

時系列データ解析における
相互情報量の推定方法の検討

筑波大学

図書館情報メディア研究科

2018年3月

高山 凱久

目次

第1章 序論.....	1
1.1 研究背景.....	1
1.1.1 LFP.....	1
1.1.2 スパイク	2
1.1.3 ブートストラップ法	2
1.1.4 CRF.....	3
1.1.5 相互情報量	3
1.2 研究目的.....	4
1.3 関連研究.....	4
1.3.1 Benvenuti & Chavane のマカクザルを使った脳活動計測実験	4
1.3.2 Guo らのマカクザルを使った実験	5
1.3.3 Deep Learning を用いた画像認識	7
1.3.4 ML 推定による脳機能デコーディング	7
1.3.5 マウスの海馬についての実験	7
第2章 手法.....	8
2.1 相互情報量の算出	8
2.2 ブートストラップ法による検定	8
2.3 受容野の推定	9
2.4 主成分分析	9
2.5 k-means 法によるクラスタリング.....	10
第3章 結果.....	11
3.1 相互情報量の算出	11
3.2 ブートストラップ法による検定	12
3.3 受容野の推定	15
第4章 考察.....	19
謝辞.....	20
参考文献.....	21

第1章 序論

1.1 研究背景

ニューロンの発火（スパイク）など、離散的なデータに対する相互情報量の推定方法については、過去の研究で示されている[4]。一方 LFP などの時間的に連続したデータに対する推定方法については手順の煩雑さなどから敬遠され、あまり検討されていない。また、LFP からスパイクを取り出すためのスパイクソーティングと呼ばれる手法は、現在までに自動化が達成されていない。そのため、LFP から直接相互情報量が求められれば価値があると言える。

本研究では、時系列データを対象とし、相互情報量の推定方法について検討する。

1.1.1 LFP

LFP とは Local Field Potential の略で、局所フィールド電位と訳される。基準電極と対象とする電極との電位差を計測し、脳の活動を記録する[3]。膜電位の直接計測のように直接電極を接触させて測定せず、細胞外からの記録を行うため、測定が比較的容易である。

LFP は同時に複数のニューロンの活動を記録しているが、波形の違いを利用してソーティングすることでスパイク系列を取得することができる。LFP データは Utah array など多チャンネルを同時計測できる機器を使って計測される。単ユニットの計測ではないため、一つ一つの細胞に着目したい場合には不向きであるが、ニューロンは周囲のものと連動していることが多いので、周囲の動きについて同時に確認する本研究のような場合、スパイクよりも適していると考えられる。

以下に実際に計測された LFP データを例として示す。




図 1 LFP データ例

横軸は計測時刻、縦軸がその時刻での potential を表す。単位はそれぞれ ms、mV である。このように、計測された LFP は時間連続な波形データとして表示できる。実際の計測においては、この波形が多チャンネルで計測される。

1.1.2 スパイク

高インピーダンス（数 MΩ 程度）の電極などを単一のニューロンに接近させて、そのニューロンの活動を記録することを単一ユニット記録と呼ぶ。この時に測定される微弱な電位変化がスパイクと呼ばれる。

同時に複数のニューロンの活動を記録する場合は、LFP をスパイクソーティングと呼ばれる手法を使って分離することで取得できる。

1.1.3 ブートストラップ法

実験などで得られたデータは、後から追加することが困難であり、限られたものとなる。そのため、特徴量を求める際に統計的偏り（バイアス）が発生する。このバイアスを取り除く手法の内の一つがブートストラップ法である。

ブートストラップ法は、元のデータ（標本）から重複を許すランダム抽出を行い、新たにブートストラップ標本とする。こうして作られたブートストラップ標本から、目的の特徴量を推定する手法である[2]。ブートストラップ法についての説明を以下の図に示す。

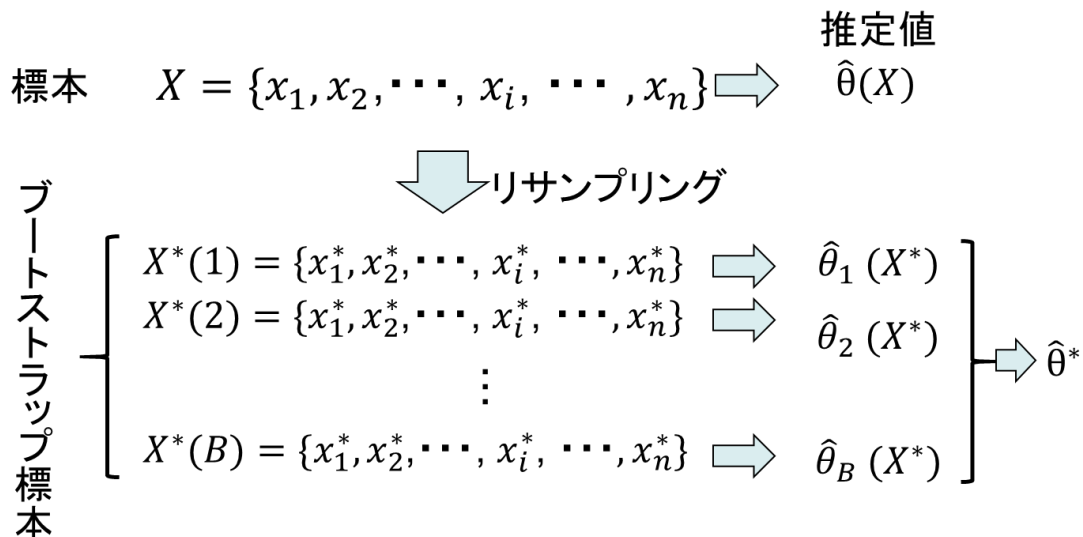


図 2 ブートストラップ法説明


例として、標本 $X = \{1, 2, 3, 4, 5, 6\}$ であったとき、 $X^*(1) = \{2, 3, 5, 5, 1, 2\}$ のように抽出される。必ずしも元データの全ての値が含まれるわけではなく、重複が存在するため、得られる

