

サプライザルによってガーデンパス効果を説明できる言語モデルは存在する

吉田遼^{1,2} 磯野真之介³ 染谷大河¹ 大関洋平^{1,2*} 栗林樹生^{4*}

¹ 東京大学 ² NII LLMC ³ 国立国語研究所 ⁴ MBZUAI

{yoshiryo0617, taiga98-0809, oseki}@g.ecc.u-tokyo.ac.jp

s-isono@ninja.ac.jp tatsuki.kuribayashi@mbzuai.ac.ae

概要

ニューラル言語モデルのサプライザル $-p_{\theta}$ (単語 | 文脈)が人間の統語的曖昧性解消の処理負荷(ガーデンパス効果)を非常に小さく見積もることから、サプライザルではガーデンパス効果は説明できないと主張されてきた。そこで、本研究は、「本当にサプライザルによってガーデンパス効果を説明できる言語モデルは存在しないのか?」という経験的な問いを検証する。結果として、言語モデルのサプライザルを、統語的に曖昧な文における人間の読み時間に近づける微調整は、統語的に単純な文を主として構成される自然コーパスでの読み時間の説明性能を損なうことなく(むしろ向上させつつ)成功し、サプライザルによってガーデンパス効果を説明できる言語モデルは存在することが示された。

1 はじめに

「人間の文処理の目的の一つは予測であり、単語の処理負荷はその単語の予測確率の負の対数に比例する」というのがサプライザル理論[1, 2]である。計算心理言語学では、「コーパス頻度は人間の文処理に影響を与える」との原則[1]のもと、コーパス上での次単語予測で最適化された言語モデルの予測確率 p_{θ} (単語 | 文脈)を、人間の予測確率 p_{human} (単語 | 文脈)の代替として用いることで、サプライザル理論が経験的に検証されてきた。実際に、言語モデルのサプライザルは、人間の処理負荷を反映すると考えられる読み時間や脳波に対する説明力を持つことが示されており、サプライザル理論の経験的な裏付けがされてきた[3, 4]。

一方、ニューラル言語モデルのサプライザルが人間の処理負荷を捉えられるのは、統語的に単純な

文を主として構成される自然コーパスに関してであり、“the horse raced past the barn fell”[5]に代表される、統語的に曖昧な文における人間の処理負荷(ガーデンパス効果)は非常に小さく見積もってしまうことが明らかになっている[6, 7]。この乖離の原因としては、以下の二つの可能性が指摘されている[8]: (i) 確率推定の問題。すなわち、言語モデルの予測確率は、人間の予測確率とは必ずしも一致しないという可能性。(ii) サプライザル理論の問題。すなわち、ガーデンパス効果をサプライザルに還元することは不可能であるという可能性。特に、近年では、後者の可能性が強く主張されている[9, 8]。

本研究では、前者の可能性の観点から、「本当にサプライザルによってガーデンパス効果を説明できる言語モデルは存在しないのか?」という経験的な問いを検証する。具体的には、言語モデルのサプライザルを、ガーデンパス文における人間の読み時間に近づける微調整を実施し、微調整後の言語モデルがガーデンパス文および自然コーパスにおける読み時間を説明できるか評価する。結果として、微調整は自然コーパスでの人間の読み時間の説明性能を損なうことなく(むしろ向上させつつ)成功し、サプライザルによってガーデンパス効果を説明できる言語モデルは存在することが示された。

2 背景

2.1 サプライザル理論

サプライザル理論は、人間の文処理における単語の処理負荷はその単語の予測確率の負の対数に比例すると仮定する:

$$\text{Cost}_{\text{human}}(w_t) \propto -\log p_{\text{human}}(w_t | \mathbf{w}_{<t})$$

サプライザル理論には複数の理論的根拠があるが、特に、Levy[2]はサプライザルが文の背後の構造 T

* 共同最終著者

に関する信念の更新度と等価であることを示した：

$$\begin{aligned} & -\log p_{\text{human}}(w_t | \mathbf{w}_{<t}) \\ & = D_{\text{KL}}(p_{\text{human}}(T | \mathbf{w}_{\leq t}) \| p_{\text{human}}(T | \mathbf{w}_{<t})). \end{aligned} \quad (1)$$

一般に、サプライザル理論は Marr の 3 つのレベル [10] における計算レベルの仮説であり、人間の文処理が達成すべき目的についての記述である [11]。すなわち、この理論の言及は「人間の文処理の目的の一つは予測であり、それは同時の文の背後の構造に関する信念の更新である」というもので、それを実現する表現・アルゴリズムについては中立である。

2.2 ガーデンパス効果

人間は以下のような文を左から右に読む時、*fell* (およびそのスピルオーバー効果 [12] を反映した後続領域) の読み時間が、例文 (1-a) で例文 (1-b) に比べて長くなる [13, 5]：

- (1) a. The horse raced past the barn *fell*...
 b. The horse that was raced past the barn *fell*...

