

論文 Original Paper

ウェアラブル光トポグラフィーを用いた
授業時脳特性の測定と解析

大 浦 邦 彦*

Analysis of Blood Flow Measurement in Class by
Wearable Optical Topography

Kunihiko Oura*

Abstract: In this paper, measurement and analysis of blood flow in class are carried out using wearable optical topography (NIRS). NIRS is known for its ability to observe three kinds of hemoglobin densities, HbO, HbR and HbT. We used temporal data of HbO for analysis because it is said to reflect brain activity very well. The technique used in this paper is hierarchical decomposition analysis, which is one of the estimation methods of multivariable auto-regressive (AR) model. The result of this paper shows the possibility of estimating students' comprehension by equipment such as NIRS.

Key words: Blood flow measurement, NIRS, Multivariable auto-regressive model

1. はじめに

本論文では、授業時の学生の脳特性をNIRS（ウェアラブル光トポグラフィー）によって測定し、学生の授業態度や精神状態ひいては理解度等も考え合わせて解析また検討する。ここで解析法としては、脳特性のモデル化に一定の有効性が知られている階層型分解法を利用、モデル構造から評価する。これらの結果をもとに、学習者の理解度推定への可能性、さらに新たな教育支援システム開発への端緒を与えることを目的とする

2. ウェアラブル光トポグラフィーを用いた実験

2.1 実験装置

実験装置は、図1に示す近赤外スペクトロスコープ（ウェアラブル光トポグラフィー装置、日立国際電気エンジニアリング社製WOT-100）である。この装置では分子吸光係数の違いを利用し、2波長の近赤外光を用いて前額部の3種類のヘモグロビン濃度変化（酸化ヘモグロビンHbO、還元ヘモグロビンHbR、全ヘモグロビンHbT）を測定できる。サンプリング間隔は200msである。

同装置での測定チャンネル数はブロック数に応じて変わる。本論文で用いたものは6ブロック、合計16チャンネルであった。

チャンネル配置は図2に示す通りであり、図2の○で示す照射部と受光部の間隔が3cmであることから、空間分解能は約3cmである。なお装置によるチャンネル番号付けは4ch～19chとなっている。解析に用いたのは3種類のヘモグロビンのうちHbOのみとした。これは、多くの文献でHbOが最も良く脳活動変化を捉えるとされるためである。



図1 ウェアラブル光トポグラフィー装置
(日立国際電気エンジニアリング社製, WOT-100)




図2 チャンネル配置図（4chが右脳側、19chが左脳側）

* 国士舘大学 理工学部理工学科 健康医工学系
E-mail: kuni@kokushikan.ac.jp

2.2 実験内容

学生の脳活動を測定するため、図3に示すスケジュールで模擬授業を実施した。まず計測開始直後の2分間は開眼で安静、その後6分間の模擬授業、最後に2分間の開眼安静であった。授業中、学生はノートを取ることや発話することなく聴講した。つまり安静時と授業中の違いは、被験者である学生の前で授業が行われているかどうかという点のみであり、他の条件は全く同一としてデータを取得した。また授業内容は学生が大学で学んでいる専門科目とは異なり、これまであまり学生が興味




図3 実験スケジュール



図4 模擬授業風景



図5 ウェアラブル光トポグラフィーを装着して授業を受ける学生

を持たなかったと予想されるものとした。授業を6分間と短めに設定したのは、教室の湿度が高く10分を越えると発汗による測定精度低下を生じたことが理由である。模擬授業の実施風景を図4に、装置を装着した学生を図5に示す。実験には脳波計を装着した学生も参加したが、脳波については本論文で扱わないので言及しない。なお実験に際しては、書面により目的と内容、注意事項を十分に説明したのち、データ提供も含めて同意を得た。

