A Terra é Plana ($p < 0,05$) parte I.: Aprimorando as Inferências Estatísticas em Psicologia

The Earth is Flat ($p < 0.05$) Part I. Improving Statistical Inferences in Psychology

Jonas Caio Costa Porfírio

Universidade Federal de Pernambuco

Novembro de 2019

Nota: esta pré-impressão não foi revisada por pares e pode sofrer alterações significativas antes de publicação. Por favor, verifique as revisões e atualizações antes de citar.

Caio Costa, doutorando. Tel : 081 9 9503-3981 Email: costa.psy@gmail.com ORCID

ID: <https://orcid.org/0000-0002-6811-1407> Endereço: Universidade Federal de

Pernambuco (UFPE) / Programa de Pós-graduação em Psicologia Cognitiva/ Centro de

Filosofia e Ciências Humanas / 8º andar – Cidade Universitária – Recife – PE – CEP:

50740-550

Resumo

A baixa taxa de replicação dos estudos na ciência e especificamente na psicologia criou uma crise de replicabilidade. Aponta-se, na literatura, que problemas de ordens metodológica e de interpretação dos dados nas pesquisas científicas tornam os resultados das investigações científicas pouco confiáveis. Para abordagem desses problemas, parâmetros metodológicos e estatísticos podem ser ajustados para que nossos resultados forneçam informações consistentes e mais confiáveis. Assim, destaca-se dois tipos de erros que podem ocorrer na execução da testagem de hipóteses que são fundamentais na construção de uma ciência cumulativa: o Erro do tipo I e o Erro do tipo II, além de possíveis abordagens para diminuir a probabilidade de cometer tais erros. Nas partes II e III dessa série, testes de equivalência e uso de fatores de Bayes como complementos aos nossos testes de hipótese padrões serão abordados.

Palavras-chave: métodos de pesquisa; estatística inferencial; teste de hipóteses.

The Earth is Flat ($p < 0,05$) part I.: Improving Statistical Inferences in Psychology

Abstract

The low rate of replication of studies in science and specifically in psychology has created a crisis of replicability. It is pointed out in the literature that problems of methodological orders and interpretation of data in scientific research make the results of scientific investigations unreliable. To address these problems, methodological and statistical parameters can be adjusted so that our results provide consistent and more reliable information. Thus, we highlight two types of errors that may occur in the execution of the hypothesis testing that are fundamental in the construction of a cumulative science, Type

I Error and Type II Error in addition to possible approaches to reduce the probability of committing such errors. In parts II and III of this series, equivalence tests and use of Bayes factors as complements to our standard hypothesis tests will be addressed.

Keywords: research methods; inferential statistics; hypothesis test.

Alegações extraordinárias exigem evidências extraordinárias. (Carl Sagan)

Introdução

A Crise da Replicabilidade na Psicologia

Há algum tempo, debate-se sobre existência de uma crise de replicabilidade na ciência (OSC, 2015). Cientistas começaram a criar a consciência de que os resultados publicados são muito menos replicáveis do que se esperaria considerando a alta taxa de resultados com “significância estatística” $p \leq 0,05$ (Wagenmakers et al., 2018). Tom Siegfried (2010) argumenta que esse é o segredo mais sujo da ciência: o *método científico* de testar hipóteses por meio de análise estatística está em uma base frágil. Problemas relacionados ao mau uso da estatística e interpretações inadequadas do *p-valor* tornaram muitos achados de pesquisa falsos (Ioannidis, 2005), não confiáveis (Ioannidis, 2015) ou ainda inúteis (Ioannidis, 2016).

Nate Silver (2013) argumenta que veremos artigos aparentemente sérios afirmando que sapos podem prever terremotos e que grandes lojas de departamentos, como a Target, dão origem a grupos que estimulam o ódio racial. Esses aplicam testes de hipótese para produzir descobertas com significância estatística, porém, falaciosas. Portanto, um único estudo é raramente, ou nunca, definitivo. A evidência pode vir de

uma replicação, que, com metanálise, deve fornecer estimativas mais precisas (Cumming, 2014).