特徴量にばらつきが生じる。

1.1.4 CRF

Classical Receptive Field の略で、古典的受容野を指す。視覚野における視野とは個々のニューロンの受容野を合わせることで、認識できる範囲を表している。細胞ごとに反応する刺激が異なるが、特定の刺激が与えられたときに強い反応が見られる点は共通している。古典的と名がついているのは最近の研究で受容野の外側においてもニューロンに反応が見られることが明らかになってきたためである。視覚における受容野の例を以下の図に示す。第一層においては光の刺激の位置に対して反応し、発火する。第二層以降では、より複雑である形状や境界について認識を行っている。それぞれのニューロンに対して、受容野とパターンが一致する画像が入力として受け取られた時、より大きな反応が見られる。生物は画像を見たときにニューロンの発火の組み合わせによって、画像を基底画像の線形和として処理して認識している。符号化には発火の強さ、頻度、発火の有無が用いられる。

網膜の第一層



網膜の第二層以降




図 3 視覚系受容野の例

1.1.5 相互情報量

従来は、光のポイント刺激のような動きがない刺激に対しては、受容野の中でのみ反応が起こっていたため、ML 推定などを用いた復号によって刺激と反応の間関係をとればよいとされていた。しかし、移動する物体に対しては受容野の外においても反応することが発見され、復号できない範囲においても情報が伝わっている可能性が出てきた。本研究では移動する物体に対して生物が予測を行っているかを調べるため、刺激と反応の間の相互情報量を求める。これにより、復号では取得できなかった情報を得る。

$$I = \sum_{\theta, n} P(\theta)P(n|\theta)\log_2 \frac{P(n|\theta)}{P(n)} \quad (1)$$

式(1)は相互情報量の式である。 n には反応、 θ には刺激の方向 (direction) が入る。この値を求めることによって刺激と反応の間に従属性があるかを確認することができる。 $P(\theta)$ 、 $P(n)$ は非 0 であるため、 $P(n|\theta)$ が 0 のとき $I=0$ となる。 $P(n|\theta)$ は条件付き確率であり、 θ が起こるという条件下で n の起こる確率である。 $P(n|\theta)=0$ とは刺激 θ と反応 n とが互いに独立であることを示す。

1.2 研究目的

LFP データに対して、相互情報量の推定に必要な手順を既存の手法 (主成分分析による次元圧縮、クラスタリング等) の組み合わせによって確立する。使用する手法の中にはパラメータを設定する必要がある手法が存在する。結果が特定のパラメータに依存しているかを確認するため、パラメータを変更したときの結果についても同様に求める。

1.3 関連研究

本研究では、以下 1.3.1.にあげる関連研究で得られたデータを使用する。

1.3.1 Benvenuti & Chavane のマカクザルを使った脳活動計測実験

この実験ではマカクザルに対してディスプレイでバー刺激を提示した際の LFP データの測定を行っている。後述する Guo らが行った実験の方法を参考にして行われた。バーは 45° ずらした 8 方向から移動させる。short (受容野の中心からの距離 1.5°)、long (6.0°) の 2 つの条件を設定し、幅 0.2° のバーを CRF へ近づけたときの脳活動がどのように変化しているかを調べている。バー刺激は計測開始から 400ms の時点で提示される。それぞれについて試行回数は 15 回である。計測には Utah array とよばれる電極を利用し、計測されたチャンネル数は 96 である。この実験により、方向と距離が異なる条件のもとでニューロンがどのように反応を示したかを表すデータが得られている。

刺激を提示した方向を図 4 に示す。




図 4 刺激提示方向

Benvenuti & Chavane の実験で参考にされた Guo らによる実験[4]を以下に記す。

1.3.2 Guo らのマカクザルを使った実験

この実験ではマカクザルに対してディスプレイでバー刺激を提示した際の脳活動データの測定を行っている。測定には、タングステン製の微小電極が用いられている。CED1401 というデジタル機器を用いて増幅し、データをスパイクソーティングにより単ニューロンのスパイクに分離している。スパイクソーティングは、スパイク検出、特徴抽出、クラスタリングの3過程を経て、個別の細胞に由来するスパイク群(クラスター)に分類していく。クラスタリングには、KlustaKwik や EtoS などの無料で使えるソフトウェアが公開されている[12]。ここでは、Cambridge Electronic Design による Spike2 というソフトウェアを用いてソーティングを行っている。特徴抽出には、後述する主成分分析が使われ、重複したスパイクを分離する用途では独立成分分析 (ICA: independent component analysis)が用いられることもある。

まず、CRF のマッピングをするために、バーと格子パッチをディスプレイ上で動かすことにより位置および範囲の特定を行っている。与える刺激の幅、長さおよび動く速さを様々に変化させ、詳細に特定が行えるよう工夫がなされている。与えた刺激であるバーと格子パッチの参考図を以下に示す。




図 5 刺激の種類

CRF に入るとき、移動してきたバーの向き (orientation) が変化する場合 (incongruent) と変化しない場合 (congruent) で条件を変えている。2 つの条件を表した図を以下に示す。使われているバーの長さは 3° で、幅は 0.3° である。CRF の半径は 1.5° であり、直径がバーの長さとも一致する。




図 6 実験条件

この 2 つの条件を対比させて実験したのは、もし予測を行っているのであれば、予測していた通りに受容野に入る場合は反応が早くなる、あるいは発火する細胞の数が増加することが考えられるからである。これが正しいければ、ニューロン可塑性の仕組みによって伝達できる情報量が変わってくるので、相互情報量を求めた際に差がでてくる。

