

Metodologi Penelitian dalam Psikologi Politik

Rizqy Amelia Zein^{1,2}

¹ Departemen Psikologi Kepribadian dan Sosial, Fakultas Psikologi Universitas Airlangga

² Institute for Globally Distributed Open Research and Education (IGDORE)

Author note

Correspondence concerning this article should be addressed to Rizqy Amelia Zein,
Kampus B Universitas Airlangga, Jalan Airlangga 4-6 Surabaya, Jawa Timur 60286. E-mail:
amelia.zein@psikologi.unair.ac.id

Metodologi Penelitian dalam Psikologi Politik

Meskipun hitung cepat (*quick count*) mayoritas lembaga survei menunjukkan bahwa dirinya kalah kontestasi, Prabowo Subianto, calon Presiden pada Pemilihan Umum (Pemilu) 2019, buru-buru mengumumkan kemenangannya di depan awak media beberapa jam setelah Tempat Pemungutan Suara (TPS) ditutup. Berbekal temuan hitung cepat dan *exit poll* dari beberapa lembaga survei sekaligus perhitungan riil (*real count*) yang dilakukan oleh relawannya, Prabowo mengklaim bahwa ia meraup suara dengan margin yang sangat besar. Meskipun temuan lembaga survei yang dirujuk Prabowo bertolak belakang dengan kebanyakan lembaga survei termasuk perhitungan resmi Komisi Pemilihan Umum (KPU), Prabowo dan pendukungnya amat mempercayai temuan lembaga survei yang memenangkan Prabowo dan dengan lantang menuduh lembaga survei yang berbeda dengan klaimnya merupakan lembaga bayaran, tidak saintifik, dan partisan.

Dari kasus diatas tentu menarik untuk membahas pertanyaan-pertanyaan seperti; bagaimana sebenarnya cara terbaik untuk membedakan informasi yang saintifik, sains semu (*pseudoscience*), mis/disinformasi, mitos, dan intuisi? Bagaimana sesungguhnya cara kerja ilmuwan dalam menghasilkan temuan yang saintifik? Dan bagaimana seharusnya temuan penelitian dilaporkan dan disebarluaskan?

1. Strategi pemeriksaan kredibilitas temuan penelitian

Sebagai mahasiswa Psikologi, tentu anda diwajibkan untuk mengerjakan proyek penelitian secara mandiri kemudian menulis laporan tugas akhir agar dapat dinyatakan lulus. Sebagian dari anda mungkin memiliki aspirasi untuk menjadi peneliti atau dosen di perguruan tinggi sebagai pilihan karir di masa depan. Ada yang mungkin berkeinginan menjadi ilmuwan data (*data*

scientist) yang banyak bersentuhan dengan penambangan data (*data mining*) dan dataset skala besar untuk dianalisis. Dalam konteks ini, anda adalah *pelaku* penelitian - dimana anda banyak berperan dalam merumuskan pertanyaan penelitian, mendesain studi yang ditujukan untuk menjawab pertanyaan tersebut, melakukan pengambilan data, menganalisisnya, lalu melaporkan, dan mengkomunikasikan temuan penelitian pada khalayak yang lebih luas.

Sedangkan sebagian dari anda mungkin lebih tertarik menjadi praktisi - misalnya, bekerja sebagai manajer tim kampanye, atau sebagai konsultan politik. Sebagian mungkin tertarik bekerja di perusahaan media, atau mungkin bekerja sebagai tim ahli di parlemen atau di kantor pemerintah lainnya. Sebagian yang lain mungkin tertarik menjadi konselor bagi calon anggota dewan yang gagal terpilih. Dalam konteks ini, dalam mengerjakan pekerjaan anda sehari-hari, anda diharuskan untuk mengambil keputusan yang **berbasis bukti dan data** sehingga peran anda dalam hal ini adalah sebagai *pengguna* hasil penelitian (Morling, 2018).

Pada praktiknya, anda melakukan kedua peran ini secara bersamaan sehingga menjadi pengguna dan produsen riset sama pentingnya. Sebelum anda melakukan penelitian secara mandiri, anda harus belajar dari pengalaman peneliti yang telah bekerja sebelum anda. Anda perlu membaca literatur yang sesuai dan relevan dengan pertanyaan penelitian yang ingin anda ketahui. Melakoni kedua peran tersebut sama-sama membutuhkan rasa ingin tahu dan ketertarikan yang besar mengenai dinamika kondisi psikologis manusia. Menjadi pelaku sekaligus pengguna membutuhkan tidak hanya rasa ingin tahu, tetapi memiliki komitmen pada prinsip-prinsip dasar pemerolehan ilmu pengetahuan. Salah satu yang dapat dilakukan adalah berlatih untuk membaca literatur dan mengevaluasi informasi di dalamnya secara kritis.