心理言語学では、この現象は以下のように説明される：例文 (1-a) では *The horse raced past the barn* の時点で、(i) *raced* が主動詞であり *the horse* がその主語である解釈 (ii) *raced* が縮約関係節を構成し *the horse* を修飾する解釈の間に統語的曖昧性が生じる。読者は (i) の解釈を 선호するが、*fell* の出現によりこの解釈を棄却することとなり、処理負荷が増大する (ガーデンパス効果)。

伝統的に、この負荷は統語構造の再解析という選択的メカニズムにより生じるとされてきた [14]。一方、Levy によるサプライザル理論の定式化 (式 1) によれば、この処理負荷は統語的曖昧性解消に起因する構造に関する信念の更新によるものに他ならず、サプライザル理論の説明対象である。近年、様々な言語モデルのサプライザルがガーデンパス効果を非常に小さく (自己ペース読み時間でおおよそ 1/10–1/30 程度に) 見積もることから、サプライザル理論の問題が強く主張されている [6, 7, 9, 8]。

3 手法・設定

3.1 手法

本研究では、Kiegeand ら [15] の微調整手法を、ガーデンパス文において適用する。

データ ガーデンパス文のデータセットを D_{gp} とする。各データポイント $d \in D_{\text{gp}}$ は単語 w_d と自己ペース読文法による読み時間 RT_d の組であり、以下の属性が付与されている：ペア ID $s(d)$ 、統語的曖昧性の種類 $g(d) \in \{\text{MVR}, \text{NPS}, \text{NPZ}\}$ ¹⁾、曖昧・非曖昧の条件 $c(d) \in \{\text{amb}, \text{unamb}\}$ (それぞれ例文 (1-a) および (1-b) に対応)、文中位置 $t(d)$ 、曖昧性解消位置 (例文 (1) では *fell*) を $r = 0$ とした関心領域位置 $r(d) \in \{0, 1, 2, \text{null}\}$ ²⁾。

D_{gp} は訓練セット $D_{\text{gp}}^{\text{train}}$ とテストセット $D_{\text{gp}}^{\text{test}}$ からなる³⁾。また、 D_{gp} と同一実験で読み時間が収集された自然文データセットを D_{filler} 、独立に読み時間が収集された自然コーパスを D_{nat} とする。任意のデータセット D に対し、文頭 2 単語および文末を除いた部分集合を $D^{(-)}$ 、さらに関心領域も除いた部分集合を $D^{(-)}$ と表記する⁴⁾。

微調整 データポイント $d \in D_{\text{gp}}$ の説明変数ベクトルを $\mathbf{x}_\theta(d) = [\boldsymbol{\iota}_\theta(d)^\top, \mathbf{z}(d)^\top]^\top$ とする。ここで、

$$\boldsymbol{\iota}_\theta(d) = [-\log p_\theta(w_d^{(k)} | \text{ctx}_d^{(k)})]_{k=0}^2$$

は現在の単語位置 ($k = 0$) 及び先行 2 領域のサプライザルであり、 $w_d^{(k)}$ は位置 $t(d) - k$ の単語、 $\text{ctx}_d^{(k)}$ はその先行文脈である。 $\mathbf{z}(d)$ は単語長等の統制変数である。

$D_{\text{gp}}^{\text{train}}$ から統語的曖昧性の各種類について同数のペアを含むように抽出された各バッチ B について、 $B^{(-)}$ 上で最小二乗法により回帰係数 $\boldsymbol{\beta}_{\theta, B^{(-)}}$ を推定する：

$$\boldsymbol{\beta}_{\theta, B^{(-)}} = (X_{\theta, B^{(-)}}^\top X_{\theta, B^{(-)}})^{-1} X_{\theta, B^{(-)}}^\top \boldsymbol{\psi}_{B^{(-)}}.$$