No ano de 2015, foi criada uma força tarefa para estimar o índice de replicabilidade na psicologia. Renomados cientistas de todo mundo tentaram replicar 100 estudos clássicos da psicologia. Conseguiram replicar apenas 37% dos achados (OSC, 2015). Mais recentemente, outra estimativa apontou que esse índice poderia estar, na verdade, em torno de 51%, com diferenças em várias subdisciplinas da psicologia (Schimmack, 2019b). Com relação aos tamanhos dos efeitos, os Intervalos de Confiança de 95% dos efeitos de replicação continham o efeito original em apenas 47,4% dos estudos. Mais especificamente, o efeito médio diminuiu de $r = 0,40$ nos estudos originais para $r = 0,20$ nos estudos de replicação. Resultados semelhantes foram encontrados por Klein et al. (2018), em que o efeito mediano de 28 estudos diminuiu de $d = 0,60$ nos estudos originais para $d = 0,15$ nos estudos de replicação.

Portanto, evidencia-se um problema. Inicialmente, a baixa taxa de replicação dos achados na psicologia com a melhor das estimativas de 51%. Além disso, os estudos que alcançaram significância estatística apresentaram resultados insatisfatórios em termos de tamanho do efeito, com acentuado decréscimo no estudo de replicação. Esse é um problema da psicologia ou do mau uso e interpretação inadequada do teste de significância da hipótese nula? No tópico seguinte, descreve-se algumas possíveis causas para o problema.

Causas

Apontou-se as prováveis e aparentes causas desta crise: o tamanho das amostras utilizadas nos estudos (OSC, 2015); a falta de transparência e flexibilidade não declarada na análise de dados (Simmons, Nelson & Simonsohn, 2011), não

disponibilização dos dados e instrumentos utilizados (Allen & Mehler, 2019), testagem de hipóteses baseadas na hipótese nula (Wegenmakers, 2011), dependência do valor p (Cumming, 2014), valor p muito alto (0,05) (Benjamin et al, 2018), subutilização de intervalos de confiança (Cumming, 2014), subutilização de medidas de tamanho de efeito (Lakens, 2013), problemas na interpretação do *valor p* (Colquhoun, 2017) e teóricas (Muthukrishna & Henrich, 2019), como teorias derivadas do senso comum e de empirismo cego (Cosmides & Tooby, 2015).

Soluções

Como possíveis soluções metodológicas para esta crise, autores apontaram a necessidade de abandonar o uso de estatística frequentista (Wegenmakers et al., 2011), testagem de hipóteses utilizando o nível de significância mais baixo (por exemplo, $p=0,001$) (Benjamin et al, 2018), uso de intervalos de confiança em substituição ao valor p (Cumming, 2014), estudos pré-registrados (Nosek & Lakens, 2016), cálculos do tamanho da amostra necessário para um poder estatístico adequado (Conhen, 2013), testes de equivalência (Lakens, 2017) e uso e correta interpretação de tamanhos de efeito (Lakens, 2013).

Em relação a possíveis problemas teóricos, apontou-se a necessidade de derivar hipóteses a partir de uma estrutura teórica abrangente, que unifique o campo da psicologia, como a teoria da evolução de Darwin, na qual poderiam ser derivadas variadas hipóteses sobre o comportamento humano (Muthukrishna & Henrich, 2019) com alto poder explanatório.

Outra possível solução proposta pelos pesquisadores para o problema da replicação da psicologia vem dos proponentes da chamada nova estatística (Calin-Jageman & Cumming, 2019; Cumming, 2014; Cumming & Calin-Jageman, 2016).

Estes pesquisadores defendem que existe uma limitação na nossa abordagem da testagem de hipóteses a partir da interpretação dos *valores p* observados. Assim, tais autores defendem que índices estatísticos como intervalos de confiança (um tipo de estimativa por intervalo de um parâmetro populacional desconhecido), o uso e interpretação de tamanhos de efeito (um valor que nos informa a possível relevância práticas dos achados da testagem de hipóteses pelo grau de um efeito estimado para população) e o uso do *raciocínio metanalítico* (inferências sobre relações entre variáveis à partir de resultados de variados estudos para estimar um valor hipotético aproximado do grau do efeito em estimado na população) são fundamentais para aprimorarmos nossas inferências estatísticas.

