

認知心理学会テクニカルレポート

回帰モデルとして見る信号検出理論 ——情動体験シグナルを見抜けるか——

難波修史（広島大学）

目的

この発表の目的は非常にシンプルで、実はこれまでの先生方によって紹介されてきた信号検出力、判断基準、反応バイアスなどのパラメータを回帰モデルの形でも導出できるということを紹介させていただくことにあります。本発表を通して、皆さんがより実践的な観点から信号検出理論を使えるようになればと思います。本発表では既存のパッケージによる導入可能性を示したうえで、本発表のメインである回帰モデルバージョンの信号検出理論を私の研究へ適用した例を紹介させていただきます。

再三になるのですが飛ばすんですけど、信号検出理論というのは再認課題で見られるような Yes / No 反応に対して、正規分布に従う二つの心理的連続量の仮定をあてはめて、それによって信号検出力や判断基準といったパラメータを推定する枠組みなんですけど、今回はこれを実際の実験データに適用する例を紹介します。

我々は他者の情動体験を見抜けるのか

それでは早速本発表で用いる例を紹介させてもらおうと思います。（女の子の笑顔の画像を提示する）まず質問なんですが、「彼女は幸福を示しているでしょうか？」という質問に対していかがでしょうか。そんなに考えなくてもいいんですけど、まあ彼女は笑っていますね。そして笑顔というのは幸福を示す表情であるだろうと考えられるわけです。ですが次の「彼女は幸福を感じているでしょうか」という質問についてはいかがでしょうか。確かに笑っているんですけど、僕から見れば彼女は本当に楽しくて笑っているというわけではなく、撮影のためにはじける笑顔を作ってくださいと指示されて一生懸命作っている笑顔のように映るわけです。つまり示されている表情（笑顔）と実際の内的状態（幸福な気持ち）の实在との間には必然的なつながりはないわけです。今回紹介する例というのは、こうした情動を示す表情についてです。情動を示す表情というのは大きく分けて二種類あると考えられます。一つは意図によって出てくる表情です。例えば幸福の表情を作成してくださいと別の人に言われてにこっと作るような笑顔であるとか、そういったものは意図表情とよばれます。もう一つは楽しいものを見たり聞いたりしたときに、思わず笑みがあふれてくるような、体験によって自然に出てくる体験表情です。これらはどちらもある情動を示すという意味においては同じなのですが、意図表情には体験が伴わず、体験表情には体験が伴うという違いが考えられ

ます。今回のリサーチクエスションは、そうした二種類の表情を見ている観察者が、表情から情動体験の有無を正確に見抜けるかどうか、という疑問について検討することです。言い換えれば、我々は体験というシグナルを表情上から見抜くことができるのか、というのがリサーチクエスションになります。

研究課題は非常にシンプルで、観察者に表情を見てもらって、それに対して「この人は幸福を感じているやろか」とか、「嫌悪を感じているやろか」といった質問に対して Yes / No の判断をしてもらうという、ただそれだけです。このような形で 2 種類の表情に対して Yes / No データを集めたとします。さて、ここからが回帰モデルとして見る信号検出理論の話になります。

回帰モデルとして見る信号検出理論

この話を展開していくうえで必要な道具が 3 つあります。最初の道具は回帰モデルです。広く知られているのは一般線形モデルと呼ばれる以下のものですね (式 1)。

$$\begin{aligned} \mu &= \beta_0 + \beta_1 * X \\ Y &\sim \text{Normal}(\mu, \sigma) \end{aligned} \quad (\text{式 1})$$

皆さんもご存知だと思うんですけども、これは従属変数 Y と独立変数 X の間の関係を記述する式で、X=0 のときには β_1 の項が消えることで β_0 のみとなります。これは切片と呼ばれます。それで X が増えれば増えるほど、 β_1 の勾配で Y が増えていくという関係を表現する式で、これは Y が平均 μ の正規分布に従って誤差が乗るよみみたいな仮定があるわけですけども、大事なのは切片と傾きがある、これが回帰モデルである、ということです。

