

---

# Visualizando e modelando dados em aquisição da linguagem

Guilherme D. Garcia

Université Laval | [gdgarcia.ca](https://gdgarcia.ca)

II SEMINÁRIO INTERNACIONAL DE PESQUISAS EM ENSINO E APRENDIZAGEM DE LÍNGUAS:  
ABORDAGENS QUANTITATIVA E MISTA

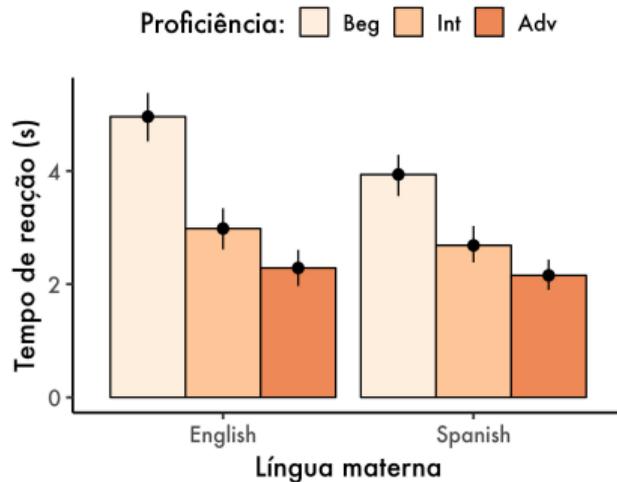
Outubro, 2023



# Por que visualizar dados?

Maximizar a compreensão de padrões empíricos

	L1	Proficiency	$\bar{x}$	95% CI
1	English	Beg	4.96	[5.38, 4.53]
2	English	Int	2.98	[3.36, 2.60]
3	English	Adv	2.29	[2.60, 1.98]
4	Spanish	Beg	3.94	[4.30, 3.57]
5	Spanish	Int	2.68	[3.02, 2.35]
6	Spanish	Adv	2.16	[2.42, 1.89]

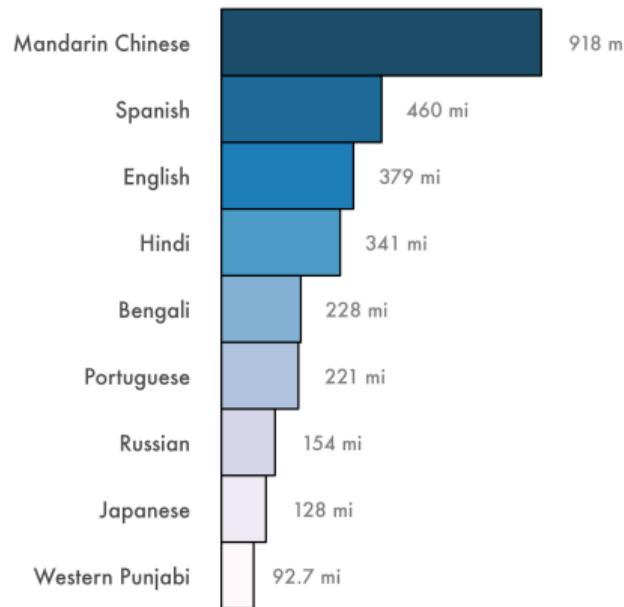
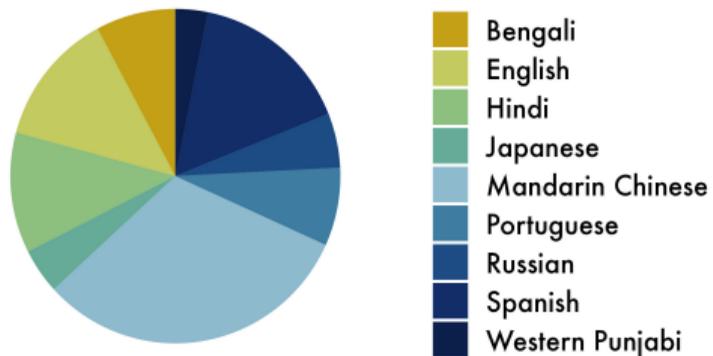


- Dados de Garcia (no prelo): [doi.org/10.31219/osf.io/8r4ec](https://doi.org/10.31219/osf.io/8r4ec)



# Por que visualizar dados?

Maximizar a compreensão de padrões empíricos



# Por que visualizar dados?

## Pré-submissão

- Exploração de padrões
- Ajuste de método

## Publicação

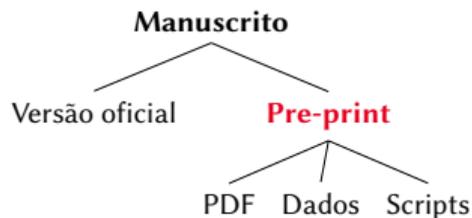
- Clareza metodológica
- Eficiência comunicativa

👉 Estudos de aquisição: **muitos dados + variação** → uma razão específica importante