Finalmente, apontou-se possíveis fatores individuais se relacionando com fatores institucionais para a baixa replicabilidade na psicologia (Bakker, van Dijk, & Wicherts, 2012). Assim, nas *regras do jogo* da psicologia, uma regra dominante provavelmente seria a de coletar resultados estatisticamente significativos, pois estes estudos terão uma maior probabilidade de serem publicados – criando os chamados vieses de publicação. De acordo com os autores, revisões da literatura apontaram que cerca de 96% dos trabalhos envolvendo o uso de teste de significância de hipótese nula relataram resultados significativos para seus principais resultados, entretanto os estudos possuíam baixa poder estatístico para possuírem essa alta taxa de resultados positivos. Nesse sentido, o uso de várias amostras pequenas e de baixo poder é uma estratégia de pesquisa eficiente (no sentido de encontrar $p < 0,05$) do que o uso de uma amostra maior e mais potente. Vieses de publicação e uso destas estratégias mais “eficientes” resultam em efeitos inflados e altas taxas de falsos positivos.

Tendo em vista tais debates na literatura, nossos objetivos nesse trabalho são abordar o chamado erro tipo I e erro tipo II. Inicialmente, serão destacadas algumas

formas de abordar dificuldades metodológicas relacionadas a esses erros e tornar os resultados de nossos estudos mais confiáveis e consistentes, o que consequentemente resultará em maior replicabilidade de nossos estudos. Nesse sentido, parâmetros fundamentais podem ser ajustados para que nossas testagens forneçam informações consistentes e mais confiáveis. Além disso, formas de abordar esses possíveis erros serão apontados. Na sessão seguinte, discorreremos sobre hipóteses para posteriormente abordar os problemas na testagem de hipóteses.

Hipóteses e Testagem de Hipóteses

Na abordagem estatística mais utilizada pelos cientistas (incluindo cientistas do comportamento), a estatística frequentista, denomina-se a testagem de hipóteses como *testagem de hipóteses baseada no modelo nulo* (do inglês *null hypothesis testing model*). Nesse tipo de testagem, fazemos inferências sobre nossas hipóteses a partir da observação da distribuição dos dados em relação a uma hipotética distribuição (baseada em simulações) que ocorreria se o *modelo nulo* fosse verdadeiro (se não existisse um determinado efeito na população). Se a distribuição ocorre abaixo de um valor de probabilidade estabelecido (normalmente 0,05) inferimos que *provavelmente* aquela distribuição não ocorreu ao acaso e nossos dados são *surpreendentes* tendo em vista que o modelo nulo seria correto *a priori*. Ou seja, é bastante improvável que aquela distribuição tenha ocorrido ao acaso (mas não impossível). Em relação a este tipo de inferência, é importante destacar que sempre é realizada a partir dos nossos dados e na observação da distribuição destes nas nossas tomadas de decisão estatísticas, não fazemos uma testagem *direta* na nossa hipótese (hipótese alternativa) ou da hipótese nula. Assim, nossas afirmações nos resultados sempre se referem aos dados coletados e não às hipóteses levantadas *diretamente* (Nickerson, 2000).

Daniel (2002) apresenta algumas características que boas hipóteses devem possuir: simplicidade, especificidade e apresentação anterior a uma investigação. Uma hipótese simples contém uma variável preditora e uma variável resposta (por exemplo, uso de jogos eletrônicos resulta em maior agressividade). Uma hipótese complexa pode conter mais de uma variável preditora e várias variáveis respostas (por exemplo, uso de jogos eletrônicos e isolamento social resultam em maior agressividade e traços depressivos) mas, da mesma forma, as variáveis e direções de relações estão explícitas.

Uma hipótese específica não deixa qualquer ambiguidade sobre os sujeitos e variáveis ou sobre como o teste de significância será aplicada. Ela usa informações operacionais concisas e definições que resumem a natureza e a origem dos sujeitos e a abordagem para medir variáveis (por exemplo, adolescentes que fazem uso excessivo de jogos eletrônicos, a partir de instrumento para medir esse uso, apresentam maiores níveis de agressividade, medido por outro instrumento específico).

A hipótese deve ser declarada por escrito na apresentação do projeto. Isso ajudará a manter o esforço de pesquisa focado no objetivo principal e criar um ambiente mais consistente para interpretar os resultados do estudo em comparação com hipótese que surgem como resultado da chamada mineração dos dados (*data dredging*), uma prática de pesquisa eticamente questionável (John, Lowenstein, & Prelec 2012).

