

Well-being
Japan
2025

計算論的神経科学 × ウェルビーイング

永山 晋
(一橋大学大学院
ソーシャル・データサイエンス研究科准教授)

Society of
Well-being



計算論的神経科学 × ウェルビーイング

永山 晋（一橋大学大学院ソーシャル・データサイエンス研究科准教授）

脳の情報処理とウェルビーイング

ウェルビーイング研究の基盤である「ウェルビーイングの測定」は、主にアンケート調査によって行われている。これは、生活満足度や人生の意義といった感覚が極めて主観的であるためだ。一歩立ち止まって考えると、ウェルビーイングは確かに感覚的かつ抽象的な概念であるが、その主観的な感覚は脳がもたらすものであると容易に推察できる。

仮に脳の情報処理の側面からウェルビーイングを捉えることができれば、ウェルビーイング研究にブレークスルーをもたらさう。既存のウェルビーイングの研究は、心理学ベースの理論と経済学ベースの理論によって主に行われてきた。神経科学という全く異なる研究アプローチによって、これまでの膨大なウェルビーイングに関する知見を統一的に説明する理論体系が構築できる可能性がある。さらに、ウェルビーイングに影響を与える要因を数理モデルで表現し、これまででない新たな要因の特定や介入方法の考案が可能となるかもしれない。

そこで、米国 Lauriate Institute for Brain Research（通称、LIBR）の Ryan Smith 准教授を筆頭とした筆者を含む研究グループは、脳の情報処理のモデルの一つである「**能動的推論モデル**」に着目し^[1]、ウェルビーイングを説明する数理モデルの構築および研究方法の探求を行った。その成果は International Journal of Wellbeing に掲載されているので、是非ご覧いただきたい (<https://www.internationaljournalofwellbeing.org/index.php/ijow/article/view/2659>)。本稿は、この論文の核となるアイデアとその前提知識について解説したい。なお、本稿は、一橋大学ウェブサイトにおける筆者の解説も参照している (<https://www.sds.hit-u.ac.jp/202/>)。

能動的推論モデル、自由エネルギー原理とは何か？

まず、本論文の中心的な概念フレームワークである「能動的推論モデル active inference model」について説明しよう。このモデルは、人を含む生物が外部環境から影響を受けながら、同時に環境に働きかけ、知覚、行動、学習を行う脳の情報処理を数理モデルとして表現したものである。題目にある「計算論的神経科学 computational neuroscience」とは、数理モデルを用いた神経科学を指す。

ここでは数理モデルの詳細には立ち入らず、モデルの直感的な理解に焦点を当てたい。基本的な考え方は、「脳は常に予測を行い、その予測と現実とのズレを最小化しようとする」というものである。われわれは、五感で捉えた情報を現実として認識しているが、実際にはすべて脳が予測したイメージによって構築された仮想世界である。

脳内の仮想世界は、予測と外界からの情報との差（予測誤差）を最小化するため、現実と連動している。この予測誤差は「自由エネルギー」と呼ばれ、自由エネルギーを最小化するために知覚や行動が行われるという仮定は「自由エネルギー原理 free energy principle」と称される。また、われわれは単に五感から情報を受け取るだけでなく、未来を予測し、能動的に行動を起こすことで現実世界に関与する。選択される行動に応じて得られる情報や状況は異なる。このモデルでは生物が能動的に予測し、行動するという仮定から「能動的」および「推論」という言葉が用いられている。

ここで理解しておきたい点は、能動的推論モデルにおいて予測誤差が時間軸に沿って二種類に分けられることである。一つは、短期的、現時点での予測誤差であり、これは外界の予測イメージと実際に得られる情報とのズレを指す。この現時点の予測誤差は、知覚によって最小化される。一方、もう一つは、長期的、将来に向けた予測誤差であり、これは将来の理想状態と現時点の状態との差である。このズレを解消するためには、知覚だけでなく行動が必要となる。行動は、複数の将来シナリオの中から、期待される報酬（本人にとっての実利）を最大化し、将来の予測の確実性を向上させる情報が得られるものを選択することで実現される。前者は「自由エネルギー」、後者は「期待自由エネルギー」と呼ばれる。なお、「期待」という用語が使われている理由は、「期待値」のように将来の未実現の報酬などが確率的に決まることを想定しているためである。