# Antes de começarmos

## Uma estrutura recomendada

- A noção de [Open science](#): acesso livre a estudos e publicações



- Repositórios como [OSF](#) são altamente recomendados
- Acesso livre, SEO, controle sobre formatação e atualizações, etc.
- ☞ Algumas revistas (formato físico) tendem a **limitar** tipos de visualização (e.g., cores)

# O problema

- Estudos de aquisição subutilizam métodos quantitativos
- O mesmo pode ser dito sobre **exploração visual** de dados

(Plonsky 2011)

- ☞ Dados não explorados costumam ser dados pouco compreendidos  
*Análises inapropriadas, resultados pouco confiáveis*

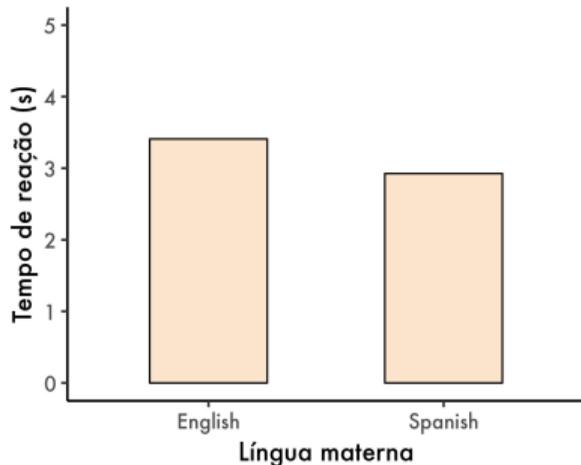
**Agravante:** modelos complexos são facilmente executados hoje em dia

# DADOS CONTÍNUOS

# Exemplo

## Padrões gerais

- Dois grupos de aprendizes de francês: línguas maternas inglês e espanhol
- Dados: tarefa de escolha forçada → acurácia (0/1), tempo de reação (s) e certeza (1–4)

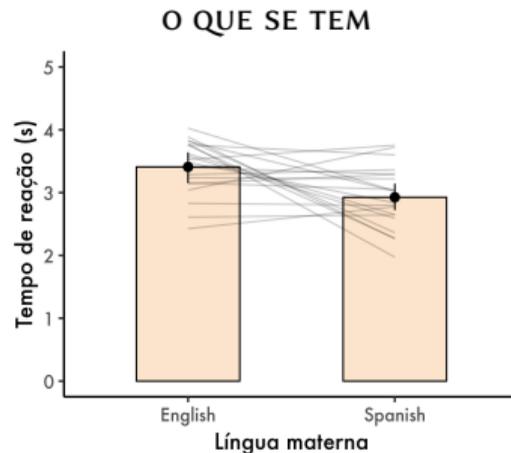
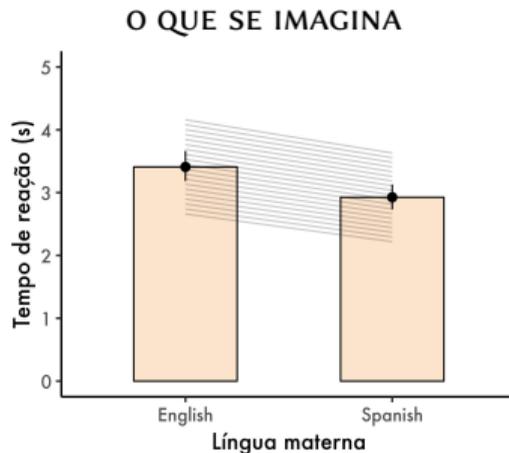
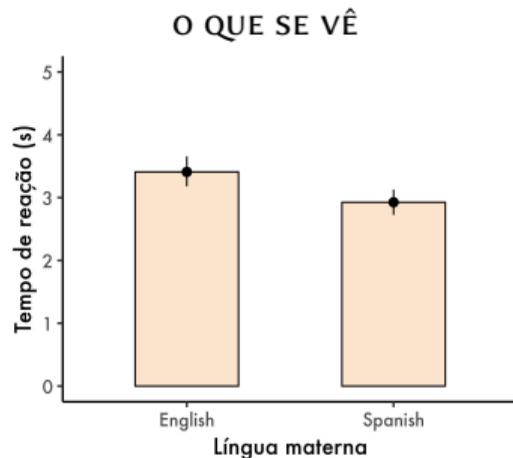


- Pouca informação ( $\bar{x}$ ): duas variáveis
- Ausência de barras de erro
- ☞ Omissão de **variação**

# Exploração visual

## Visualizando variação: itens

- Comportamento de aprendizes: **raramente** constante para todos os **itens** de um estudo