Erro tipo I tipo II

Um erro do tipo I (falso-positivo) ocorre se um investigador rejeitar uma hipótese nula (H_0) que é realmente verdadeira na população, já um erro tipo II (falso-negativo) ocorre se o investigador *não* rejeita uma hipótese nula que é realmente falsa na população. Já os chamados taxas de erros cruciais do tipo I e do tipo II (O'Brien & Casteloe, 2007) são as probabilidades de que a hipótese nula é verdadeira quando é

rejeitada e a probabilidade de que a hipótese nula é falsa quando não é rejeitado. Muitos pesquisadores acham que estes erros cruciais são os símbolos α e β , mas as fórmulas para essas taxas de erros cruciais são α^* :

$$\begin{aligned}\alpha^* &= Prob (H_0 \text{ verdadeira} | p \leq \alpha) \\ &= \frac{\alpha (1 - \gamma)}{\alpha (1 - \gamma) + (1 - \beta) \gamma}\end{aligned}$$

E β^* :

$$\begin{aligned}\beta^* &= Prob (H_0 \text{ falsa} | p > \alpha) \\ &= \frac{\beta \gamma}{\beta \gamma + (1 - \alpha) (1 - \gamma)}\end{aligned}$$

Nestas fórmulas, α^* é a taxa de erro crucial tipo I e β^* é a taxa de erro crucial tipo II, α é a taxa de erro usual do tipo I, β é a taxa de erro usual do tipo II. γ é a probabilidade anterior de que a hipótese nula é falsa (a proporção de os estudos para os quais a hipótese nula é falsa) (O'Brien & Casteloe, 2007). Por essa fórmula deduz-se que outras variáveis sendo iguais, maior poder estatísticas reduz os dois tipos de erro crucial. Como resultado, os resultados estatísticos são mais confiáveis quando a potência estatística é alta. Uma forma de ilustrar a tomada de decisão na testagem de hipóteses é fazer uma analogia com uma decisão judicial em que o juiz parte do princípio de que o acusado é inocente e é preciso apontar boas evidências para o juiz ser convencido (Banerjee et al., 2009), como pode ser observado no Quadro 1.

Inserir quadro 1 aqui

O Quadro 2 ilustra as possíveis decisões e erros de decisões que um pesquisador pode tomar na interpretação dos resultados de um estudo com base na simulação de que um efeito seja real ou não na população.

Inserir quadro 2 aqui

Discussão

Abordando o erro do Tipo I

Evitando o Hackeamento do Valor p (p -hacking)

Com a necessidade de publicações para evolução na carreira, aliado a um viés para a publicação de resultados estatisticamente significativos nas revistas científicas (Bakker, van Dijk, & Wicherts, 2012), muitos cientistas fazem buscas por relações entre variáveis que não foram apresentadas anteriormente nas hipóteses levantadas e alteram as hipóteses quando encontram relações significativas. Essa é uma das chamadas *práticas eticamente questionáveis* (John, Lowenstein, & Prelec 2012) que tem várias denominações, como escavação de dados (*data dredging*) ou hackeamento do valor p (p -hacking). Um problema com essa prática é que virtualmente sempre se encontrará alguma correlação espúria entre alguma variável, após vários testes realizados, por simples aleatoriedade presente em qualquer conjunto de dados (Simmons, Nelson & Simonsohn, 2011). Assim, essa prática cria falsos positivos indiscriminadamente.

Práticas comuns que levam ao *hackeamento do valor p* incluem conduzir análises no meio de experimentos, para decidir se os dados devem continuar a serem coletados ou não; registrar muitas variáveis de resposta e decidir qual relatar após a análise; decidir se inclui ou descarta *outliers* após as análises; excluir, combinar ou dividir grupos de tratamento após a análise; incluir ou excluir covariáveis após a análise

e parar a exploração de dados se uma análise produzir um valor p desejado (Head et al., 2015). Portanto, como as possíveis relações não estavam hipotetizadas anteriormente, foge totalmente do escopo da investigação científica da testagem de hipóteses, deturpando totalmente seu objetivo (Daniel, 2002).