ここで、 $X_{\theta, B^{(-)}}$ は、 $d \in B^{(-)}$ に対応する $\mathbf{x}_\theta(d)^\top$ を各行とする計画行列であり、 $\boldsymbol{\psi}_{B^{(-)}}$ は $d \in B^{(-)}$ に対応する読み時間 RT_d からなるベクトルである。

$\boldsymbol{\beta}_{\theta, B^{(-)}}$ に基づき、以下の損失を計算する：

$$\begin{aligned} \mathcal{L}_B(\theta) = & \frac{1}{|B^{(-)}|} \sum_{d \in B^{(-)}} (RT_d - \mathbf{x}_\theta(d)^\top \boldsymbol{\beta}_{\theta, B^{(-)}})^2 \\ & + \lambda \|\boldsymbol{\beta}_{\theta, B^{(-)}} - \boldsymbol{\beta}_{\theta_0, D_{\text{gp}}^{\text{train}}}\|^2. \end{aligned}$$

1) Main verb/Reduced Relative clause 曖昧性、Noun Phrase/Sentential complement 曖昧性、Noun Phrase/Zero 曖昧性。具体例については付録 A を参照せよ。

2) スピルオーバー効果を反映しうる後続 2 単語を $r \in \{1, 2\}$ 、関心領域外を $r = \text{null}$ とする。

3) テストセットと訓練セットの間で、曖昧性を生じさせる動詞 (例文 (1) では *raced*) および関心領域の単語に重複はない。

4) 文頭 2 単語はスピルオーバー変数が未定義、文末はラップアップ効果 [16] の影響がある。関心領域外は統語的曖昧性解消の影響がない「普通の」読み時間と捉えられる。

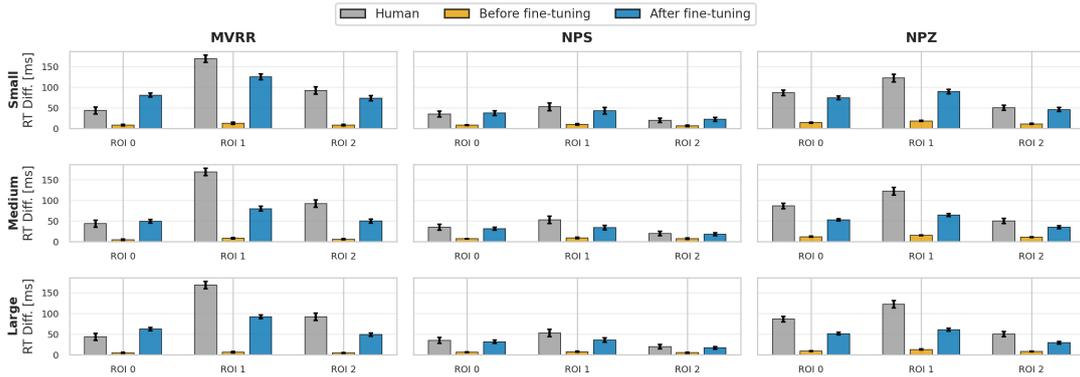


図1 ガーデンパス効果の微調整の結果。行がモデルサイズ、列が曖昧性の種類であり、横軸が関心領域位置、縦軸が曖昧文と非曖昧文の読み時間差である。灰色が実際の人間の読み時間差、黄色および青色がそれぞれ微調整前後の言語モデルのサプライザルによる推定読み時間差を表す。エラーバーは標準誤差を表す。

第一項は人間の読み時間と読み時間の推定値との差分、第二項は回帰係数が初期係数から逸脱することへの正則化項である⁵⁾。

評価 評価は以下の2つの観点から行う。

ガーデンパス効果の微調整 $D_{\text{filler}}^{(-)}$ 上で推定した回帰係数 $\beta_{\theta, D_{\text{filler}}^{(-)}}$ を用い、 $D_{\text{gp}}^{\text{test}}$ における曖昧文と非曖昧文の推定読み時間差

$$\Delta \widehat{RT}_{g,r}(\theta) = \frac{1}{|S_g|} \times \sum_{s \in S_g} [\mathbf{x}_{\theta}(d(s, \text{amb}, r))^{\top} \beta_{\theta, D_{\text{filler}}^{(-)}} - \mathbf{x}_{\theta}(d(s, \text{unamb}, r))^{\top} \beta_{\theta, D_{\text{filler}}^{(-)}}]$$