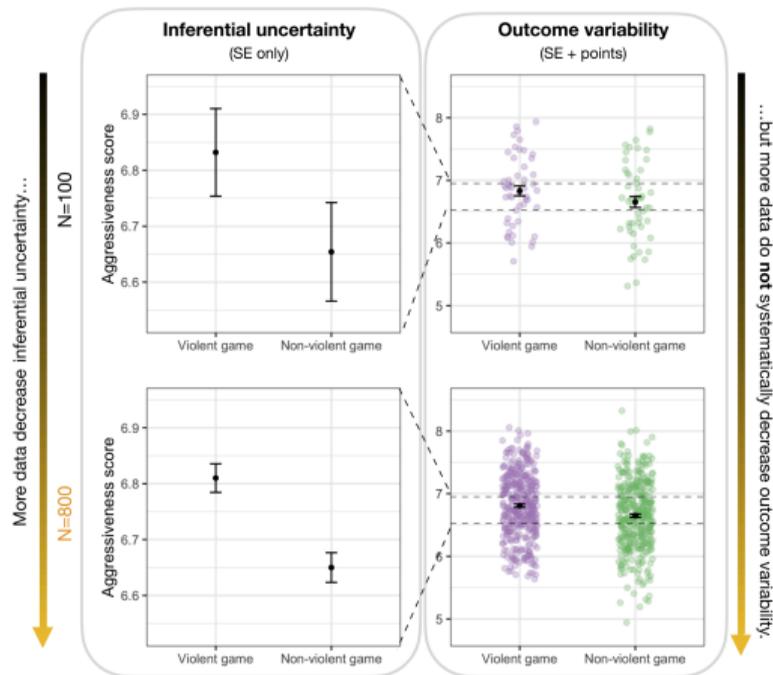


# Exploração visual

## A ilusão da magnitude de efeitos

- Incerteza inferencial vs variabilidade
- Percepções **bastante** distintas

👉  $n$  pode não resolver o problema

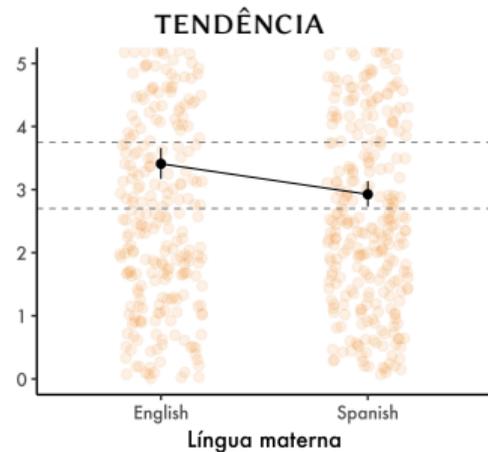
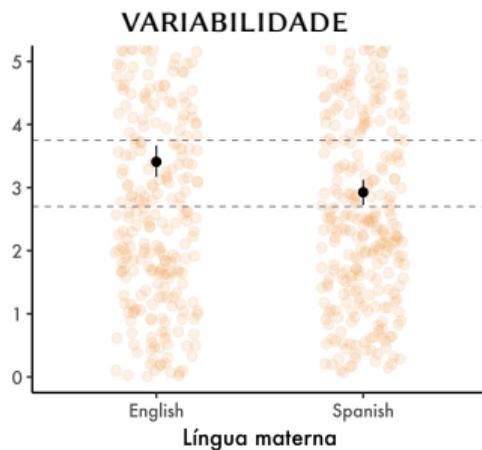
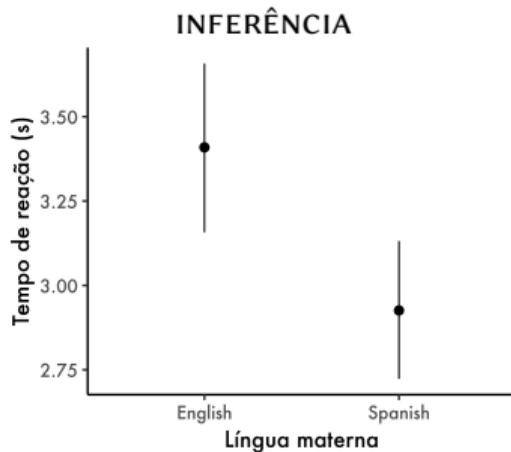


(Zhang et al. 2023, p. 2)