Ajustando o Alfa

Uma forma de diminuir a probabilidade de encontrar falsos positivos é o ajuste do nível de alfa (Chen, Feng, & Yi, 2017). Assim, um valor p será justificado de acordo com o número de hipóteses que se irá testar, não será estático por conveniência (Lakens et al., 2018). Existem várias formas de realizar esse procedimento (Chen, Feng, & Yi, 2017), mas o procedimento mais utilizado é a chamada *Correção de Bonferroni* (Bland & Altman, 1995). Com essa técnica, divide-se o valor p desejado pelo número de hipóteses que se está testando. Suponha X hipóteses sendo testadas simultaneamente (H_m) e valores de P calculados para H_m . Consequentemente, os valores de P de comparações múltiplas são denotados como $1p', \dots, Hmp'$. Os níveis de significância especificados anteriormente e ajustados são denotados como α e α' , respectivamente. Por exemplo, se forem testadas cinco hipóteses ($5H_m$) e o valor p desejado foi de 0,05, o valor Hmp' que seria utilizado para realizar os testes estatísticos (por exemplo, correlações de *Pearson*) seria o de 0,01. Na Tabela 1 são ilustradas simulações com o programa *G Power* (Faul et al., 2007) para diferentes números de hipóteses testadas.

Inserir Tabela 1 aqui

Esse teste foi criticado por ser muito conservador e não levar em conta as relações entre as variáveis analisadas. Entretanto, tem a vantagem de ser simples e acessível para pessoas com conhecimentos estatísticos básicos. Outras possíveis formas de ajustes podem ser consultadas na literatura (Chen, Feng, & Yi, 2017). Uma

consequência do ajuste de alfa é a necessidade de aumentar o tamanho da amostra para se alcançar um mesmo poder estatístico (por exemplo, 80%). Assim, fatores como recursos disponíveis e tempo devem ser levados em consideração para um estabelecimento de quantidades de hipóteses que se irá testar.

Abordando o erro do Tipo II

Calculando a Amostra Necessária para um Poder Estatístico Desejado

O poder de um teste estatístico de uma hipótese nula (H_0) é a probabilidade de que H_0 seja rejeitada quando é falso, ou em outras palavras, a probabilidade de encontrar um efeito significativo quando ele existe em uma população. Quanto maior nosso poder estatístico, maior a probabilidade de encontrar um resultado estatisticamente significativo na nossa testagem de hipóteses supondo que o efeito na população realmente existe (Cohen, 1992; 2013). Por outro lado, nosso poder estatístico irá depender, entre outras coisas, do tamanho do efeito real na população.

Pode-se definir tamanho de efeito como um valor quantitativo de uma magnitude de algum fenômeno que é usado com a finalidade abordando uma questão de interesse (Kelley & Preacher, 2012), ou, mais simplificada, uma variação na população de alguma variável de interesse do pesquisador. Por exemplo, o cálculo para o tamanho do efeito no teste t clássico é d onde encontra-se a diferença entre as amostras padronizadas investigadas e divide-se essa diferença pelo desvio padrão da população ($t1-t2/DP$) (Cohen, 1992). Este índice estatístico tornou-se padrão como complemento nos resultados das estatísticas publicadas (particularmente, testes de significância) (APA, 2001, 2010).

Uma forma de aumentar nosso poder estatístico do estudo é a realização de um cálculo para sabermos nosso tamanho de amostra necessário. No software *G-Power*

(Faul et al., 2007) é possível realizar tais cálculos, no entanto precisamos estimar o tamanho do efeito na população, que pode variar de 0,1 até 1 (Cohen, 1988). Uma sugestão feita por alguns autores é uma pesquisa em metanálises que investigaram as relações que desejamos investigar ou procurar por estudos similares que investigaram estas mesmas variáveis. Entretanto, o possível tamanho de efeito encontrado em uma metanálise pode estar inflado pelo grande número de estudos com baixo poder estatístico e com práticas de flexibilidade de análise, fatores que devem ser levados em consideração em metanálises (Ioannidis, 2005). Com relação aos tamanhos de efeitos, em um conjunto de estudo de replicação, o efeito médio diminuiu de $r = 0,40$ nos estudos originais para $r = 0,20$ nos estudos de replicação (OSC, 2015). Da mesma forma, em outro estudo, o efeito médio de 28 estudos diminuiu de $d = 0,60$ para $d = 0,15$ nos estudos de replicação (Klein et al., 2018).