もう一つの道具がプロビット変換 (ϕ として表現) と呼ばれるもので、なかなかいかつい名前なんですけども、これはシンプルなものとして、0 から 1 に従う確率 p を実数値 z に変換、と発表資料に書いてありますが、要はコインの裏表とか体験がある / ないなどの Yes / No 反応といった二値の変数というのは、確率 p で表現できるわけなんです。そういった確率 p に従う二値変数にプロビット変換をかけると、平均 0、標準偏差 1 の標準正規分布に従う等分散を仮定する信号検出理論にとって都合のよさそうな値になるわけです。

で、最後の道具である一般化線形モデルです。まさかの 1 ページのスライドに収めようとするんですけど、関連する書籍はたくさんあるので改めて勉強してもらおうと思います。先

ほど紹介した一般線形モデルっていうのは従属変数Y(正確にはその残差)が正規分布に従うものです。そして大雑把に一般化線形モデルっていうのは、従属変数Yが任意の分布に従うよ、という回帰モデルになります。回帰モデルのYが正規分布以外の分布に従いそうな場合に、例えば先ほどのプロビット変換を組み合わせれば、図のように0/1の二値変数を予測する切片と傾きを推定可能ですよと (Figure 1)。これがざっくり説明したバージョンの一般化線形モデルになります。今回はこの枠組みを使って信号検出理論と一致するパラメータを出しますよ、という話になります。




Figure 1. プロビット変換を用いた一般化線形モデルの概念図

情動体験判断データを分析する

情動体験判断データを使って具体的に説明すると、Yというのは体験あるなしの判断で確率pに従うYであると。で、ここのXというのは何なのかというと、参加者に提示された表情が意図表情なのか体験表情なのか、シンプルにそれだけです。例えば再認課題とかであれば、提示された単語がフィラー単語かターゲット単語かという感じで分けるんだと思います。で、信号検出理論的な枠組みで考えるのであれば、ノイズ分布(N分布)が意図表情に対する心理量であり、シグナル+ノイズ分布(SN分布)が体験表情に対する心理量であると想定できます。では、一段階ずつ考えていきましょう。まず意図表情に対する体験あり反応を考えたとき、これは非常に簡単で、β₁に0をかけるので、切片のみが残ります(式2)。

IF X = 意図表情 :

$$Y = \phi(\beta_0 + \beta_1 * 0) = \phi(\beta_0) = \text{False Alarm (FA)} \quad (\text{式} 2)$$

この場合のYは意図表情に対する体験あり反応になるので、単純にFAであると。この切片にはプロビット変換がかかっているので、切片の計算にはφ⁻¹をFAに適用することで計算できます。また、zCR(すなわち -zFA)は判断基準kと対応するため(DeCarlo, 1998)、式2での切片は判断基準にマイナスをかけたものであると…簡単に出来ましたね。次は体験ありの場合はどうなるのかについてです。切片は先ほど求めたので、体験ありの式ではzFAを活用しようと思います(式3, 4)。

IF X = 体験表情 :

$$Y = \text{Hit Rate (HR)} = \phi(\beta_0 + \beta_1 * 1) \quad (\text{式} 3)$$

$$z\text{HR} = z\text{FA} + \beta_1 \quad (\text{式} 4)$$

この場合のYは体験表情に対する体験あり反応になるので、単純にHRであると。で、両辺にφ⁻¹による変換を適用していくと、zHRになって右辺のφがなくなると。で、この両辺を並び替えると、β₁ = zHR - zFAになります。ところで、信号検出力(d')というのは、心理量分布の標準偏差が1であると想定するとzHR - zFAと記述できます(Stainslaw & Todorov, 1999)。つまり、プロビット変換を用いた一般化線形モデルの回帰式において、切片とはマイナスがかかった判断基準と対応しており、傾きというのは信号検出力と対応しているということが、ここまでの簡単な式でも求められるという…不思議ですね。いや、不思議ではないのかな。まあいいか。