3. 階層型分解法

ウェアラブル光トポグラフィーから測定されたデータの解析手法として、階層型分解法 (Hierarchical Decomposition Analysis, HDA) を用いる。この手法は、比較的多数の観測データから主成分のみを取り出し、多次元ARモデルにより表現したものをさらにパラメータ変換して階層構造 (上三角構造) にすることで、脳機能をモデル化するものとしてその有効性が知られている。HDAが提案された論文1) では、脳波を用いたてんかん症例の検出に適用された結果が報告され、著者による論文4) ではHDAを利用した脳機能マッピング法について提案された。

HDAの基盤は、主成分分析 (Principal Component Analysis, PCA) にある。HDAはPCAにより低次元化された時系列データを多次元ARモデルにより表現する際、PCAの非唯一性を解消すべく反復計算によって推定パラメータを階層構造に従うように変換したものである。以下、概略を説明する。

時系列データを $\{x_i(k)\}$ とする。データ長を N として測定チャンネル数を M とすれば、当然ながら $\{x_i(k)\}$ ($k = 1, \dots, N, i = 1, \dots, M$) となる。これらを並べた行列 $X = [x_1(k) \dots x_m(k)]^T$ にPCAを適用して寄与率の高いもののみ取り出す。これを (1) 式に表す。主成分数を P とすれば、 $X (M \times N)$ というデータ行列が $T (P \times N)$ のように低次元化されたことになる。なお低次元化する際の閾値は、文献1) にならって成分数の逆数 M^{-1} としてある。

$$X = C^T W T \quad (1)$$

(1) 式において、 $W (P \times P)$ は固有値を並べた対角行列、 $C (P \times M)$ が行方向に空間的重みを表す行列であり、 $T (P \times N)$ が主成分を表す行列である。

$T (P \times N)$ の各行は時系列データを表すため、 $T (P \times N)$ に対して多次元ARモデル (2) 式を構成する。

$$T_{p,n} = R_{p,n} + \mu_p + \sum_{q=1}^P \sum_{l=1}^L A_{q,p,l} T_{q,n-l} \quad (2)$$

ここで μ_p は成分の平均値、 $R_{p,n}$ は残差、 A はYule-Walker方程式から求めた R_{MLAR} (3) 式が最小となるよ

うなモデル係数である。なおモデル次数 l はAICより求められる。

$$R_{MLAR} = \sum_{q=1}^P \sum_{n=1}^N R_{q,n}^2 \quad (3)$$

これまでのステップにより、低次元化された主成分時系列にARモデルが得られるが、そもそもPCAから得られる T が非唯一解であるため、一意なモデルとすべくパラメータを変換する。まずARモデルにおける残差項 $R_{p,n}$ がARモデルの動的項となっており、 T が発生源ならば $R_{p,n}$ が無相関になるという仮定から、 $R_{p,n}$ を正規直交変換するような行列を求める。具体的には I を単位行列として、 $(KR)(KR)^T = I$ の成立する行列 K を求める。新たな時系列および推定パラメータは(4)により求められる。

$$T' = KT, \quad A'^T = KA^T K^{-1} \quad (4)$$

非唯一性の問題は(4)式の変換後でもまだ解決しないため、次に推定パラメータが階層構造と一致するような正規直交行列 Q を繰り返し計算により探す。なお階層構造とは各成分が未来とは無関係になるように、 T (T') が列方向に時系列となっている点を考慮して、パラメータ A を上三角行列としたもののことである。初期値 Q_0 を与え、 P 個の成分から選ばれた任意の軸に対して個々の回転 J を合成する。回転行列が Q である。

$$Q = J_{u_d, v_d}(\theta_{fd}) \cdots J_{u_1, v_1}(\theta_{d+1}) J_{u_d, v_d}(\theta_d) \cdots J_{u_1, v_1}(\theta_1) Q_0 \quad (5)$$

(5)式で $d = P(P-1)/2$ は主成分数 P だけ存在する空間上の軸のうち、2つを選ぶときの組み合わせ数、 f が繰り返し回数である。(6)式で表される R_{HD} が、設定さ