能動的推論は、知覚、行動、学習を統合的に説明するモデルである。これを理解するために、単純な例を考えてみよう。勝率が未知の2択のロットマシンAとBがあり、複数回ロットを引くことができ、勝数に応じて賞金が増加するゲームに参加するとしよう（このようなゲーム設定はバンディットタスクと呼ばれる）。

このロットマシンの例における「知覚」とは、各ロットが勝ちロットなのか負けロットなのかを推論する過程に該当する。例えば、AとBをそれぞれ10回試し、Aが8回勝利し、Bが2回しか勝てなかった場合、過去の情報をもとに、参加者はAを勝ちロット、Bを負けロットと知覚するのが自然である。逆にBを勝ちロットみなすことは不自然だろう。これが知覚の調整を通じた予測誤差の最小化である。

次に、この例における「行動」とは、実際にAまたはBのロットを引くという選択にあたる。もし、先の例のようにAを勝ちロット、Bを負けロットと認識した場合、将来の報酬を最大化するためにはAを引き続けるという行動方針が採用されるだろう。しかし、例えば、Aロットを2回試して両方で勝利を得た一方でBロットは未試行の場合、Aを勝ちロットと知覚し、今後もAを引き続ける選択が最善であるかどうかは疑問である。Bロットは試行回数が少なく、その確率が未知であるため不確実性が高い。実際、Aが単にたまたま連勝してただけで、Bロットの方が実際には勝率が高い可能性も否定できない。人が未知の可能性を切り開く行動を取るのには、Aを引き続けるよりもBの持つ情報的価値が高いと判断するためである。これが、将来の予測誤差の最小化のため、期待される報酬を最大化し、将来の予測の確実性を向上させる行動が選択されるという原理である。

最後に、「学習」とは何か。仮にAを勝ちロット、Bを負けロットと知覚していたとしても、Aでの負けが増加すれば、従来の予測が成立しなくなる。そこで、得られた結果と予測との差を反映して知覚を更新する過程が学習と呼ばれる。

能動的推論モデルからみたウェルビーイング

ここまでの説明から、単純な例に限れば、能動的推論の考え方自体はそれほど難解ではないことが分かっただろう。

では、能動的推論モデルにもとづくと、ウェルビーイングをどのように捉えられるだろうか。われわれの論文では、「主観的ウェルビーイングは、期待自由エネルギーが低下した状態」と捉えている。このように捉える理由は、期待自由エネルギーが次の3つの側面を備えているからである。それぞれ説明しよう。

一つは「過去と現在を顧みた際の将来の期待」という側面である。直感的に説明すれば、期待自由エネルギーとは、その人が描く理想状態と現状との乖離だと解釈できる。乖離が小さいほど期待自由エネルギーは低下し、ウェルビーイングは高まる。逆に、大きな乖離が常態化すると、ウェルビーイングは低下してしまう。過去の経験からその人の能力や選択肢、機会が非常に限られていると知覚している状態は、低い自己効力感や救いよくなささと類似する。

もう一つは、「期待報酬」である。何を報酬と捉えるかは状況や個人の性質にも依存するが、高い確率で何らかの

報酬を獲得できるという期待は、ウェルビーイングに直結すると容易に推察される。スロットマシンの例でいえば、勝利時の賞金に対する期待がこれに該当する。もちろん、快楽に直結するような報酬があれば、感謝や絆のような報酬、人生の意義のような報酬もあるだろう。

最後は「不確実性の低下」である。この点は、抽象的に説明するよりも具体例の方がわかりやすい。改めてスロットマシンの例で考えてみよう。スロット A と B のうち、スロット A しか引いたことがない場合、スロット B を引くという新たな選択肢を取ることで、未知が既知に変わる。この未知が既知に変わることは、行動を通じて不確実性を低下させることを意味する。直接的な報酬は得られないものの、状況をより高い解像度で理解できるため、理想状態と現状の乖離が縮まる可能性が高まる。一方、スロットマシンの確率が完全にランダムであれば、どの行動を選択したとしても有用な情報が得られず、理想状態と現状との乖離が埋まる期待が得られない状態となる。その結果、ウェルビーイングは低下してしまいかねない。