また、計測による誤差が起こらないか比較を行うため、CRF に入るときに消える (missing CRF)、CRF にのみ現れる (only CRF) パターンに加え、完全にランダムな方向から近づくパターンについても計測している。それぞれの条件において、バーは 30° ずらした 6 方向 ($0^\circ \sim 150^\circ$) から移動させる。刺激が提示される受容野からの距離は 12° (視野角) で固定である。

この実験では、スパイクデータに対して相互情報量の算出を行っている。スパイクについて相互情報量を求める場合は、1.1.3 の(1)に示した式の n にスパイク数を入れる。 n が増大するとサンプル数が不足してしまうため、試行数を増やす必要が出てくる。しかし、実験の後に試行数を増やすことはできないため、工夫が必要となってくる。ここで使われているのは一定の時間に生じたスパイク数によってクラスタリングを行う手法である。一定時間に生じたスパイク数が同数であれば同じ反応であるとみなす。この手法により相互情報量を求められている。元となったのは、Panzeri & Treves (1996) のサンプリングバイアスの除去手法である。試行数が、反応クラス数の 2~4 倍程度あれば、手法を適用でき、サンプリングバイアスを効果的に除去できると述べられている。Guo らは、この手法を相互情報量に対し

でも適用した。

congruent の条件と incongruent の条件間で情報量に 1.8bit/s 程度の差が見られ、大きな差があるといえる結果となった。これにより、一次視覚野において、物体の移動方向についての予測が行われていることが示唆された。

1.3.3 Deep Learning を用いた画像認識

ニューラルネットワークは人間の脳を模して作成されている。特に Deep Learning で学習されるフィルタは、受容野に対応している。重み付けを行い、入力画像をフィルタリングするが、この重みを学習によって習得し、適切な判別を可能とする。

人の脳でも行われていることであるが、前の層で学習した規定画像のエッジ・勾配・ぼかし具合などの基本的な構成要素が、後ろの層に伝わると目や鼻といった複雑な形状を持ったものとして認識される。

1.3.4 ML 推定による脳機能デコーディング

方向について予測を行っているかどうかについて、ML 推定 (Maximum Likelihood Estimation: 最尤推定) を用いて確かめた研究である。スパイク系列をクラスとして学習させ、テストフェーズで表れた反応について、どのクラスに属するかを判定し、刺激を特定する。表れた反応から刺激を推定できれば対応付けが行える。ML 推定の式を以下に示す[1]。

$$\hat{y}_{ML}^{(h)} = \arg \max_y \prod_{m=1}^M p(\zeta_m^{(h)} | y) \quad (2)$$

$\zeta_m^{(h)}$: サンプル h のユニット m におけるスパイクの発火率またはスパイクの数

$p(\zeta_m^{(h)} | y)$: ガウシアンまたはポワソン分布

訓練段階では、サンプルについての統計を用いて分布のパラメータを推定する。テスト段階では、最も尤度の高いクラスを選択することで復号を行う。

1.3.5 マウスの海馬についての実験

この実験では、データを用いて受容野の推定と方向指向性の確認を行った。CRCNS (Collaboration Research in Computational Neuroscience: 神経科学分野の研究データ共有サイト) にアップロードされたデータを利用して行った。ラットを 1.8m×1.8m の空間に放ち、海馬の動きを観測したものである。餌やり場または水やり場を設け、報酬として設定する。一般に、生物にとって重要であるこういった場に到達した時にニューロンの活動が活発になることは予め知られている。到達する以前に発火が見られるか、方向によって発火の頻度に違いが出るかについて調べた。

第2章 手法

2.1 相互情報量の算出

1.1.3 の式(1)で示した相互情報量の式に基づいて、LFP データが持つ相互情報量の算出を行う。

最も近い受容野にバーが入った時刻を利用し、その時刻より前の LFP とバーの方向の間の相互情報量を求める。これにより、受容野へバーが入るよりも前に情報が伝達されていることを確かめる。計測位置が隣接するチャンネルであっても反応のピーク時刻、ピーク値は異なっているため、一定の閾値を用いて反応があったか、情報が伝わっているかを判別することは難しい。そのため、そのチャンネルでの LFP が平均から最も離れた時のバーの位置を受容野の中心として用いる。

LFP データは高次元ベクトルであるため、全く同じ波形が 2 回現われる可能性はほとんどない。そのため、LFP の波形そのものを反応クラスとして相互情報量を算出しようとする、各反応クラスに属すサンプル数は 0 か 1 となる。この場合、サンプリングバイアスが生じてしまい、相互情報量で必要とされる母分布を正しく推定することができない。この問題を解決するためには、主成分分析などを利用した低次元表現、あるいはクラスタリング等を利用することが考えられる。本研究では、k-means 法によるクラスタリングおよび主成分分析による次元圧縮を行い、相互情報量の算出を試みる。

相互情報量を求めることで測りたいことは、条件 (バーの角度) と多チャンネル LFP (反応) の間の従属性である。データをそのまま使うとサンプルが少なすぎるため、条件と多チャンネル LFP との間の従属性を求める。多チャンネル LFP をクラスタに割り当てたうえで、条件ごとに対応する多チャンネル LFP はどのクラスタに属することが多いかといった従属性を相互情報量を使って測る。

2.2 ブートストラップ法による検定

実験データから相互情報量を求めるにあたり、限られたサンプル数であることから偏りが生じることが懸念される。そのため、データからブートストラップ標本を作り、標本を使って相互情報量を求め、値のばらつきを確認する。バイアスの推定にはブートストラップ数 $B=50\sim 200$ 必要となる[10]。

本研究では、LFP データを時間窓に分割し、その範囲のデータを利用して相互情報量を求める。その操作をブートストラップにより複数回実行し、結果のばらつきを確認する。