と人間の読み時間差 $\Delta RT_{g,r}$ との近さ [6] を評価する。ここで S_g は曖昧性の種類 g のテストペア集合、 $d(s, c, r)$ はペア s ・条件 c ・位置 r に対応するデータポイントである。

自然文への影響 $D_{\text{nat}}^{(-)}$ 上で推定した回帰係数を用い、サプライザルを説明変数に含む回帰モデルの、統制変数のみのベースライン回帰モデルに対するデータポイントあたり対数尤度改善 [17]

$$\Delta \text{llh}(\theta) = \frac{1}{|D_{\text{nat}}^{(-)}|} \times \sum_{d \in D_{\text{nat}}^{(-)}} [\log f(RT_d | \mathbf{x}_{\theta}(d); \beta_{\theta, D_{\text{nat}}^{(-)}}) - \log f(RT_d | \mathbf{z}(d); \beta_{\theta, D_{\text{nat}}^{(-)}})]$$

を評価する。ここで $f(\cdot | \cdot; \beta)$ は回帰係数 β に基づく回帰モデルの確率密度関数であり、添字 θ は統制変数のみによる回帰係数の推定を表す。

5) 予備実験により、この項がない場合、言語モデルは関心領域外のサプライザルを小さくして回帰係数を大きくし、関心領域の推定読み時間を表面的に増大させてしまうことが判明した。

3.2 設定

言語モデル θ_0 として、GPT-2 [18] の small (S)、medium (M)、large (L) を用いた⁶⁾。

データ D_{gp} として、Syntactic Ambiguity Processing (SAP) データセット [9] を用いた⁷⁾。MVR、NPS、NPZ の3種類の曖昧性について曖昧文・非曖昧文からなる24ペアずつを含み、各単語には220–440名の英語母語話者による自己ペース読み時間が付与されている⁸⁾。

本データセットは言語モデルの微調整には比較的小規模であるため、leave-one-out 交差検証 (LOO) を採用した。各 fold では3種類の統語的曖昧性解消から1ペアずつ (計3ペア) をテストデータとし、残りのペアで脚注3)に合致するよう訓練セットを構築した⁹⁾。データの誤りを含む1ペアを除外したのち23回評価を行い、fold 平均値を報告する。

D_{filler} として同データセット内の filler 文 (39文) を、 D_{nat} として Natural Stories [20] (181名、485文)、Brown [3] (35名、449文)、UCL [21] (117名、361文) の3コーパスを用いる。

微調整 統制変数 $\mathbf{z}(d)$ は、ユニグラムサプライザル、単語長、および文中位置を含む¹⁰⁾。サプライザ

6) <https://huggingface.co/openai-community/gpt2>

7) <https://github.com/caplabnyu/sapbenchmark>

8) 100 ms 未満または 3000 ms 超の観察を除外し、読み時間の被験者平均を代表値として用いた。以下のデータセットにも同様の前処理を適用した。

9) 訓練セットは fold 平均で 1645 単語となり、元論文 [15] で本手法の有効性が報告されている Provo コーパス [19] (1113 単語) と同規模となった。

10) スピルオーバー効果を考慮し、ユニグラムサプライザル、単語長については1単語前および2単語前の値も含む。ユニグラムサプライザルは wordfreq ライブラリ [22] により推定し、頻度が欠損しているデータポイントは除外した。

ルは、サブワードのサプライザルの補正和 [23, 24] を用いた。ハイパーパラメタの詳細は付録 B に記す。

4 結果・分析

4.1 結果

ガーデンパス効果の微調整 ガーデンパス効果の微調整の結果を図 1 に示した。まず、先行研究通り、微調整前の言語モデル（黄色）のサプライザルは、人間の読み時間遅延（灰色）の存在は捉えられないものの、その大きさを非常に小さく見積っていることが分かる。例えば、ROI=1¹¹⁾では、最も人間に近い振る舞いを示している GPT-2 small でも、それぞれの現象で人間の読み時間遅延の大きさの 7% (MVRR)、19% (NPS)、15% (NPZ) を示すに留まっている。

一方で、微調整後のモデル（青色）は未知のデータポイントに対して汎化し、人間の読み時間遅延（灰色）に非常に近い振る舞いを示していることが分かる。特に、最も微調整が成功している GPT-2 small は、それぞれの現象で人間の読み時間遅延の 73% (MVRR)、83% (NPS)、73% (NPZ) を説明するに至っている（同じく ROI=1 に着目）。