なお、能動的推論モデルでは、数理モデルの式展開に応じて、期待自由エネルギーを構成する要素に関してさまざまな解釈が成立する。詳しくは、参考文献に記した文献 [2] を参照してほしい。

ウェルビーイングを左右する認知パラメータ

本論文は、主観的ウェルビーイングの向上を期待自由エネルギーの低下と位置づけることで、能動的推論の数理モデルを用いて主観的ウェルビーイングを測定できる可能性を提示している。

能動的推論の数理モデルは、複数の認知パラメータで構成される。認知パラメータとは、例えば、スロットマシンで得られる金銭的報酬への執着が個人によって異なるように、人それぞれの認知や思考の傾向を指す。本論文では、ウェルビーイングと認知パラメータの関係、あるいは認知パラメータの組み合わせに関する仮説を提示している（下図参照）。この認知パラメータの組み合わせを「フェノタイプ (phenotypes : 生物が示す観察可能な特徴の集合体)」と呼んでいる。

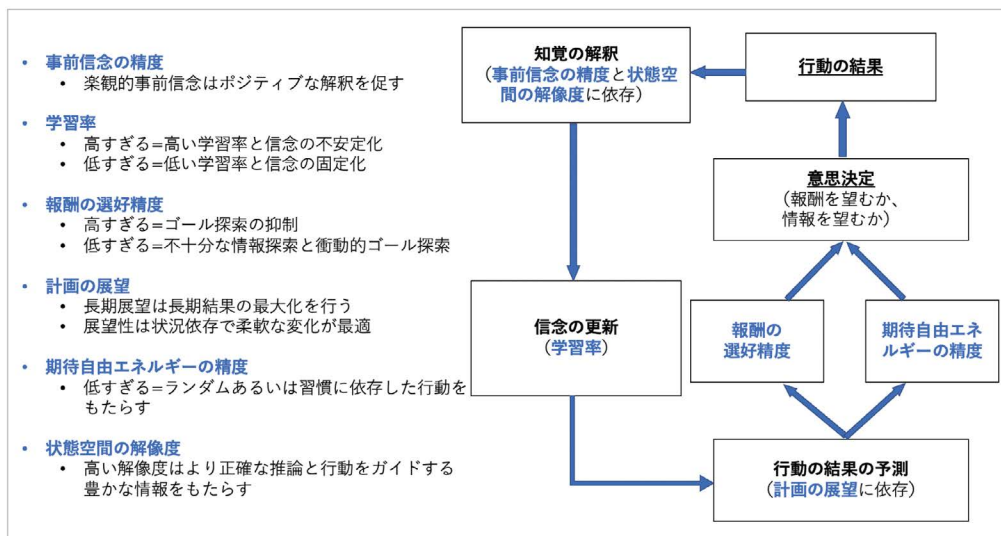


図. 主観的ウェルビーイングの計算論的フレームワーク

※モデルを構成する認知パラメーターは青字

出典 : Smith et al. (2022)・永山ほか (2022) をもとに筆者作成

現実の複雑な環境下での研究方法の確立はまだ試行錯誤の段階にあるが、スロットマシンのような単純な実験環境下では、参加者の行動履歴に基づいて数理モデルを構成する認知パラメータを推定できる。現段階では、能動的推論の数理モデルで主観的ウェルビーイングを直接推定するというより、まずはアンケート調査による主観的ウェルビーイングの測定と組み合わせ、ウェルビーイングに影響を与える認知パラメータを探索するアプローチがとられる。

ここでは、本論文で対象とした認知パラメータについて説明する。この部分はやや複雑なため、読み飛ばしても構わない。焦点を当てたパラメータは次の6つである。各パラメータとウェルビーイングとの関係の予測について説明しよう。