ここでは以下に示す操作を行い、結果を確認する。

- ・時間窓の幅を変更 (50ms, 20ms, 10ms)
- ・スライディングウィンドウ (時間窓を設定して、それより短い時間幅で窓を移動させる)

例) 50ms の時間窓で、25ms ずつずらす (0~50ms, 25~75ms … ~1200ms)

- ・ クラスタ数を変更

2.3 受容野の推定

LFP の多点計測ではチャンネルごとに受容野の位置が異なるため、チャンネルごとに位置の推定を行う。一般に視覚野における CRF (Classical Receptive Field: 古典受容野) の範囲は最大で半径 1.5° (度は視野角を示す。) とされている[4]。また、刺激が受容野内で提示された時に反応が大きくなるため、LFP が平均電位から最も離れた時の刺激の位置を受容野の位置と推定し、この時刻をピーク時刻とする。ピーク時刻とチャンネル位置の間の相関を求め、バー刺激に対してピーク時刻がどのように変化するかを確認し、チャンネル毎の受容野の位置を推定する。

チャンネルごとに受容野の位置が違ふことにより、「バーが受容野に入る前の時間帯の LFP」が一意に定義されない。LFP のピーク時刻が揃うように LFP を平行移動させるという提案があり、本研究ではこの手法で相互情報量の推定を行う。

一方、この操作を行うことで受容野到達以前の時間帯に余計な情報が伝わってしまうことが懸念される。そのため最も近い受容野にバーが入った時刻を利用し、その時刻より前の LFP と刺激クラス (バーの移動方向) の間の相互情報量についても求める。

2.4 主成分分析

「高次元のデータを低次元に射影する」という操作はデータの特性を見る上で有効な操作であり、様々な手法が提案されている。これらは一般に「次元圧縮」と呼ばれるが、主成分分析 (PCA: Principal Component Analysis) はそのうち「射影後の分散を最大化する」という最適化によって次元圧縮を行うものである。多変量データから最も分散が大きいベクトルを主成分として取り出し、指標とする。変数に対して重み付けを行い、少数 (多くは 2~3) の合成変数とする。この操作により各データ間に存在する差異を明確にできる。

本研究では、主成分分析を LFP データの次元圧縮に用いる。多次元ベクトルを持つ LFP データを低次元に射影し、圧縮する。

MATLAB における主成分分析は `pca(X)` 関数を用いることで実行できる。X は n 行 p 列のデータ行列である。 p 行 p 列の主成分係数行列が返り値として与えられる。このうち、寄与率の絶対値が大きい幾つか (累積寄与率などをもとに分析者が決定する) の主成分軸を用いて変換する。パラメータの設定により、使われるアルゴリズムを SVD (特異値分解) 以外に指定して変更することができる。

LFP データをそのままクラスタリングすると、次元数が大きくなり冗長となる可能性がある。主成分分析による次元圧縮を用いて低次元で表現し、改めてクラスタリングを行う。

まず、各チャンネルについて試行ごとの LFP 値を使って主成分分析を行う。

相互情報量を求めるために必要なのはチャンネルを分類したクラスタではなく、条件（バー刺激が近づく方向）と試行の組み合わせで指定されるサンプルのクラスタである。単一チャンネルの LFP が似ているかどうかでクラスタリングするのではなく、多チャンネル LFP が似ているかどうかでサンプルのクラスタリングを行う。一つのサンプルは「一つの 96 チャンネル LFP」を指す。

10 個の主成分軸を用いてサンプルの射影を行うことで、15 試行×8 方向=120 個の 10 次元ベクトルを得る。このベクトルを k-means 法に与える特徴ベクトルとして、クラスタリングを行う。

2.5 k-means 法によるクラスタリング

k-means 法とは、クラスタリングアルゴリズムのうち、分割最適化クラスタリングと呼ばれる手法の 1 つである。データに対してランダムにクラスタを割り振り、そのデータを元にクラスタの中心を計算する。クラスタの中心と各データの距離を求めて、近いクラスタに割り当て直す。評価関数の式を以下に示す。

$$\sum_{i=1}^k \sum_{x \in C_i} (d(x, c_i))^2 \quad (3)$$

この関数を最小化するように k 個のクラスタに分割する。クラスタへの割当てと中心の再計算を繰り返して行う。初期値の選択などに工夫が必要となる。階層的クラスタリング（Ward 法など）と比べ、計算量が少ないという特徴がある。

本研究においては、似た波形をクラスタリングし、相互情報量の算出を行えるようにする。これによって同一の波形データが複数回表れないことにより生じるサンプリングバイアスの問題に対処する。1 チャンネルの LFP データをひとつのサンプルとして、8 方向×96 チャンネル×15 試行の試行を少数のクラスタに分ける。サンプルの特徴ベクトルには各時刻での LFP の値を用いる。一定時間で区切り、データ点をチャンネルの代表として取得する。k-means の計算には MATLAB の関数 `kmeans(X,k)` を使用した。X には n 行 m 列の行列を入れる。k はクラスタ数を表す。返り値として n 行 1 列のインデックス値が返る。この値がクラスタ番号を表す。

データ解析には Mathworks 社が提供している MATLAB を使用する。MATLAB は行列計算、ベクトル演算、グラフ化、3 次元表示等を行えるライブラリを持ち、多変量データ、実験データ、時系列データを取り扱うことができる。後述する主成分分析、k-means 法についても関数が用意されているため、適している環境である。