れた閾値よりも小さくなることが終了条件になる。これらより階層構造として、可能な限り上三角形式に近いパラメータ A_{HD} と階層成分 $T_{HD} = QT'$ が導かれる。

$$R_{HD} = \sum_{l=1}^L \sum_{p=2}^P \sum_{q=1}^{p-1} \left[(QA^l Q^T)_{p,q} \right]^2 \quad (6)$$

推定パラメータ(階層構造)の評価には、(7)–(9)式を用いる。アルゴリズムは(9)式の $R_{lower} \rightarrow 0$ となるように動くため、 R_{lower} が小さいほど階層構造に近づき、主成分が上位と下位のレベルに分かれて表現されていることになる。評価の目安となるのは R_{diag} も同様であり、この項が大きいと各主成分間の相関が小さいことが予想される。

$$R_{upper} = \sum_{\ell=1}^L \sum_{p=1}^{P-1} \sum_{q=p+1}^P A_{q,p,\ell}^2 \quad (7)$$

$$R_{diag} = \sum_{\ell=1}^L \sum_{p=1}^P A_{p,p,\ell}^2 \quad (8)$$

$$R_{lower} = \sum_{\ell=1}^L \sum_{p=2}^P \sum_{q=1}^{p-1} A_{q,p,\ell}^2 \quad (9)$$

4. 実験結果と考察

1名の被験者より得られた測定データを図6に示す。今回の実験では両端のch4およびch19に大きな測定誤差が認められたため、この2チャンネルを除く14個の時系列データを解析対象とした。定量的には、授業終了直前に教員から被験者に問いかけ(質問)があった時に反応が見られた以外、タスク間に大きな差異は認められず、次にHDAによる検討を試みる。




図6 観測データ (左から前休憩, 授業, 後休憩)

HDAの第1ステップとしてPCAを適用した結果を示す。図7が各タスクで寄与率を求めた結果である。授業と前後の休憩を別のタスクとして捉え、3つの異なるタスクで比較する。閾値により求めた主成分数は授業中に2、休憩は3となった。また特徴として、第2主成分以降の寄与率は概ね同程度の大きさであるが、授業中タスクの第1主成分のみ非常に大きいことが指摘される。授業中には集中することで、血流量も特定の成分が支配的となる傾向が見られると解釈される。ここで得られた主成分時系列を図8に示す。

推定モデル構築の前に、低次元化の影響を調べるべく観測値行列 X を再計算する。すなわち(1)式で分解された T に対し、寄与率により低次元化された行列を T_i とすると C^TWT_i が低次元化後の観測値行列となるから、 $\text{var}\{X - C^TWT_i\}$ により行方向に分散を求めれば、その大きさにチャンネル別の重要性が推測できる。分散が小さければ低次元化の影響が小さいことを示し、高い寄与率に対応するチャンネルと解釈できるからである。その結果を図9に示す。授業中では前額部中央(ch8-13)周辺の誤差が小さくなり、休憩は前・後とも誤差の小さいチャンネルが散在する形となる。これにより、授業中

には前額部中心部チャンネルのHbO寄与率が大きくなっている傾向が確認される。

低次元化した時系列 T_i を多次元ARモデルで表現し、パラメータ変換して最終的に得られたHDAの時系列を図10に示す。推定モデルに関わる諸値を表1に示す。

PCAの結果から、授業中は2次元、休憩は前後とも3次元のARモデルを構築した。まずモデル次数は前休憩と授業中が8、後休憩が4となった。次数は過去の値が影響を及ぼす長さに関係があると考えられ、授業前の緊張時から授業中までは比較的長い(サンプリングを考慮して1.6s程度)影響下にあったものが、授業後には半分程度に低下するという興味深い傾向が表れている。改めて指摘するまでもなく、これはNIRSで測定されたHbOについて得られた結果であり、神経活動に直接関係しないとされる脳血流HbOにおいても精神状態の影響が表れることを示唆するものである。

