学習時間の観点からも出来る限りチャンネル数は少ない方が良いと考えられ、4 チャンネル用いた場合の分析も行ったが、精度は向上しなかった。

表 4: 3 種類の SVM の切替による判別精度

Participant	Accuracy
A	0.76
B	0.72
C	0.68
D	0.68
E	0.76
F	0.84
G	0.88
Average	0.76

を組み合わせた場合に最大となる)。さらに、分散値は 2 チャンネルを組み合わせた場合が最も小さく、どの被験者にも適用しやすいことがわかる。本研究では、チャンネル数が増えることは、学習器 (SVM) に入力するデータ数が増えることになるため、学習モデルは複雑になるといえる。つまり、中程度の複雑さの学習モデル (2 チャンネルを組み合わせた場合) の場合が多く、多くの被験者に対してそれなりの判別精度を示し、複雑になる (組み合わせるチャンネル数が増える) ほど、増えたチャンネルに関するデータが、ノイズとなるか、学習に有効になるかが個人によって異なることがわかる。ここで、もし、各被験者ごとに 3 種類の組み合わせ方法から、最も良い判別精度となる組み合わせを選ぶことができたとして、平均判別精度は 79% となり、判別精度が大幅に向上することがわかる。この結果は、文献 [Luu 09] とほぼ同じ判別精度であるが、本研究はチャンネル数、画像表示時間、タスク数ともに文献 [Luu 09] よりも少なく、これは、BCI の小型化、被験者への負担軽減に貢献するものであると考えられる。

#### 4.4 オフライン実験

本研究ではさらに、4.3 の分析結果に基づき、実務で使用するために、リアルタイムに自動で 3 種類の組み合わせ方法 (学習モデル) から最適である組み合わせを求められるかをオフラインで検証した。つまり、上記 3 種類の組み合わせ方法 (1 チャンネルの組み合わせ (ch12), 2 チャンネルの組み合わせ (ch9, 12), 3 チャンネルの組み合わせ (ch9, 10, 12)) に対して SVM を作成し、過去の判別精度が高い SVM を用いて判別を行う。より具体的には、過去 2 回分の判別精度を比較し、最も良い判別精度をもつ SVM を用いる。この時、判別精度が同じ場合は、さらに過去 2 回分の判別精度を追加していく。すべての過去判別精度を用いても同じ場合は、SVM の判別値が最もよいモデルを用いる。上記手法による判別精度を表 4 に示す。表 4 より、すべての被験者が最もよい判別精度となる学習モデルを選択しているとは言えないが、半数以上の被験者 (4 名) は最もよい学習モデルを選択しており、残りの被験者も極端に判別精度が低下している現象はみられない。その結果、平均判別精度は 76% となり、高い判別精度を維持することが可能であることがわかる。

#### 4.5 今後の可能性

4.4 のように複数の学習モデルを切り替えることで、高い判別精度を得ることが可能であるため、すべての組み合わせ方法について切り替えることも考えられるが、無駄に学習モデルを増やすことはシステムに負荷をかける (計算量が増加するなど) ばかりでなく、リアルタイム動作にも影響があると考えられるため、できる限り少ない学習モデルを用いる必要があると考えられる。また、本研究では簡単な切り替え方法をもちいたが、さらに検討が必要であると考えられる。また、本研究で用

いた学習モデルである SVM はデータ数が増えると学習時間を要する問題点がある。そのため、SVM 数の増加や学習データの増加に対して、学習頻度を減らす (現在は 1 タスク (新しい oxyHb 濃度変化データの入力) ごとに学習しているが、例えば、5 タスクごとに学習する) などの工夫が必要であると考えられる。本実験の結果は、被験者数、タスク数などが少ないことから、オーバーフィッティングの可能性も否定できないが、今後の fNIRS を用いたシステムの実務での有効な使用の可能性を示唆できたのではないかと考えられる。

## 5. おわりに

本研究では、購買意思決定支援のための BCI を試作した。具体的には、商品選好を判別するシステムである。また、システムの実用化、小型化も視野に入れ、測定機器として fNIRS を用いた。実験の結果、平均判別精度は 60% であった。さらに、判別精度を向上させるために複数の SVM を切り替える手法を提案した。分析の結果、平均判別精度は 76% となり、1 つの SVM を用いた場合よりも約 10% の精度向上となった。また、測定チャンネル (部位) もある程度特定しており、これは実用化に向けてのハードウェアの小型化、無線化を後押しするものである。本研究で試作した BCI はまだ十分な判別精度であるとはいえず、実用化のためにはさらに判別精度向上が必要であるが、今後の可能性を十分示す結果となったと思われる。今後はさらに追加実験を行い、本モデルの検証を行うとともに、他の学習モデル (例えば、隠れマルコフモデル) などの検証を行い、判別精度向上を目指す予定である。

## 参考文献

- [Ariely 10] Ariely, D. and Berns, G. : Neuromarketing: the hope and hype of neuroimaging in business, *Nature Reviews Neuroscience*, Vol.11, pp.284-292 (2010).
- [Asano 11] 浅野裕俊, 斎藤良徳, 井出英人 : 前頭葉部の酸素化ヘモグロビン濃度を用いた味の嗜好評価, *電気学会論文誌 C Vol.131, no.1*, pp53-54 (2011).
- [Krajbich 10] Krajbich, I., Armel, C. and Rangel, A. : Visual fixations and the computation and comparison of value in simple choice, *Nature Neuroscience*, Vol.13, no.10, pp1292-1298 (2010).
- [Luu 09] Luu, S. and Chau, T. : Decoding subjective preference from single-trial near-infrared spectroscopy signals, *Journal of Neural Engineering*, 6, 016003 (2009).
- [Shimokawa 08] Shimokawa, T., Misawa, T. and Suzuki, K. : Neural representation of preference relationships, *Neuroreport*, 19, pp1557-1561 (2008).