Nas tabelas 2 e 3 podem ser observadas simulações com o *G Power* (Faul et al., 2007) de tamanho de amostras necessário para diferentes tamanhos de efeitos estimados, valores p com uma calda (supondo que a direção das relações das variáveis seja prevista, por exemplo, relação positivo entre frequência de uso de jogos violentos e agressividade) ou duas caldas (sem previsão de direção das relações entre variáveis) na execução dos testes estatísticos (Banerjee, et al., 2009). Frequentemente é indicado que se realize testes bicaudais, mas existem casos em que apenas uma direção de relação entre variáveis é procurada (por exemplo, apenas investigar se um medicamento antidepressivo realmente *baixa* os sintomas depressivos – uma relação negativa). Como se pode observar existe uma variação muito grande da amostra necessária de acordo com ajustes em outros parâmetros.

Inserir tabelas 2 a 9 aqui.

Conclusões

A partir dos pontos discutidos acima, conclui-se que existem variadas formas acessíveis de se abordar o erro chama tipo I e erro tipo II nas tomadas de decisões estatísticas, favorecendo o desenvolvimento de investigações científicas mais robustas e replicáveis, aumentando a confiabilidade dos nossos resultados. Considerando o possível impacto social de nossos achados e o investimento feito pela sociedade na investigação científica, é fundamental o desenvolvimento de esforços para melhorar nossas inferências estatísticas. Em dois artigos futuros desta série serão abordadas duas ferramentas que podem ser utilizadas como auxiliares em nossas testagens de hipóteses: o teste de equivalência e a utilização dos fatores de Bayes como complementares às nossas estatísticas padrões.

Referências:

Allen, C., & Mehler, D. M. (2019). Open Science challenges, benefits and tips in early career and beyond. *PLoS biology*, 17(5), e3000246.

American Psychological Association [APA] (2001). *Publication Manual of the American Psychological Association*, 5th Edn. Washington, DC: American Psychological Association.

American Psychological Association [APA] (2010). *Publication Manual of the American Psychological Association*, 6th Edn. Washington, DC: American Psychological Association.

Bakker, M. (2016) Is there a reproducibility crisis? *Nature* 533, 452454.

Bakker, M., van Dijk, A., & Wicherts, J. M. (2012). The rules of the game called psychological science. *Perspectives on Psychological Science*, 7(6), 543-554.

Banerjee, A., Chitnis, U. B., Jadhav, S. L., Bhawalkar, J. S., & Chaudhury, S. (2009). Hypothesis testing, type I and type II errors. *Industrial psychiatry journal*, 18(2), 127.

Benjamin, D. J., Berger, J. O., Johannesson, M., Nosek, B. A., Wagenmakers, E. J.,

Berk, R., & Cesarini, D. (2018). Redefine statistical significance. *Nature Human Behaviour*, 2(1), 6.

Bland, J. M., & Altman, D. G. (1995). Multiple significance tests: the Bonferroni method. *Bmj*, 310(6973), 170.

Calin-Jageman, R. J., & Cumming, G. (2019). Estimation for Better Inference in Neuroscience. *eNeuro*, 6(4).

- Chen, S. Y., Feng, Z., & Yi, X. (2017). A general introduction to adjustment for multiple comparisons. *Journal of thoracic disease*, 9(6), 1725.
- Cohen, J. (1988). Statistical power analysis for the social sciences.
- Cohen, J. (1992). Statistical power analysis. *Current directions in psychological science*, 1(3), 98-101.
- Cohen, J. (2013). *Statistical power analysis for the behavioral sciences*. Routledge.
- Cumming, G. (2014). The new statistics: Why and how. *Psychological science*, 25(1), 7-29.
- Cumming, G., & Calin-Jageman, R. (2016). *Introduction to the new statistics: Estimation, open science, and beyond*. Routledge.
- Colquhoun, D. (2017). The reproducibility of research and the misinterpretation of p-values. *Royal Society open science*, 4(12), 171085.
- Daniel, W. W. (2002). Hypothesis testing. *Biostatistics*. 7th ed. John Wiley and Sons, Inc. New York; pages 204-294
- Faul, F., Erdfelder, E., Lang, A. G., & Buchner, A. (2007). G* Power 3: A flexible statistical power analysis program for the social, behavioral, and biomedical sciences. *Behavior research methods*, 39(2), 175-191.
- Head, M. L., Holman, L., Lanfear, R., Kahn, A. T., & Jennions, M. D. (2015). The extent and consequences of p-hacking in science. *PLoS biology*, 13(3), e1002106.
- Ioannidis, J. P. (2005). Why most published research findings are false. *PLoS medicine*, 2(8), e124.
- Ioannidis, J. P. (2015). How to make more published research true. *Revista Cubana de Información en Ciencias de la Salud (ACIMED)*, 26(2), 187-200.
- Ioannidis, J. P. (2016). Why most clinical research is not useful. *PLoS medicine*, 13(6),

e1002049.