また推定パラメータについては、 R_{lower} の大きさなどから授業中の推定モデルが最も階層化されており、階層の低位および高位成分が明確となっている傾向が明らかとなった。階層構造の成立は、文献1)で脳波における源信号の存在と関連づけられて説明されており、これを




図7 寄与率グラフ (左から授業, 前休憩, 後休憩)




図8 主成分時系列
(上から授業中, 前休憩, 後休憩)




図9 主成分によるチャンネル別誤差評価
(上から授業中, 前休憩, 後休憩)

考慮すればHbOについても授業中は何らかの源信号が存在すると仮定して差し支えないと思われる。ただし授業中のモデルが完全に階層化されている訳ではなく、また休憩時モデルも一定の階層化が達成されていることから程度の差であり、より詳細な検討が必要とも考えられる。別のアプローチとして被験者数を増やしたのち、文献4)で提案された脳機能マップにより評価するのひとつの方法といえる。

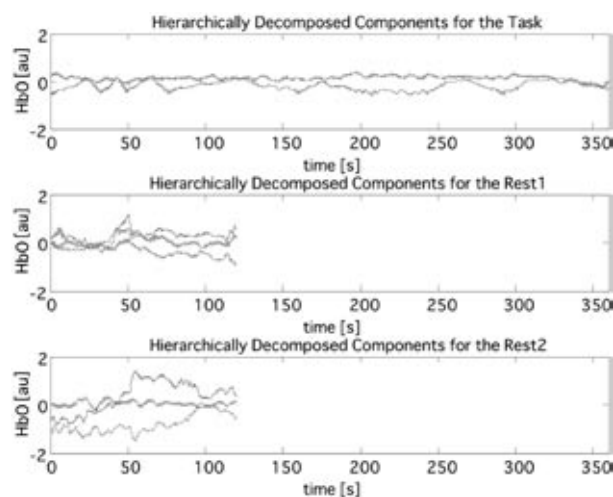


図10 階層成分時系列
(上から授業中, 前休憩, 後休憩)

表1 推定モデルの特徴比較

	授業中	前休憩	後休憩
主成分数	2	3	3
モデル次数	8	8	4
R_{upper}	-0.18	-0.31	-0.12
R_{diag}	2.87	2.91	2.22
R_{lower}	0.03	-0.12	-0.04

5. おわりに

ウェアラブル光トポグラフィーを用いて授業中の前額部脳活動（脳血流量）を測定し、多次元ARモデリングの一手法である階層型分解法により解析を試みた。その結果、授業中と休憩中は次元など異なる推定モデルとなるほか、推定モデルからは脳血流にも精神状態が反映されることが示唆された。特に本論文の主テーマである授業中に関しては、誤差評価から休憩中に比べ集中度が高く、また前額部の脳血流を司る源信号の存在することが予測された。本論文では1名の測定結果を解析したのみであり、正確な解析結果を得るには、より多くの被験者が必要であることは言うまでもない。しかし学習者の理解度推定に繋がる第一段階として、本論文で明らかにした内容は有効であると思われる。

参考文献

- 1) M.A.Repucci, N.D.Schiff and J.D.Victor "General Strategy for Hierarchical Decomposition for Multi-variate Time Series : Implications for Temporal Lobe Seizures", Annals of Biomedical Engineering, Vol.29, pp.1135/1149, 2001
- 2) Sarah-Jayne Blakemore, Uta Frith, 他「脳の学習力」岩波書店, 2006
- 3) 松本綱紀ほか「光トポグラフィ装置を用いたファジィ言語優位半球判定法」, BMFSA (14), 46-47, 2001.10
- 4) 大浦邦彦「階層型分解法による脳機能マッピングについての検討」, 電気学会論文誌C, Vol.129, No.9, pp.1675-1681, 2009
- 5) L.Kocsis, P.Herman and A.Eke "Mathematical model for the estimation of hemodynamic and oxy-genation variables by tissue spectroscopy", Journal of Theoretical Biology, Vol.241, Issue.2, pp.262/275, 2006