- (1) 事前信念の精度
- (2) 学習率
- (3) 報酬選好の精度
- (4) 期待自由エネルギーの精度
- (5) 計画の展望
- (6) 状態空間の解像度

(1) **信念の精度**とは、その人の知覚の主観的な明確さを表す。先の例でいえば、スロット A は勝ちスロット、スロット B は負けスロットといったように、世界の解釈において曖昧さがなく明確であれば、信念の精度は高い（すなわち信念が強い）。逆に、勝ちスロットとも負けスロットとも判断できない曖昧な解釈の場合、信念の精度は低い。信念には、自分にとって都合の良い世界を強く信じる楽観的信念（例：社会には善人が多く、善行には必ず見返りがある、など）と、都合の悪いことを強く信じる悲観的信念（例：社会は悪人だらけである、など）とがある。ウェルビーイングは、実際に自分にとって都合が良く、外部環境とフィットした楽観的な信念を持つ場合に高まりやすいと予想される。

(2) **学習率**とは、行動の結果として新たに得られた情報が、どれだけ信念の変更に寄与するかを意味する。先ほどのスロットの例でいえば、スロット A を 10 回引いて 8 回勝った場合と、100 回引いて 80 回勝った場合では、同じ勝率でも試行回数が多い方が信頼性が高く感じられる。一般的には、過去のエビデンスが豊富であればあるほど、強固な信念が形成される。しかし、学習率が極めて高い人は、新たに入手する情報を有用と感じやすいため、その後 10 回（つまり計 110 回）引いて 10 回負けた場合、これまでの履歴を十分に考慮せずに負けスロットと認定してしまう。一方、学習率が低い人は、一度強固な信念が形成されると、たとえ連続して 10 回負けたとしても信念をあまり変更せず、依然として A を勝ちスロットとして知覚する。あまりにも高すぎる学習率は過去の信念を軽視し、逆に低すぎる学習率は過去の信念に固執する原因となる。したがって、学習率が適度である場合に、環境に適合しやすく、ウェルビーイングが高い状態が得られると予想される。

(3) **報酬選好の精度**とは、報酬を得た際の主観的価値の強さを意味する。スロットの勝ち負けの例であれば、勝ちを強く好み、負けを強く嫌う場合は報酬選好の精度が高い。一方、勝ち負けにあまり関心がなく、報酬に対する選好が薄い場合は、報酬選好の精度が低い。報酬選好の精度が高いほど、報酬に対して過敏に反応するため、例えばスロット A で勝ちが得られると、未知のスロット B を検討する余地もなく、スロット A を選択するという衝動的な行動を誘発しやすい。ただし、報酬選好の精度は、報酬獲得と情報探索とのバランスにも関係する。一定の探索がなければ最適な行動は発見できないため、報酬選好の精度が適度に高い場合にウェルビーイングが高くなると予想される。

(4) **期待自由エネルギーの精度**とは、行動が期待自由エネルギーの値にどれだけ影響を受けやすいかを意味する。より直感的に言えば、自分の行動が有用な情報や高い報酬獲得に結びつきやすいという確信の程度を表す。これは、自分の世界に関する理解への評価に関わるため、「メタ認知」とも深く関連する。スロットマシンの例でいえば、スロ

ト A と B の勝率推定に対する自信の程度である。この精度が高いほど、ランダムな行動や習慣的な行動に支配されにくくなる。逆に、精度が低いと、適当な行動やこれまで選択してきた行動を継続しやすくなる。期待自由エネルギーの精度が高いほど、ウェルビーイングも高いことが予想される。

(5) **計画の展望**とは、先々のステップをどれだけ見通せるかを示すものである。この展望が長期的であれば、受験勉強やジム通いのように、一時的に辛い状況でも、損して得をするような投資的行動が可能となる。ただし、大きな社会変動が起こり、これまでの定説が通用しなくなる場合もある。このように、環境が不安定な場合、先々のことばかり考えた結果、直近の報酬を見逃す可能性もある。そのため、計画の展望は、置かれている環境に応じて柔軟に変化できる場合に、高いウェルビーイングもたらされると予想される。