古典的な信号検出理論と回帰モデルとの比較

とあるデータに古典的な信号検出理論をあてはめた場合と、同じデータに対して回帰モデルで当てはめた場合を比較してみましょう(Figure 2)。古典的な場合の判断基準は0.57で、信号検出力が1.10くらいでした。回帰モデルの場合は、マイナスがかかっていますが、0.57で、もう片方が1.12で、概ね一致した値になることがわかりますね。




Figure 2. 古典的信号検出理論 vs 回帰モデル信号検出理論

以上で回帰モデルと古典的な信号検出理論で推定する値がだいたい一致するという事までわかったんですけども、これっていったい何が嬉しいのかと。信号検出理論を使ったことがある人はもしかしたら経験があるかもしれないんですけども、個人ごとのd'をいちいち計算して、それをまた分散分析にかけて、違いがあったりなかったり、みたいな方法を採用する人がいらっしやると思うんですけどね。だけでも、今回紹介した回帰モデルで計算を行えば、単純に回帰係数とかをみて判断することができる、というのが利点の一つとしてあげられます。さらに予測変数の導入も簡単にできるので、条件に分けて逐一古典的な信号検出理論から同じような求め方をしなくても、回帰モデルの形で分析すれば簡便に条件を追加した解析ができると。で、階層性を持たせる拡張も楽で、単純な回帰モデルと同様に切片傾き変数モデルを適用すればいいと。階層モデルというのは、ものすごく単純に言うと、切片や傾きというのが参加者ごと、刺激ごとに異なるという仮定を導入するモデルになります。

私の実験データについて、判断基準が変化すると信号検出力も同じように大きくなったり小さくなったりするっていう、切片と傾きが共変関係にあるという仮定をぶちこんだ応用も可能です。さらに、実は今回用いたデータでは、表情の提示方法が参加者間で異なります。一つは静止画像、もう一つは動画によって表情刺激が提示されています。この映像提示方法によって反応バイアスや信号検出力は異なってくるのでしょうか。回帰モデルから見た信号検出理論を用いれば、単純に独立変数を増やすことで、この疑問は解決可能です。先ほどまでのモデルにおける提示刺激の性質 X1 に加えて、提示条件の X2 の要素を含めたいので、その交互作用といったように新たな独立変数を増やした検討を簡単に行うことができます。で、やりたいことをまとめると、階層モデルによる個人差を含めたパラメータおよび信号検出力と判断基準の共変関係を推定し、そして新たな独立変数である表情刺激の提示条件によって各パラメータの値が異なるかどうかを明らかにしたいわけですよ。ここまで聞いてると、これを実際に導入するのは難しいだろうなあ、っていう風に思うわけですよ。ところがどっこい、R のパッケージに `brms` というパッケージがありまして、このパッケージを使えば、なんと以下のようにほんの数行で済むんですね（なお、`brms` はベイズ用のパッケージであり、最尤推定を用いた同様の解析は `lme4` パッケージによってほぼ同一のモデル式で計算を行うことができます）。

```
# 推定用モデル（事前にパッケージ・データ読み込みが必要）
fitF1 <- brm(Y ~ 1 ~ X1*X2 + (1+X1|subject),
            family = bernoulli(link="probit"), data
            = F1)
```