- John, L. K., Lowenstein, G. and Prelec, D. (2012) Measuring the prevalence of questionable research practices with incentives for truth telling. *Psychological Science* 23 517-523
- Kelley, K., & Preacher, K. J. (2012). On effect size. *Psychological methods*, 17(2), 137.
- Klein, R. A., Vianello, M., Hasselman, F., Adams, B. G., Adams Jr, R. B., Alper, S., ... & Batra, R. (2018). Many Labs 2: Investigating variation in replicability across samples and settings. *Advances in Methods and Practices in Psychological Science*, 1(4), 443-490.
- Lakens, D. (2013). Calculating and reporting effect sizes to facilitate cumulative science: a practical primer for t-tests and ANOVAs. *Frontiers in psychology*, 4, 863.
- Lakens, D. (2017). Equivalence tests: a practical primer for t tests, correlations, and meta-analyses. *Social Psychological and Personality Science*, 8(4), 355-362.
- Lakens, D., Adolphi, F. G., Albers, C. J., Anvari, F., Apps, M. A., Argamon, S. E., ... & Buchanan, E. M. (2018). Justify your alpha. *Nature Human Behaviour*, 2(3), 168.
- Muthukrishna, M., & Henrich, J. (2019). A problem in theory. *Nature Human Behaviour*, 1.
- Nickerson, R. S. (2000). Null hypothesis significance testing: a review of an old and continuing controversy. *Psychological methods*, 5(2), 241.
- Nosek, B. A., & Lakens, D. (2016). Registered Reports: A Method to Increase the Credibility of Published Reports.
- O'Brien RG, Casteloe JM. (2007). Sample size analysis for traditional hypothesis

- testing: concepts and issues. Em: *Pharmaceutical Statistics Using SAS: A Practical Guide*, ed. A Dmitrienko, C Chuang-Stein, R D'Agostino, pp. 237–71. Cary, NC: SAS
- Open Science Collaboration. (2015). Estimating the reproducibility of psychological science. *Science*, 349(6251), aac4716.
- Siegfried, T. (2010). Odds are, it's wrong. *Science news*, 177(7), 26ff.
- Simmons, J. P., Nelson, L. D., & Simonsohn, U. (2011). False-positive psychology: Undisclosed flexibility in data collection and analysis allows presenting anything as significant. *Psychological science*, 22(11), 1359-1366.
- Silver, N. (2013). *O sinal e o ruído*. Editora Intrínseca.
- Schimmack, U. (2019b). *Estimating the Replicability of Psychological Science*. Disponível em: <https://replicationindex.com/2019/04/05/estimating-the-replicability-of-psychological-science/>
- Tooby, J., & Cosmides, L. (2015). Conceptual foundations of evolutionary psychology. *The handbook of evolutionary psychology*, 5-67.
- Wagenmakers, E. J., Marsman, M., Jamil, T., Ly, A., Verhagen, J., Love, J., ... & Matzke, D. (2018). Bayesian inference for psychology. Part I: Theoretical advantages and practical ramifications. *Psychonomic bulletin & review*, 25(1), 35-57.
- Wagenmakers, E. J., Wetzels, R., Borsboom, D., & Van Der Maas, H. L. (2011). Why psychologists must change the way they analyze their data: the case of psi: comment on Bem (2011). *Journal of Personality and Social Psychology*. Vol. 100, No. 3, 426–432

Quadro 1. Analogia entre tomada de decisão estatística e uma decisão jurídica na condenação ou absolvição de um réu.

Decisão do Juiz	Teste Estatístico
Inocência: o réu não cometeu crime	Hipótese nula: Nenhuma associação entre as variáveis
Culpa: O réu cometeu o crime	Existe associação entre variáveis
Padrão para rejeitar inocência: além de um dúvida razoável	Padrão para rejeitar a hipótese nula: nível de significância estatística

Quadro 2. Possíveis decisões e erros de decisões que um pesquisador pode tomar na interpretação dos resultados de um estudo.