自然文への影響 自然文への影響の結果を図 2 に示した。すべての条件で、統語的に曖昧な文における微調整は、統語的に単純な文を主として構成される自然コーパスにおける読み時間の説明性能をも向上させていることが分かる。

これらの結果は、サプライザルによってガーデンパス効果を説明できる言語モデルが存在することを示している。

4.2 分析：現象間転移

4.1 節では、3 種類すべての統語的曖昧性の文を用いて言語モデルの微調整を行なった。本小節では、単一種類の文のみで言語モデルの微調整を行い、3 種類すべての統語的曖昧性で評価する。これにより、言語モデルが各曖昧性ごとに特定のパターンを学習しているのか、ガーデンパス効果に共通する一般的な機序を獲得しているのかを検証する。

GPT-2 small の ROI=1（主効果位置）における現象間転移の結果を図 3 に示した。ある現象で微調整

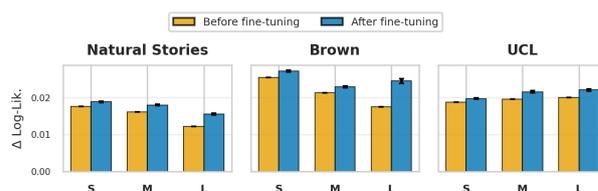


図 2 微調整の自然文への影響。それぞれのグラフは各自然コーパスに対応し、横軸がモデルサイズ、縦軸が統制変数のみのベースライン回帰モデルに対する対数尤度改善である。

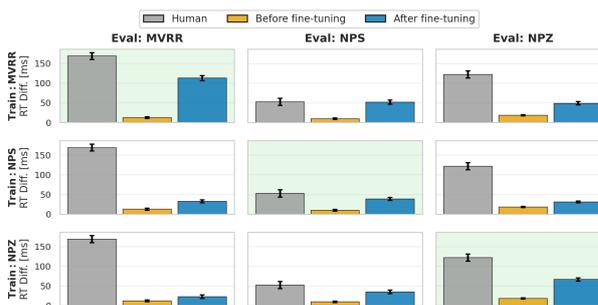


図 3 GPT-2 small の ROI=1 における現象間転移の結果。行および列はそれぞれが微調整、評価に用いた統語的曖昧性の種類を表す。緑の背景はドメイン内評価を表す。

された言語モデルは、その他の現象においても、微調整前の言語モデルよりよくガーデンパス効果を捉えられていることが分かる。例えば、MVRR で微調整されたモデルは、NPS に対しても、51.5ms（微調整前：9.6ms）の遅延を、NPZ に対しても、48.9ms（微調整前：18.1ms）の遅延を予測している。

転移は完璧ではなく、ある現象で微調整されていない言語モデルは、その現象で微調整されたモデルと比べて遅延を小さく見積もってはいるものの、この結果は、微調整がガーデンパス効果に共通する一般的な機序の獲得をもたらすことを示唆している。GPT-2 medium および large についても、同様の傾向が見られた（付録 C）。

5 おわりに

本研究では、言語モデルのサプライザルを、ガーデンパス文における人間の読み時間に近づける微調整を実施することで、サプライザルによってガーデンパス効果を説明できる言語モデルは存在することを示した。今後の課題として、英語以外の多様な言語におけるガーデンパス効果への拡張や、微調整により言語モデルの内部機序に引き起こされた変化の調査などが挙げられる。

11) 先行研究 [9] で「主効果位置」として主たる分析対象とされてきた。

謝辞

本研究は JSPS 科研費 JP24H00087、JP24KJ0800、JST ACT-X JPMJAX25CS、JST さきがけ JPMJPR21C2、JST CREST JPMJCR2565、JST BOOST JPMJBY24B2、JST SPRING JPMJSP2108 の助成を受けたものです。