第3章 結果

3.1 相互情報量の算出

k-means 法で得られた反応クラスをもとに、相互情報量の算出を行う。1.1.3 の式(1)で示した式を刺激と反応クラス毎の式に書き換える。

$$i(\theta, n) = P(n|\theta) \log_2 \frac{P(n|\theta)}{P(n)} \quad (4)$$

(4)式について、 n と θ で総和をとり、平均をとったものが、刺激と反応クラス間の相互情報量である。 n にはクラスタ番号が入り、 θ にはバーの方向が入る。バーの方向は 8 方向であるため、1 つの刺激が起こる確率 $P(\theta)$ は $1/8$ である。 $P(n)$ はクラスタに振り分けられた要素数を表す。 $P(n|\theta)$ は刺激 θ が与えられた時の LFP のうち、クラスタ n に振り分けられたものの数を表す。これらの値を使って相互情報量を求める。

時間窓を 50ms に設定して相互情報量を求めた結果を以下に示す。




図 7 相互情報量の時間変化

最大値と平均値を以下の表に示す。

表 1 最大値と平均値

	最大	平均
long	2.066	0.451
short	1.811	0.309

3.2 ブートストラップ法による検定

ブートストラップ標本毎に特徴量を求め、そのばらつきを boxplot で表現する。時間窓を変更したときのグラフを以下に示す。時間窓の幅を 50ms, 20ms, 40ms, 80ms に設定し、窓の移動幅はそれぞれ窓幅の半分の時間に設定している。図の中で、青色の box が short、赤色の box が long 条件の相互情報量を示す。箱の大きさが値のばらつきを確認できる。

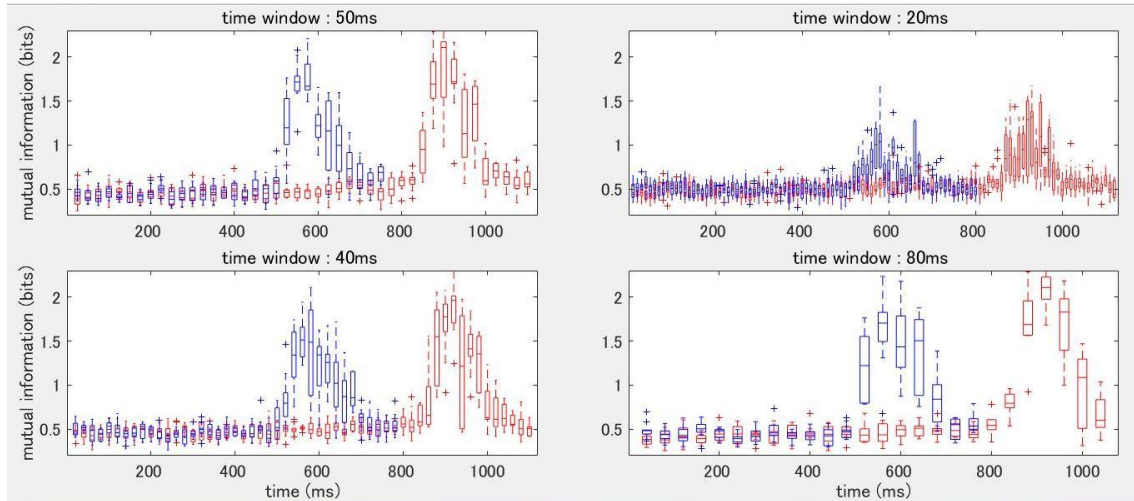


図 8 時間窓の幅による比較

時間窓の幅を小さくすると細かな変化を読み取ることができるが、計算のステップ数が増加するため、計算時間が大幅に増大する。50ms で反応の特徴は十分捉えられていると読み取り、以降の実験では窓幅を 50ms、窓の移動幅を 25ms に設定する。

クラスタ数を変更して計算した結果を以下に示す。

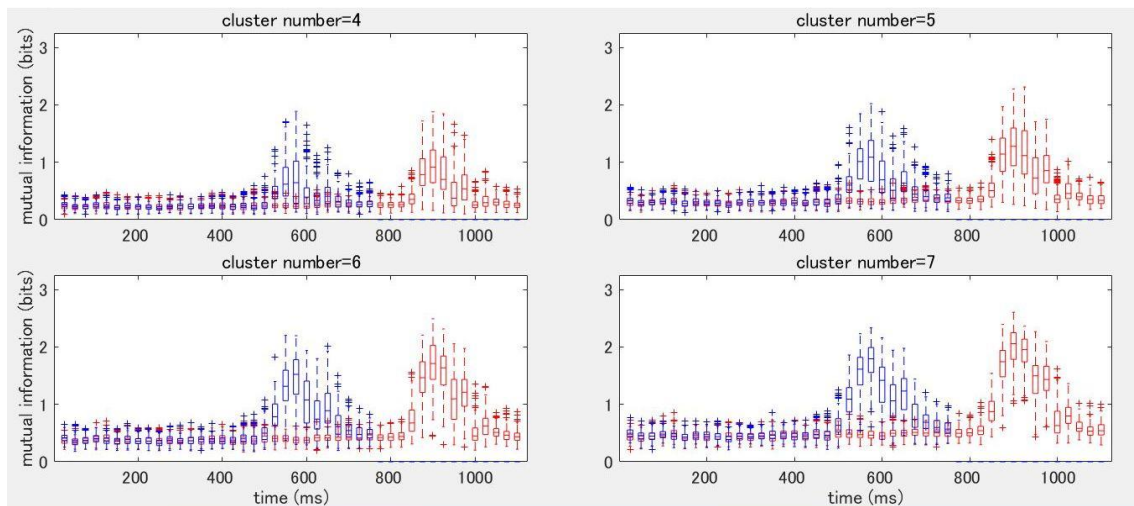


図 9 クラスタ数による比較 (4-7 クラスタ)