# Do geral ao específico

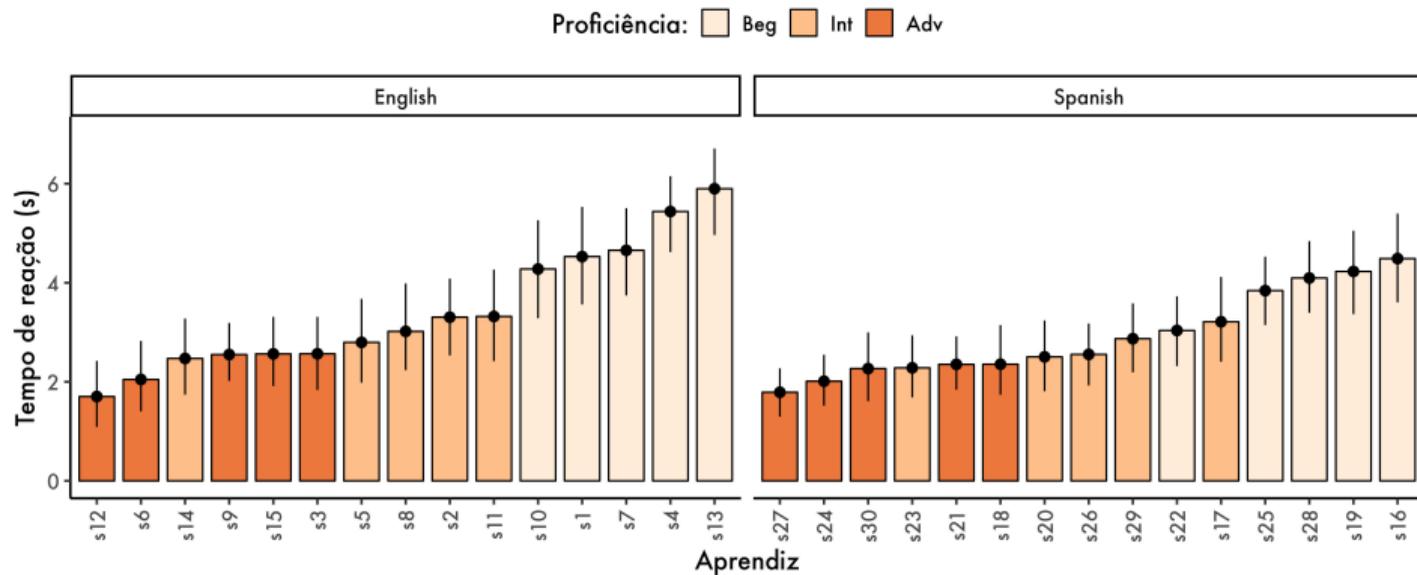
## A ilusão da magnitude de efeitos

- Gráficos afetam nossa conclusão sobre o tamanho do efeito de L1



# Exploração visual

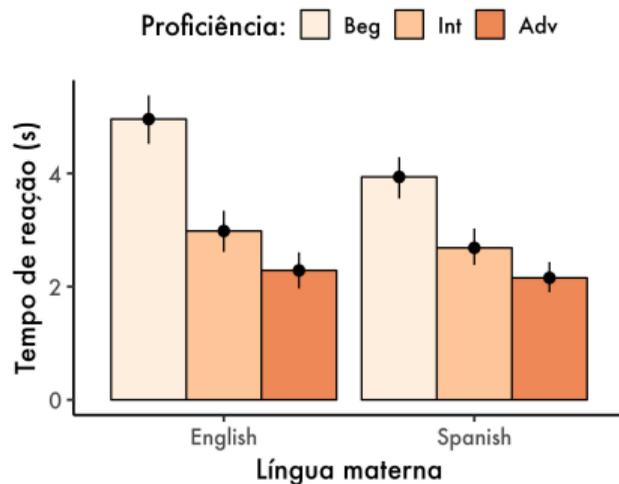
## Visualizando variação: aprendizes



- Variação em tempo de reação: aprendizes, língua materna, e níveis de proficiência

# Exploração visual

- Tanto língua materna quanto proficiência são relevantes em nossa exploração
- ☞ Variável principal: **proficiência** (L1 *provavelmente* não terá um efeito substancial)