参考文献

- [1] John Hale. A Probabilistic Earley Parser as a Psycholinguistic Model. In **Second Meeting of the North American Chapter of the Association for Computational Linguistics**, 2001.
- [2] Roger Levy. Expectation-based syntactic comprehension. **Cognition**, Vol. 106, No. 3, pp. 1126–1177, March 2008.
- [3] Nathaniel J. Smith and Roger Levy. The effect of word predictability on reading time is logarithmic. **Cognition**, Vol. 128, No. 3, pp. 302–319, September 2013.
- [4] Stefan L. Frank, Leun J. Otten, Giulia Galli, and Gabriella Vigliocco. The ERP response to the amount of information conveyed by words in sentences. **Brain and Language**, Vol. 140, pp. 1–11, January 2015.
- [5] Thomas G. Bever. The cognitive basis for linguistic structures. In **Language Down the Garden Path: The Cognitive and Biological Basis for Linguistic Structures**, p. 0. Oxford University Press, August 2013.
- [6] Marten van Schijndel and Tal Linzen. Single-Stage Prediction Models Do Not Explain the Magnitude of Syntactic Disambiguation Difficulty. **Cognitive Science**, Vol. 45, No. 6, p. e12988, 2021.
- [7] Suhas Arehalli, Brian Dillon, and Tal Linzen. Syntactic Surprisal From Neural Models Predicts, But Underestimates, Human Processing Difficulty From Syntactic Ambiguities. In **Proceedings of the 26th Conference on Computational Natural Language Learning (CoNLL)**, pp. 301–313, Abu Dhabi, United Arab Emirates (Hybrid), February 2022. Association for Computational Linguistics.
- [8] William Timkey, Kuan-Jung Huang, Byung-Doh Oh, Grusha Prasad, Suhas Arehalli, Tal Linzen, and Brian Dillon. Eye movements reveal a dissociation between prediction and structural processing in language comprehension, November 2025.
- [9] Kuan-Jung Huang, Suhas Arehalli, Mari Kugemoto, Christian Muxica, Grusha Prasad, Brian Dillon, and Tal Linzen. Large-scale benchmark yields no evidence that language model surprisal explains syntactic disambiguation difficulty. **Journal of Memory and Language**, Vol. 137, p. 104510, August 2024.
- [10] David Marr. **Vision: A Computational Investigation into the Human Representation and Processing of Visual Information**. W. H. Freeman and Company, San Francisco, 1982.
- [11] John T. Hale. **Automaton Theories of Human Sentence Comprehension**. CSLI Studies in Computational Linguistics. CSLI Publications, Stanford, CA, 2014.
- [12] D. C. Mitchell. An Evaluation of Subject-Paced Reading Tasks and Other Methods for Investigating Immediate Processes in Reading 1. In **New Methods in Reading Comprehension Research**. Routledge, 1984.
- [13] Lyn Frazier. ON COMPREHENDING SENTENCES: SYNTACTIC PARSING STRATEGIES. **Doctoral Dissertations**, pp. 1–243, January 1979.
- [14] Janet Dean Fodor and Fernanda Ferreira. **Reanalysis in Sentence Processing**. Studies in Theoretical Psycholinguistics ; v.21. Kluwer Academic Publishers, Dordrecht ;, 1998.
- [15] Samuel Kiegeland, Ethan Wilcox, Afra Amini, David Robert Reich, and Ryan Cotterell. Reverse-Engineering the Reader. In **Proceedings of the 2024 Conference on Empirical Methods in Natural Language Processing**, pp. 9367–9389, Miami, Florida, USA, January 2024. Association for Computational Linguistics.
- [16] Marcel A. Just and Patricia A. Carpenter. A theory of reading: From eye fixations to comprehension. **Psychological Review**, Vol. 87, pp. 329–354, 1980.
- [17] Ethan G. Wilcox, Jon Gauthier, Jennifer Hu, Peng Qian, and Roger P. Levy. On the Predictive Power of Neural Language Models for Human Real-Time Comprehension Behavior. In **Proceedings of the Annual Meeting of the Cognitive Science Society**, Vol. 42, 2020.
- [18] Alec Radford, Jeff Wu, Rewon Child, David Luan, Dario Amodei, and Ilya Sutskever. Language models are unsupervised multitask learners. 2019.
- [19] Steven G. Luke and Kiel Christianson. The Provo Corpus: A large eye-tracking corpus with predictability norms. **Behavior Research Methods**, Vol. 50, No. 2, pp. 826–833, April 2018.
- [20] Richard Futrell, Edward Gibson, Harry J. Tily, Idan Blank, Anastasia Vishnevetsky, Steven Piantadosi, and Evelina Fedorenko. The Natural Stories Corpus. In **Proceedings of the Eleventh International Conference on Language Resources and Evaluation (LREC 2018)**, Miyazaki, Japan, May 2018. European Language Resources Association (ELRA).
- [21] Stefan L. Frank, Irene Fernandez Monsalve, Robin L. Thompson, and Gabriella Vigliocco. Reading time data for evaluating broad-coverage models of English sentence processing. **Behavior Research Methods**, Vol. 45, No. 4, pp. 1182–1190, December 2013.
- [22] Robyn Speer. Rspeaker/wordfreq: V3.0. Zenodo, September 2022.
- [23] Byung-Doh Oh and William Schuler. Leading Whitespaces of Language Models’ Subword Vocabulary Pose a Confound for Calculating Word Probabilities. In **Proceedings of the 2024 Conference on Empirical Methods in Natural Language Processing**, pp. 3464–3472, Miami, Florida, USA, January 2024. Association for Computational Linguistics.
- [24] Tiago Pimentel and Clara Meister. How to Compute the Probability of a Word. In **Proceedings of the 2024 Conference on Empirical Methods in Natural Language Processing**, pp. 18358–18375, Miami, Florida, USA, January 2024. Association for Computational Linguistics.