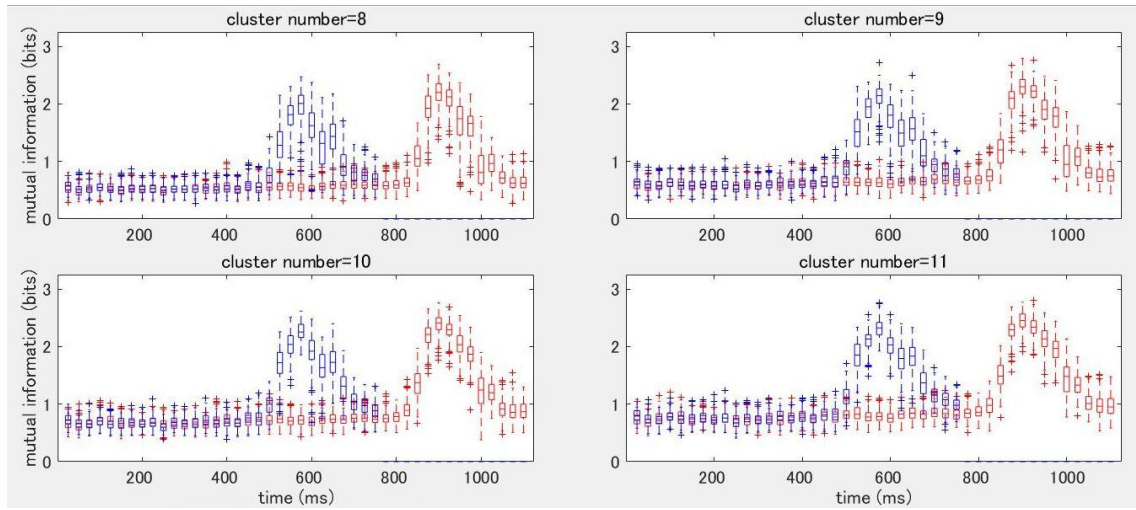


図 10 クラスタ数による比較 (8-11 クラスタ)

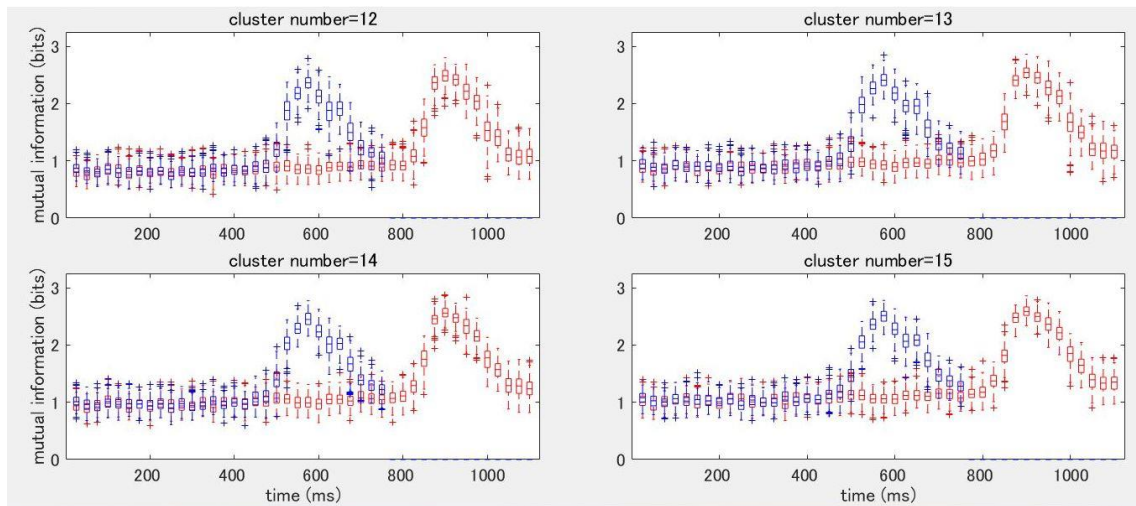


図 11 クラスタ数による比較 (12-15 クラスタ)

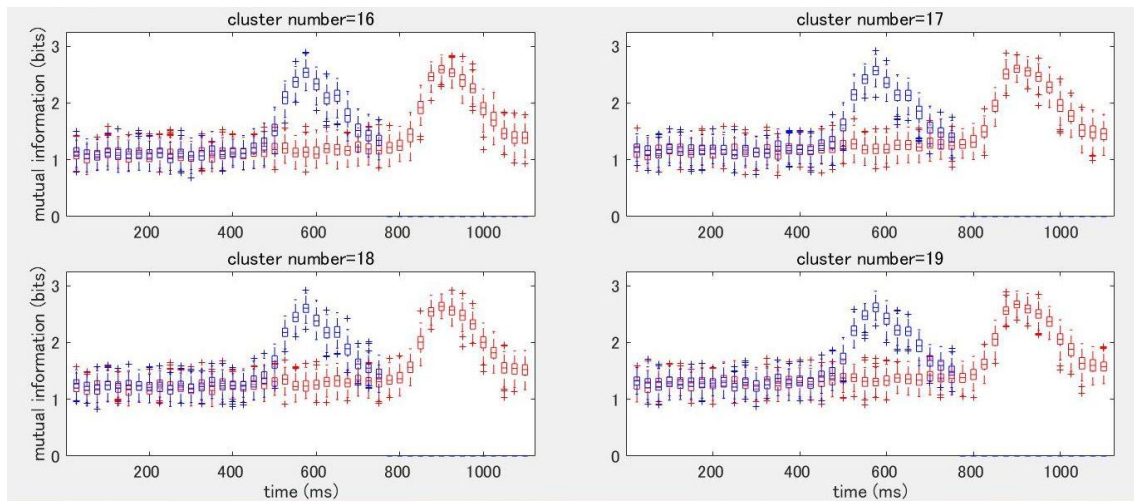


図 12 クラスタ数による比較 (16-19 クラスタ)