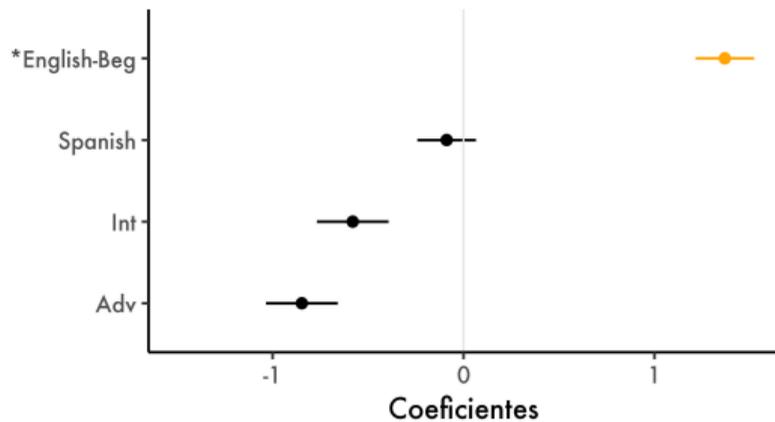


# Análise

## Visualização de modelos estatísticos

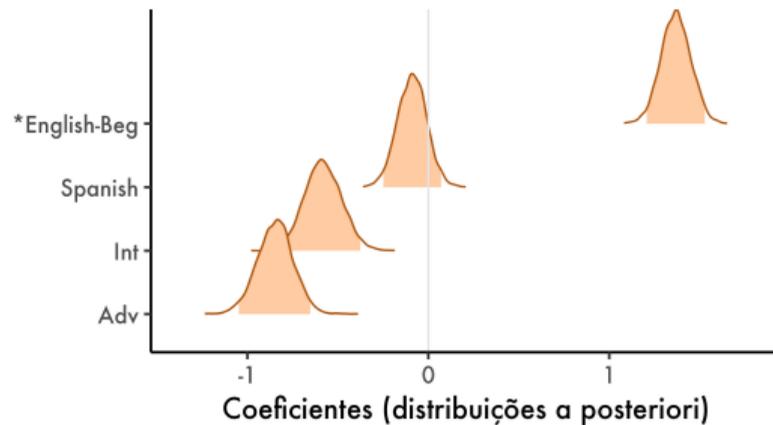
### Frequentista

Intervalos de confiança 95%



### Bayes

Intervalos de credibilidade 95%

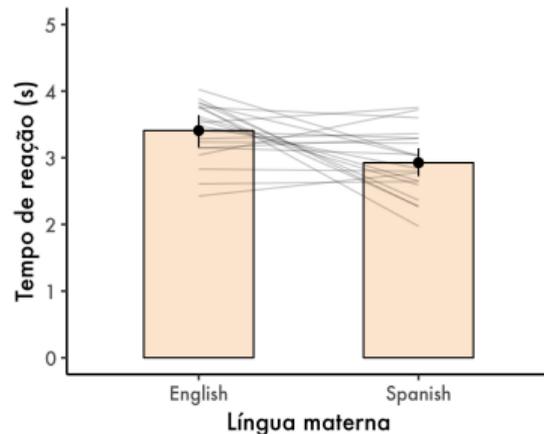
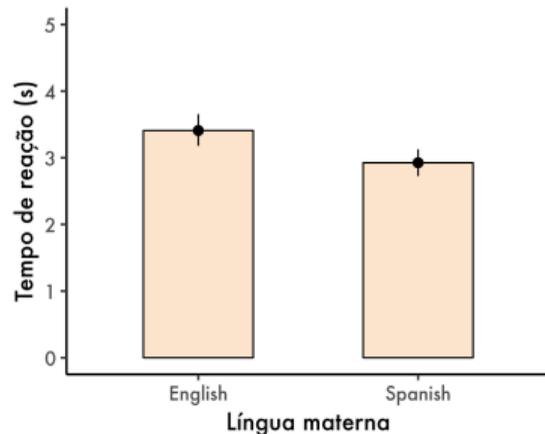


# Análise

## Visualização de modelos estatísticos

- Nem toda variação precisa ser incluída em um modelo: aqui, **fit singular**
  - Complexidade excessiva quando consideramos variáveis principais + efeitos aleatórios
- 👉 Aqui, **L1 + Proficiência**  $\succ$  **variabilidade de item e aprendiz**

**Dúvida:** qual das duas figuras será mais apropriada?



## DADOS ORDINAIS

# Exploração visual

## Escalas

- Escalas são frequentemente usadas em estudos de aquisição

*Qual o seu grau de certeza sobre sua resposta?*

1	2	3	4
---	---	---	---

- ☞ Como variáveis binárias, variáveis ordinais muitas vezes exigem **transformações**

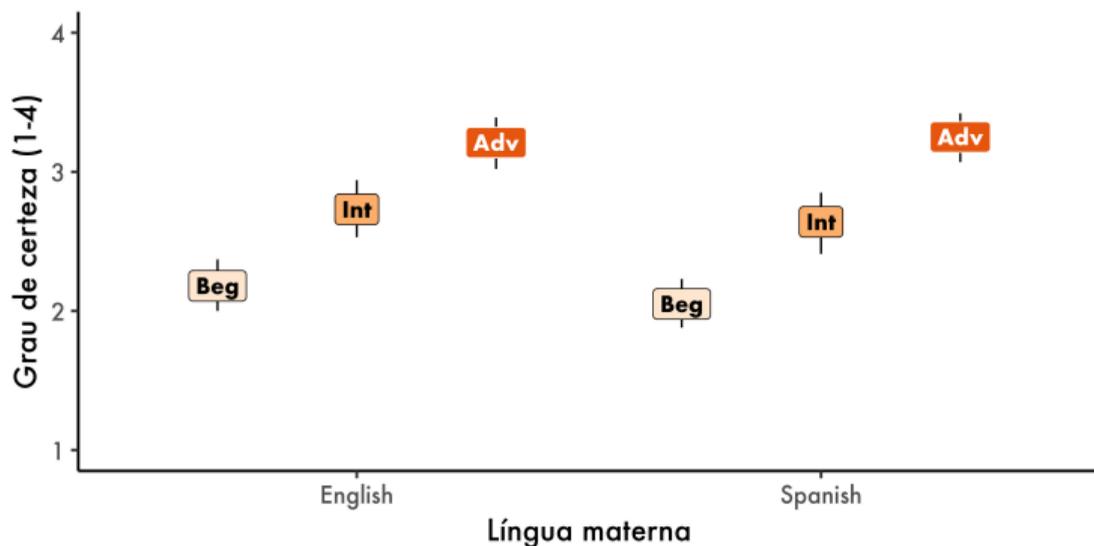
### Como visualizar escalas...?