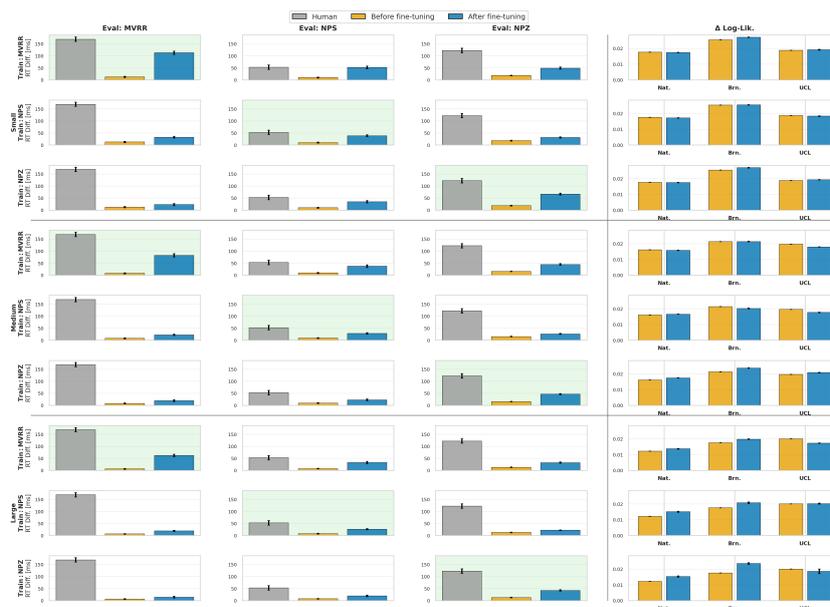


図 4 左：現象間転移の結果 (ROI=1)。それぞれのパネルはモデルサイズ (上から small, medium, large) に対応する (参照：図 3)。右：単一現象学習時の、自然文への影響 (参照：図 2)。

オプティマイザ	AdamW
学習率スケジューラ	Cosine annealing with warm restarts
バッチサイズ	66/44
ステップ数	500
ウォームアップステップ数	3
最大学習率	$5.25 \times 10^{-5} / 3.5 \times 10^{-5}$
最小学習率	$7.8 \times 10^{-8} / 5.2 \times 10^{-8}$
最大学習率減衰率	0.01
正則化項の重み λ	100

表 1 微調整のハイパーパラメタ

A ガーデンパス文の具体例

Main Verb/Reduced Relative Clause (MVRR) *fed* が、主動詞/縮約関係節を構成する過去分詞の間の曖昧性。

- (2) a. The girl fed the lamb *remained* relatively calm. . .
 b. The girl who was fed the lamb *remained* relatively calm. . .

Noun Phrase/Sentential Complement (NPS) *the lamb* が、*found* の直接目的語/補文の主語の間の曖昧性。

- (3) a. The girl found the lamb *remained* relatively calm. . .
 b. The girl found that the lamb *remained* relatively calm. . .

Noun Phrase/Zero (NPZ) *the lamb* が、*attacked* の直接目的語/主節の主語の間の曖昧性。

- (4) a. When the girl attacked the lamb *remained* relatively calm. . .
 b. When the girl attacked, the lamb *remained* relatively calm. . .

B ハイパーパラメタ

微調整のハイパーパラメタを、表 1 に示した。スラッシュで分割されている値は、前者が 3 種類すべての統語的曖昧性の文を用いた学習時の値、後者が単一種類の文のみでの学習時の値に対応する。

C 現象間転移

すべてのモデルサイズの ROI=1 における現象間転移の結果を図 4 に示した。