クラスタ数を 4 から 19 の間で増加させると、相互情報量の最小値と最大値がともに増加した。

相互情報量の変化量の大きさを見るため、クラスタ数を変更しピークの値と全時刻の平均値を比較したものを、以下の図に示す




図 13 ピーク値と平均値の差

クラスタ数 6 と 7 の時に差が最大となっている。Panzeri らのサンプリングバイアスを除く定理でも試行数の 1/2 以下に設定するとあり[7]、試行数 15 に対してクラスタ数 7 はこの

定理にも沿った結果である。クラスタ数は可能な限り大きくするのが望ましいため、以降はクラスタ数を7に設定して実験を行う。

3.3 受容野の推定

実験データの中で、電極とデータの対応関係を示したファイルがある。このファイルを利用して各チャンネルのピーク時刻を求める。ここで得られたピーク時刻を使って、時間が進むにつれピークがどのように移動するかを、ピーク時刻を迎えたチャンネルの座標の平均を取ることで確認する。座標の平均と時刻の間の回帰直線を求める。

時刻と座標の平均の間の回帰直線を求めたグラフを以下に示す。**condition** は刺激の方向と対応している。




図 14 回帰直線 (condition = 2)




図 15 回帰直線 (condition = 4)

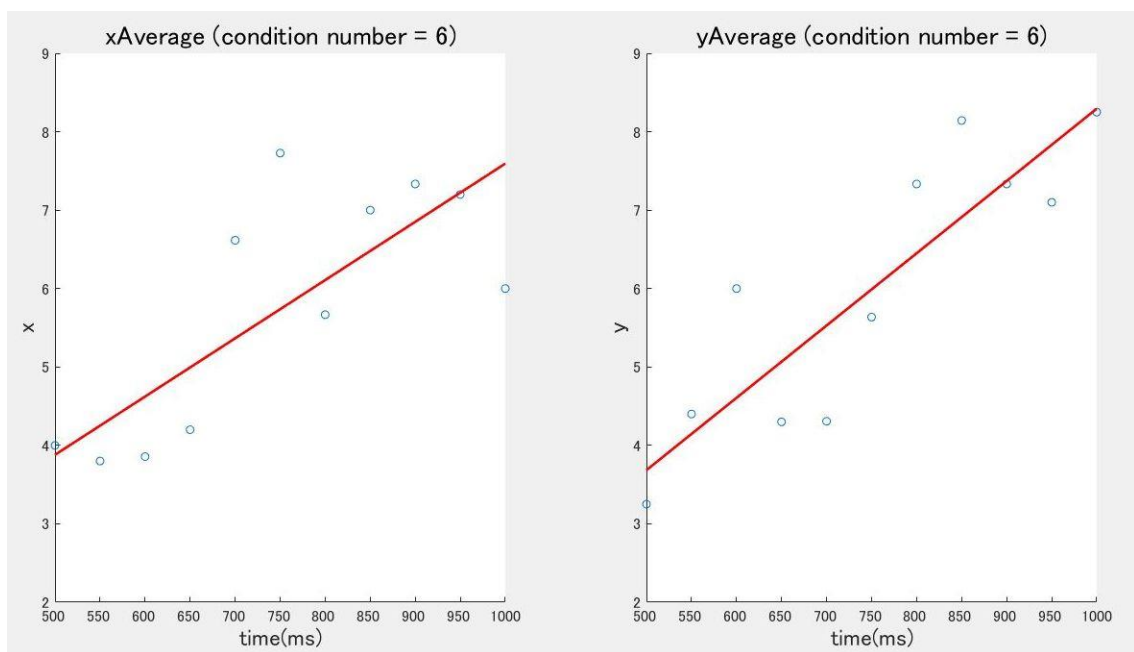


図 16 回帰直線 (condition = 6)

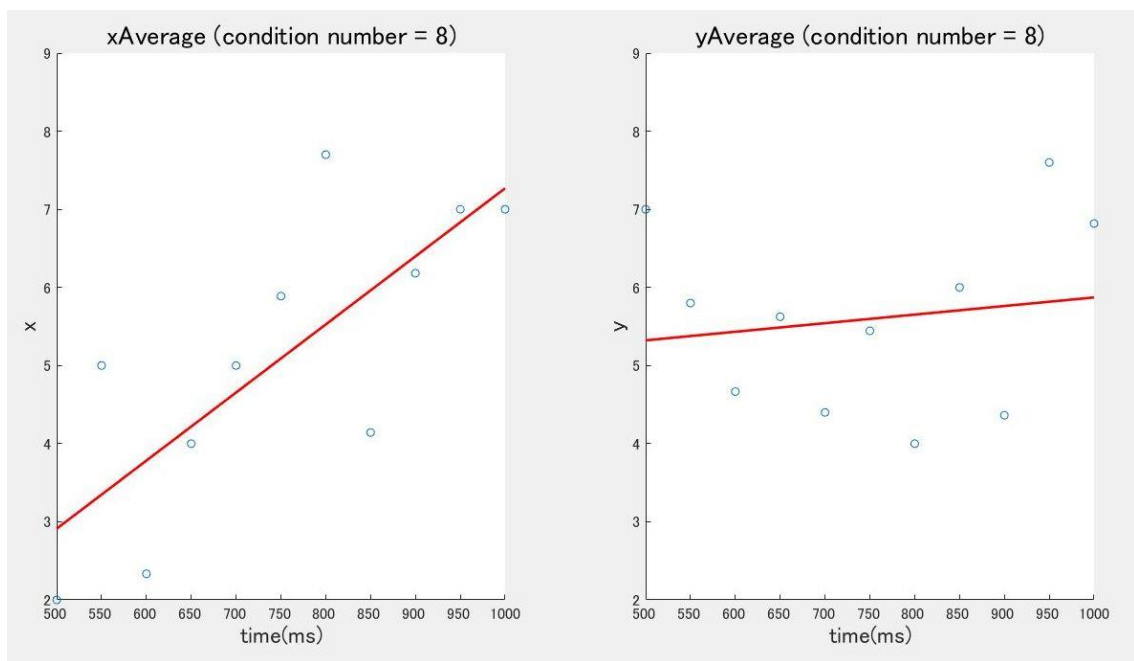


図 17 回帰直線 (condition = 8)