- ☞ Discussão baseada em Garcia (2021, caps. 5 e 8) e Garcia (no prelo)

# Exploração visual

## Escalas

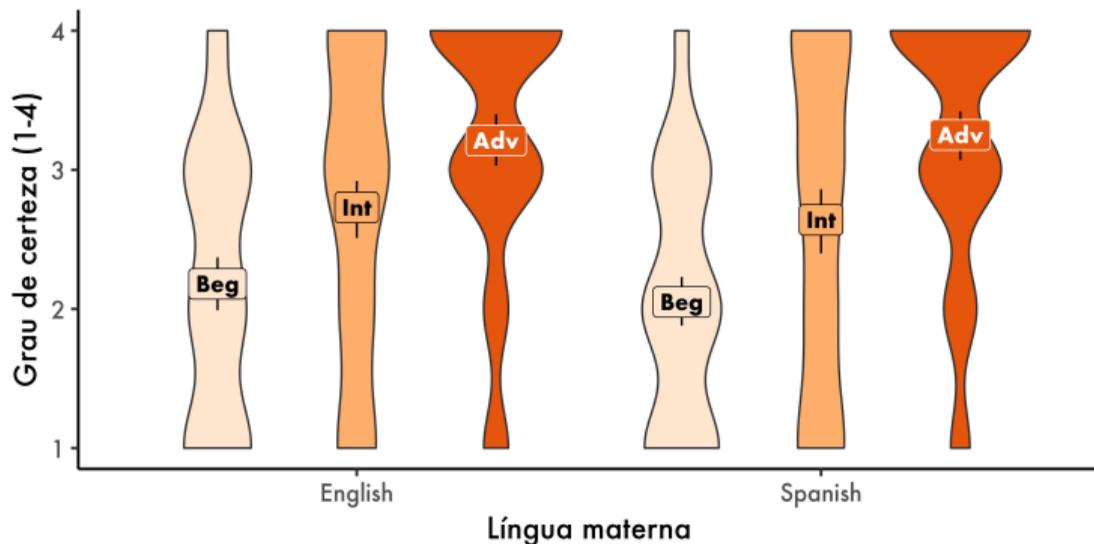
- Dados ordinais não são contínuos (**ordered factor**)
- Distribuição raramente normal → médias são pouco representativas



# Exploração visual

## Escalas

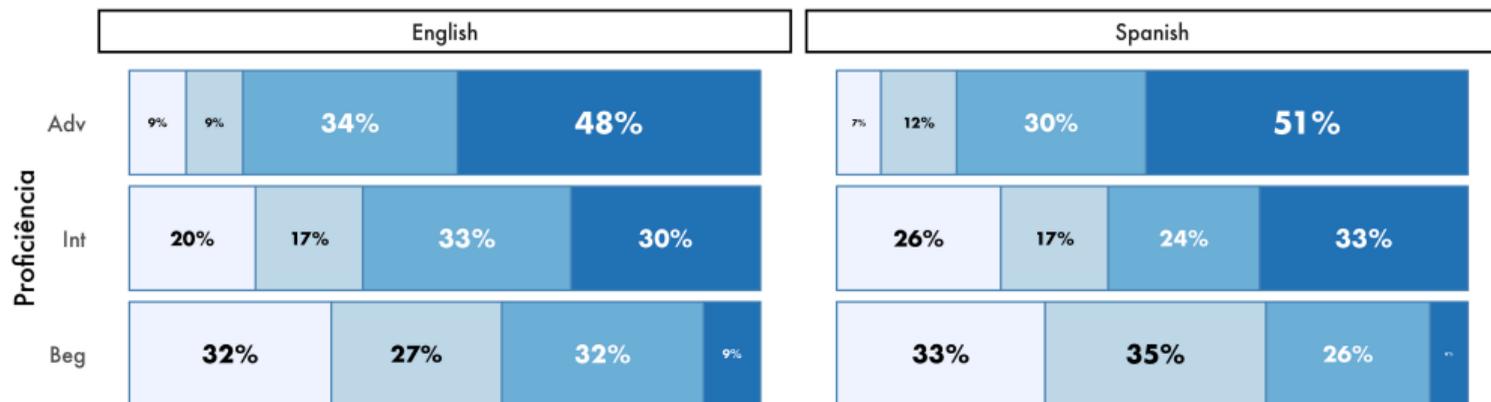
- Dados ordinais não são contínuos (**ordered factor**)
- Distribuição **raramente normal** → médias são pouco representativas



# Exploração visual

## Escalas

- Visualização **sem** transformação → melhor alinhamento com modelos ordinais
- Barras e cores que espelham escala original (adaptado de Garcia 2021, p. 100)