Decisão com base em amostra	H_0 é verdadeiro	H_0 é falso
Deixa de rejeitar H_0	Decisão Correta (probabilidade = $1 - \alpha$)	Erro tipo II - deixa de rejeitar H_0 quando ela é falsa (probabilidade = β)
Rejeitar H_0	Erro tipo I - rejeitando H_0 quando ela é verdadeira (probabilidade = α)	Decisão Correta (probabilidade = $1 - \beta$)

Tabelas

Tabela 1. Simulações de valores alfa para diferentes quantidades de hipóteses testadas
(1,5,10,15 e 20).

Número de hipóteses testadas	Valor alfa
1	0,05
5	0,01
10	0,005
15	0,003
20	0,002

Tabela 2. Simulações no programa G-Power 3.1 do N necessário para estudos de correlação entre duas variáveis, de acordo com diferentes tamanhos de efeitos estimados (0.1, 0.2, 0.3, 0.4 e 0.5) com um poder estatístico 80% e valor p de 0,05 com uma calda.

Tamanho do efeito estimado	N total necessário
0.1	616
0.2	153
0.3	67
0.4	37
0.5	23

Tabela 3. Simulações no programa G-Power 3.1 do N necessário para estudos de correlação entre duas variáveis, de acordo com diferentes tamanhos de efeitos estimados (0.1, 0.2, 0.3, 0.4 e 0.5) com um poder estatístico 80% e valor p de 0,05 com duas caldas.

Tamanho do efeito estimado	N total necessário
0.1	782
0.2	193
0.3	84
0.4	46
0.5	29

Tabela 4. Simulações no programa G-Power 3.1 do N necessário para estudos de correlação entre duas variáveis, de acordo com diferentes tamanhos de efeitos estimados (0.1, 0.2, 0.3, 0.4 e 0.5) com um poder estatístico 80% e valor p de 0,01 com uma calda.

Tamanho do efeito estimado	N total necessário
0.1	1000
0.2	247
0.3	107
0.4	59
0.5	36

Tabela 5. Simulações no programa G-Power 3.1 do N necessário para estudos de correlação entre duas variáveis, de acordo com diferentes tamanhos de efeitos estimados (0.1, 0.2, 0.3, 0.4 e 0.5) com um poder estatístico 80% e valor p de 0,01 com duas caldas.

Tamanho do efeito estimado	N total necessário
0.1	1163
0.2	287
0.3	125
0.4	68
0.5	42

Tabela 6. Simulações no programa G-Power 3.1 do n total necessário para dois tipos de estudos de comparação de médias de variáveis entre dois grupos independentes, de acordo com diferentes tamanhos de efeitos estimados (0.1, 0.2, 0.3, 0.4 e 0.5) com um poder estatístico 80% e valor p de 0,05 com uma calda.

Tamanho do efeito estimado	N total necessário
0.1	2476
0.2	620
0.3	278
0.4	156
0.5	102

Tabela 7. Simulações no programa G-Power 3.1 do n total necessário para dois tipos de estudos de comparação de médias de variáveis entre dois grupos independentes, de acordo com diferentes tamanhos de efeitos estimados (0.1, 0.2, 0.3, 0.4 e 0.5) com um poder estatístico 80% e valor p de 0,05 com duas caldas.

Tamanho do efeito estimado	N total necessário
0.1	3142
0.2	788
0.3	352
0.4	200
0.5	128

Tabela 8. Simulações no programa G-Power 3.1 do n total necessário para dois tipos de estudos de comparação de médias de variáveis entre dois grupos independentes, de acordo com diferentes tamanhos de efeitos estimados (0.1, 0.2, 0.3, 0.4 e 0.5) com um poder estatístico 80% e valor p de 0,01 com uma calda.

Tamanho do efeito estimado	N total necessário
0.1	4018
0.2	1008
0.3	450
0.4	254
0.5	164

Tabela 9. Simulações no programa G-Power 3.1 do n total necessário para dois tipos de estudos de comparação de médias de variáveis entre dois grupos independentes, de acordo com diferentes tamanhos de efeitos estimados (0.1, 0.2, 0.3, 0.4 e 0.5) com um poder estatístico 80% e valor p de 0,01 com duas caldas.

Tamanho do efeito estimado	N total necessário
0.1	4676
0.2	1172
0.3	524
0.4	296
0.5	192