図 18 回帰直線 (condition = 10)




圖 19 回歸直線 (condition = 12)




圖 20 回歸直線 (condition = 14)




図 21 回帰直線 (condition = 16)

回帰直線の傾きから、情報の伝達が行われる方向が推測できる。電極の位置とバー刺激の移動方向を比べた時、2つが一致しているとは言えない結果となった。

第4章 考察

時間窓に区切って相互情報量を求めることで、バーが受容野に到達する動きと相互情報量の変化が近い結果となった。Guo らの実験でも同様の動きは見られており、LFP に対して相互情報量を求めることができていると言える。今後の検証として、利用した LFP データをスパイクに変換し、同様の実験を行って同じような結果が得られるか確認する。

受容野に到達する時刻は、LFP のピークが現れた 800ms あたりと仮定していたが、今回の実験では受容野に到達する以前にピークは見られなかった。受容野の位置を推定し、各チャンネルでピークを迎える時刻を LFP の水平移動により揃えた後、相互情報量を求めた時にどのような結果が出るのかを確認することが今後の課題である。

時間窓のサイズを小さくするにつれ、相互情報量のピーク値が小さくなった。原因としては、情報が減ったことで、反応と刺激の対応が上手く取れず、相互情報量が減少したことが考えられる。

クラスタ数を増加させた時に相互情報量のピーク値が大きくなったが、これは相互情報量の反応クラスが増えると、1つに割り当てられるサンプル数が減り、刺激と反応の対応付けがしやすくなることから起こったと考えられる。クラスタ数を 8 以上にした場合、Panzeri らの定理から外れることに加え、図 8 のピーク値と平均値の差からわかるように、ピークが

鈍くなることから、試行数が 15 の時クラスタ数は 6 または 7 に設定すると良いと考えられる。

ピーク時刻とピークを迎えたチャンネルの座標の平均との間の回帰直線を求めた結果、刺激の方向に対して直線の傾きが変化した。刺激の方向と一致しているわけではないため、受容野の位置を確定させることはできていない。推定には他の方法を検討する必要があると考えられる。Guo らの実験では、受容野到達から 100ms 前後で相互情報量のピークが現れている。この結果を参考にし、ピーク時刻から 100ms 手前を受容野到達時刻に設定すると受容野の位置が推定できる可能性がある。本研究で利用したデータとの相違点を確認し、条件に沿った調整を加えることでこの問題は解決できると考えられる。

謝辞

本研究を通して多くの御指導を頂きました手塚太郎准教授に心より感謝致します。研究を進める中で度々方針を示して頂き、大きな支えとなりました。

また、ゼミ等を通して様々なアドバイスを頂きました、若林啓助教に大変感謝しております。

研究を行うにあたり Giacomo Benvenuti、Frederic Chavane 両氏には実験データを提供して頂きました。ありがとうございました。

催事に尽力された手塚研究室ならびに若林研究室の皆様には大変お世話になりました。ゼミで刺激を頂くことも多く、感謝しております。

研究を進めるにあたり支えていただいた皆様、本当にありがとうございました。重ねて謝意を表します。

参考文献

- [1] Alexandre Pouget, Peter Dayan, and Richard Zemel, “Information processing with population codes”, Nature Review Neuroscience, 2000.
- [2] Bradley Efron and R.J. Tibshirani, An Introduction to the Bootstrap, 1993.
- [3] Gyorgy Buzsaki, Costas A. Anastassiou, and Christof Koch, “The origin of extracellular fields and currents? EEG, ECoG, LFP and spikes”, Nature Reviews Neuroscience, 2012, 13, pp.407-420
- [4] Kun Guo, Robert G. Robertson, Maribel Pulgarin, Angel Nevado, Stefano Panzeri, Alexander Thiele and Malcolm, P. Young,” Spatio-temporal prediction and inference by V1 neurons”, European Journal of Neuroscience, 2007, 26, pp.1045-1054.
- [5] Peter Dayan, L.F.Abbott. ”Theoretical Neuroscience”, Massachusetts Institute of Technology Press 2001 年, 480p.
- [6] Rajesh P. N. Rao, Dana H. Ballard, “Predictive coding in the visual cortex: a functional interpretation of some extra-classical receptive-field effects”, Nature Neuroscience 2, 1999, pp.79 - 87
- [7] Stefano Panzeri, Alessandro Treves, “Analytical estimates of limited sampling biases in different information measures”, Computation in Neural Systems, 1996, pp.87-107
- [8] Thomas M. Cover, Joy A. Thomas. Elements of Information Theory. Wiley-Interscience, 2006 年, 776p.
- [9] 合原一幸, 神崎亮平. 理工学系からの脳科学入門. 初版, 東京大学出版会, 2008 年, 212p.
- [10] 韓太舜, 小林欣吾. 情報と符号化の数理. 初版, 培風館, 2002 年, 352p.
- [11] 小西貞則, 越智義道, 大森裕浩. 計算統計学の方法 -ブートストラップ・EM アルゴリズム・MCMC-. 初版, 朝倉書店, 2008 年, 223p
- [12] 齊木 愛希子, 磯村 宜和. 細胞外記録 - 脳科学辞典. 2014-06-02.
<https://bsd.neuroinf.jp/w/index.php?title=細胞外記録>, (参照 2016-12-20).
- [13] 櫻井鉄也. MATLAB/Scilab で理解する数値計算. 初版, 東京大学出版会, 2006 年, 235p.