で、これが何をしているかという、普通にここまでのモデルを記述しているだけで、X2 っていうのは表情の提示条件——静止画か動画か——です。X1 は表情刺激が意図表情か体験表情かかっていうのを含めて、そんな感じですぐに求まります。引数の `bernoulli(link="probit")` というのは、Y が従う確率分布を二値の確率を表現するベルヌーイ分布として、そして Y と線形結合をつなぐリンク関数としてプロビット変換を選択してくださいねー、ということを示しています。そしてモデル式に含まれる `(1+X1|subject)` というのは切片と傾きが参加者ごとに異なるよ、さらに共変関係もあるかもね、という仮定をいれてくださいね、という指示をしているわけです。基本的に `brms` というパッケージは、非常に便利なんですけど、この発表の中では扱いきれないので、静岡理科大学の紀ノ定先生が作成した `brms` パッケージの使い方（紀ノ定, 2018）というのが大変有用な記事なので、もしこのパッケージに興味をもていただければ、併せて参考にしていただければよいかなと思います。

で、先ほどの R コードをガツと回した結果（Figure 3）をお見せすると、判断基準と信号検出力の参加者ごとの分散はそこそこあるよねと。信号検出力と反応バイアスの相関はほぼほぼないよと。で、切片と傾きを見ると Intercept と display が静的な提示条件における判断基準と信号検出力なんですけど、静止画像で提示されると信号検出量は結構小さ目ということが、この値の大きさに判断できると。一方、動的な提示、映像で見た場合の判断基準と信号検出力はそれぞれ `presentation` と `display:presentation`（“:” は交互作用を意味する）で示されており、この場合の信号検出力は大きくなっている。

Group-Level Effects:					
~ID (Number of Levels: 58)					
	Estimate	Est. Error	1-95% CI	u-95% CI	Eff. Sample Rhat
sd(Intercept)	0.13	0.08	0.01	0.31	1394 1.00
sd(display)	0.15	0.10	0.00	0.38	1416 1.00
cor(Intercept, display)	-0.04	0.57	-0.95	0.94	3191 1.00
Population-Level Effects:					
	Estimate	Est. Error	1-95% CI	u-95% CI	Eff. Sample Rhat
Intercept	0.23	0.09	0.07	0.40	4329 1.00
display	0.18	0.12	-0.06	0.41	3793 1.00
presentation	-0.73	0.12	-0.96	-0.49	4358 1.00
display:presentation	1.00	0.17	0.66	1.33	3432 1.00

Figure 3. 情動体験データ×回帰信号検出理論モデルの結果

つまり今回のデータによる実践例をまとめると、静的な提示をされるよりも動的な提示をした場合のほうが、より観察者は情動を示す 2 種類の表情から情動体験の有無を正確に見抜けるであろう、ということが回帰モデルによる信号検出理論モデルを適用した結果からわかります。番外編として、先ほどの山根先生のお話（山根, 2019）にあったような、不均一の分散を持つ信号検出理論についても同様に、変換とモデルを工夫すれば SN 分布と N 分布の分散の違いがありつつ、反応ごとの判断基準を表現するようなこともできると。それほど長いかついでコードにもならない。

まとめると、回帰モデルで信号検出理論のパラメータも推定できちゃうよという話でした。私の発表は以上になります。

Q: 判断基準 (k) と反応バイアス (c) を区別していますがどう違うのですか？

A: 計算式が異なります ($c = k - (d/2)$)。

文献

DeCarlo, L. T. (1998). Signal detection theory and generalized linear models. *Psychological methods*, 3, 186-205.

紀ノ定保礼 (2018). `brms` パッケージを用いたベイズモデリング入門, `nora_goes_far`, <https://das-kino.hatenablog.com/entry/2018/12/15/230938> (2019 年 9 月 25 日)

Stanislaw, H., & Todorov, N. (1999). Calculation of signal detection theory measures. *Behavior research methods, instruments, & computers*, 31, 137-149.

山根 高史 (2019). ベイズ推定による信号検出モデルの拡張 認

知心理学会テクニカルレポート, COGPSY-TR-005.

付記

本稿の内容は、日本認知心理学会第17回大会 自主企画WS
2「シグナルかノイズか、それが問題だ——信号検出理論の深化
とモデリング——」の発表内容に基づくものです。