(6) 最後に、**状態空間の解像度**とは、世界や自分の状態に関する知覚の細やかさを意味する。たとえば、先ほどのスロットの例で、スロットマシンに対して「勝ちスロット」か「負けスロット」かの二種類の知覚しかない場合と、これに加えて「半々勝率のスロット」という三種類の知覚がある場合では、後者の方が状態空間の解像度が高い。潜在状態の解像度が高いほど、より正確な世界の推論が可能となり、より有用な行動がとれるようになる。したがって、状態空間の解像度が高いほど、ウェルビーイングも高くなると予想される。

今後の研究の展開

能動的推論モデルをはじめとした計算論的神経科学アプローチによるウェルビーイング研究は、今後どのように進展していくだろうか。

短期的な進展として、本論文が掲げた基本的な前提、すなわち期待自由エネルギーの低下と主観的ウェルビーイングとの関連性を検証する必要がある。また、本論文で提示した能動的推論モデルの認知パラメータと主観的ウェルビーイングがどのように関係しているかを探求する必要がある。これらの点については、既に Ryan Smith らの研究グループが取り組んでいる。本論文では詳しく説明しているが、複数の認知パラメータを単一の実験で推定するのではなく、パラメータの特性に応じた様々な実験を行う必要がある。いずれも、環境の知覚が刻々と変化の中で、繰り返しの意思決定や行動が求められるスロットマシンのような実験である。

実験手法のアップデートも求められる。スロットマシンなどの単純な実験で得られた結果だけでは、現実の複雑な世界に適用できない可能性があるからだ。なるべく現実世界に接近し、参加者がリアリティを感じられる実験を設計することが望まれる。実験だけでなく、現実世界のデータの活用も可能かもしれない。すでに、心理学の一部では、SNS における投稿行動など、数理モデルのアプローチを用いて認知パラメータを推定する研究が現れ始めており^[3, 4]、計算論的神経科学アプローチを用いたウェルビーイング研究においても、この流れが見られるだろう。

さらに、fMRI などを用いた脳活動測定のアプローチとの併用も望まれる。数理モデルで推定した認知パラメータと脳活動パターンとの関係を検証することで、これまで神経科学が培ってきた神経基盤の知識の観点から、ウェルビーイングおよびそれに関連する認知パラメータとの関係を探求することが可能となる。

このように、計算論的神経科学によるウェルビーイング研究は、非常に広大な未知の領域を含んでいる。このアプローチで得られる新たな知見と、ウェルビーイング研究および神経科学研究で培われた既存の知が統合されることで、学問的にも社会的にも価値ある研究分野として発展していくに違いない。

原著

Smith, R., Varshney, L. R., Nagayama, S., Kazama, M., Kitagawa, T., Managi, S., & Ishikawa, Y. (2022). A computational neuroscience perspective on subjective wellbeing within the active inference framework. *International Journal of Wellbeing*, 12(4), 102-131. <https://www.internationaljournalofwellbeing.org/index.php/ijow/article/view/2659>

参考文献

- [1] トーマス・パー、ジョバンニ・ベッツーロ & カール・フリストン (2022) 『能動的推論：心、脳、行動の自由エネルギー原理』 ミネルヴァ書房 (乾敏郎訳)
- [2] Smith, R., Friston, K. J., & Whyte, C. J. (2022). A step-by-step tutorial on active inference and its application to empirical data. *Journal of Mathematical Psychology*, 107, 102632. <https://doi.org/10.1016/j.jmp.2021.102632>.
- [3] Lindström, B., Bellander, M., Schultner, D. T., Chang, A., Tobler, P. N., & Amodio, D. M. (2021). A computational reward learning account of social media engagement. *Nature Communications*, 12(1), 1311. <https://doi.org/10.1038/s41467-020-19607-x>
- [4] Turner, G., Gunschera, L. J., Subrahmanya, S., Salecha, A., Eichstaedt, J. C., Palminteri, S., & Orben, A. (2024). A computational model of reward learning and habits on social media. <https://doi.org/10.31234/osf.io/xe25k>