Escala de certeza: 1-4

# Exploração visual

## Escalas

- Escala de cinza para publicações físicas (note que, mais uma vez, proficiência  $\succ$  L1)
- Fácil adaptação com diferentes paletas no `ggplot2`



Escala de certeza: 1-4

# Exploração visual

## Escalas

### Preparação de dados

1. Agrupar variáveis relevantes
2. Contar  $n$  para cada ponto da escala
3. Calcular porcentagens

```
code
1 prop = viz ▷
2   summarize(n = n(),
3             .by = c(L1, Proficiency, Certainty)) ▷
4   mutate(Prop = n / sum(n),
5          .by = c(L1, Proficiency),
6          Dark = if_else(Certainty %in% c("3", "4"),
7                          "yes", "no"))
```

☞ Utilização de *dummy variables* para maior personalização em gráficos (linhas 6–7)

## PREVISIBILIDADE DE DADOS

# Qual o propósito de uma análise?

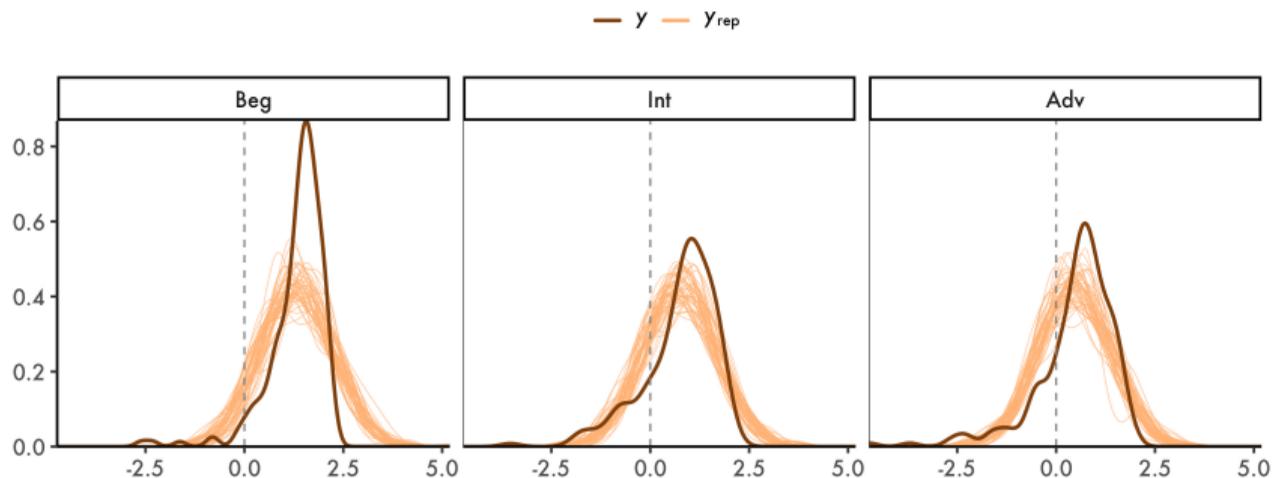
1. Examinar o papel de variáveis dentro de um estudo com bases teóricas específicas
2. Gerar o melhor modelo possível para prever novos dados (e.g., *machine learning*)
3. ...

- ☞ Normalmente, o desejo de previsibilidade está relacionado ao objetivo 2
  - Mas visualizar previsões de nossos modelos pode ser bastante informativo

# Qual o propósito de uma análise?

## Posterior predictive check

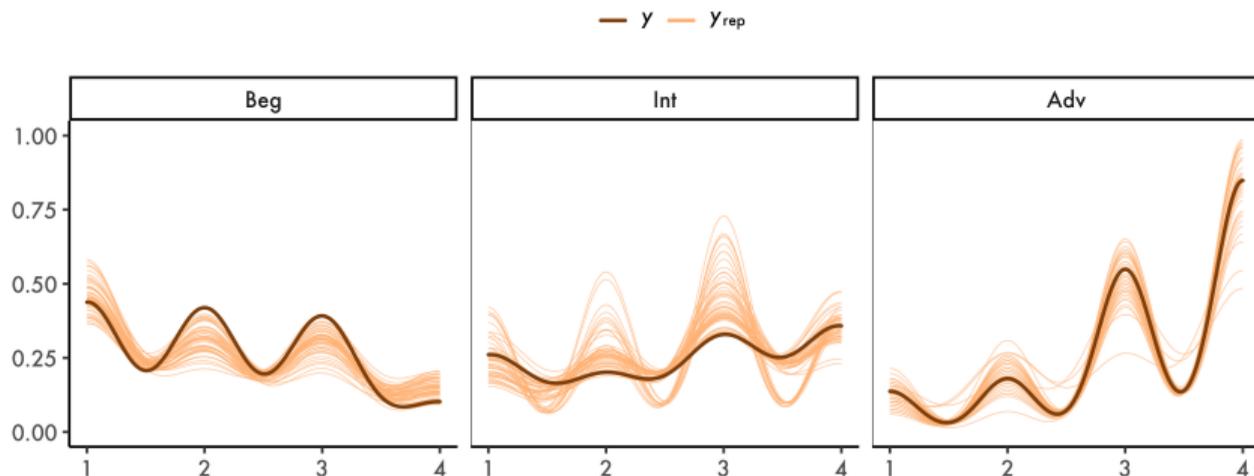
- Comparação entre dados reais e dados simulados a partir do modelo
- Modelo que examina **tempos de reação** (log) em função de L1 e proficiência:



# Qual o propósito de uma análise?

## Posterior predictive check

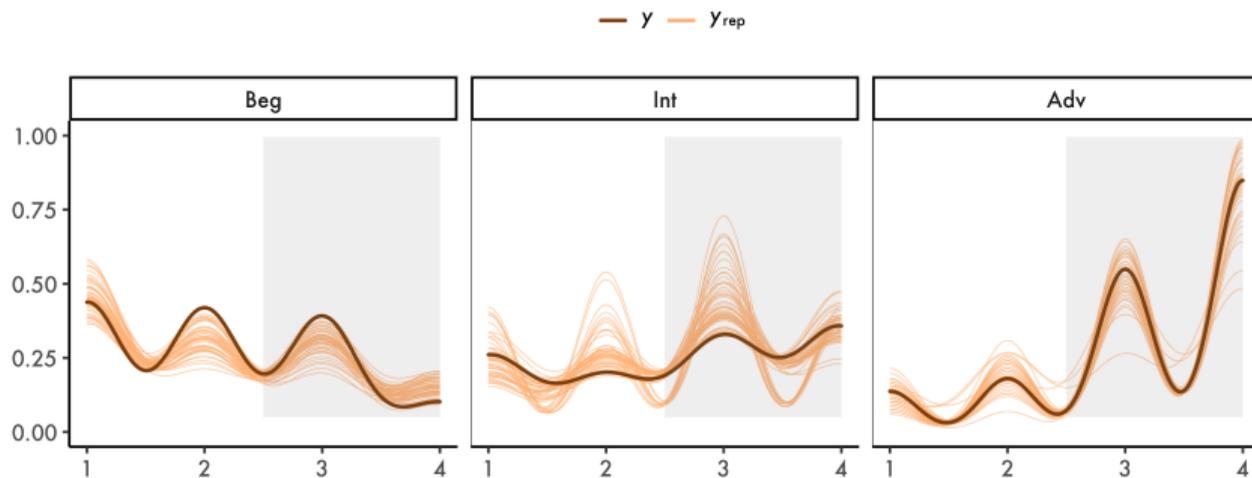
- Comparação entre dados reais e dados simulados a partir do modelo
- Modelo que examina **certeza** em função de L1 e proficiência:



# Qual o propósito de uma análise?

## Posterior predictive check

- Comparação entre dados reais e dados simulados a partir do modelo
- Modelo que examina **certeza** em função de L1 e proficiência:



## Considerações e sugestões finais

- Visualizar dados antes, durante, e depois da análise
- Considerar aspectos estéticos com cuidado: cores, tamanhos, quantidade de informação
- Alinhar visualização com análise e objetivos: maximizar eficiência
- Ter presença online para divulgação de materiais (pre-prints + extras)

# Recursos visuais

## Pacotes em R

- [tidyverse](#) ([ggplot2](#))
- [plotly](#) (gráficos interativos)
- [MoMAColors](#)
- [RColorBrewer](#)

## Links e livros

- [r4ds.hadley.nz](#)
- [gdgarcia.ca](#) + [blog](#)
- Garcia (2021, 2023)
- Winter (2019)

👉 Estes slides já estão disponíveis em [gdgarcia.ca](#)

Muito

BRIGADO!

Dúvidas?



# References I

- Garcia, G. D. (2021). *Data visualization and analysis in second language research*. New York, NY: Routledge.
- Garcia, G. D. (2023). Quantitative data visualization. In C. A. Chapelle (Ed.), *The Encyclopedia of Applied Linguistics*. John Wiley & Sons, Ltd. To appear. Pre-print, data and code available at <https://doi.org/10.31219/osf.io/8r4ec>.
- Plonsky, L. (2011). *Study quality in SLA: A cumulative and developmental assessment of designs, analyses, reporting practices, and outcomes in quantitative L2 research*. Ph. D. thesis, Michigan State University.
- Winter, B. (2019). *Statistics for linguists: an introduction using R*. New York: Routledge.
- Zhang, S., P. R. Heck, M. N. Meyer, C. F. Chabris, D. G. Goldstein, and J. M. Hofman (2023). An illusion of predictability in scientific results: Even experts confuse inferential uncertainty and outcome variability. *Proceedings of the National Academy of Sciences* 120(33), e2302491120.