Working in Scientific Research

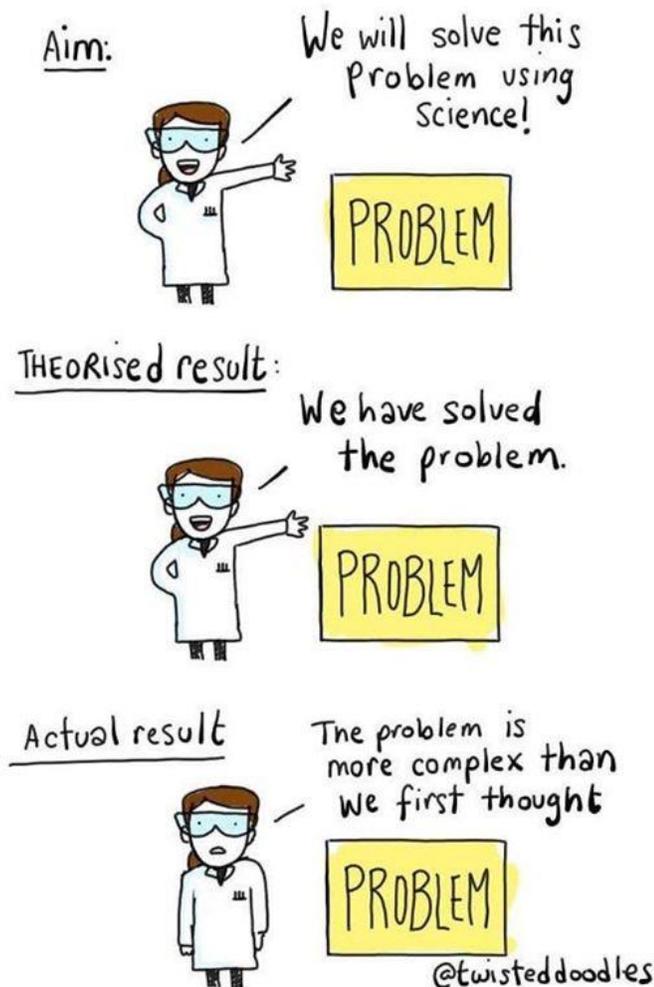


Figure 1.: Sumber: <https://twitter.com/twisteddoodles>

Ada beberapa hal yang dapat dilakukan peneliti untuk mengevaluasi informasi dalam literatur secara kritis. Yang pertama adalah berulang kali mengajukan pertanyaan dan menghindari sikap 'menerima segala hal begitu saja' (*taken everything for granted*). Proses ini amat sulit pada awalnya dan membutuhkan latihan yang intensif. Namun yang perlu diingat,

kemampuan ini amat sentral peranannya apabila kita ingin mendekati realitas yang ingin kita pahami.

Yang kedua, mengevaluasi semua bukti termasuk yang bertentangan dengan asumsi yang diyakini, untuk memahami ‘gambar besar’ dari fenomena yang sedang diselami. Ketika menarik kesimpulan, ilmuwan wajib mempertimbangkan seluruh bukti, bukan hanya yang sesuai dengan asumsi atau keinginannya saja. Melakukan yang terakhir dapat meningkatkan risiko terjadinya bias konfirmasi, dimana peneliti hanya percaya pada bukti-bukti yang sesuai dengan keinginannya saja. Apabila hal ini terjadi, maka sangat mungkin peneliti mendapatkan impresi yang keliru soal fenomena yang sedang ia pelajari.

Yang ketiga, ketika membaca hasil penelitian, cari tahu apakah studi tersebut dilandasi oleh teori yang jelas dan diikuti dengan prediksi yang jelas juga. Prediksi biasanya berbentuk hipotesis statistik yang spesifik, misalnya; ada korelasi yang positif/negatif antar variabel penelitian, ada perbedaan antara kelompok kontrol dengan yang diberi perlakuan, dsb. Namun yang perlu dicatat, hipotesis statistik tidak secara langsung mencerminkan substansi dari teori, meskipun hipotesis tersebut diperoleh atau diturunkan dari teori (Dienes, 2008).

Yang keempat, untuk melakukan pengujian apakah suatu teori sah atau tidak, maka dibutuhkan hipotesis *auxilliary* berupa prediksi statistik, yang langsung dapat diujikan pada data. Misalnya, ketika anda ingin menguji kesahihan *dual-process motivational model of prejudice* (Duckitt, 2001) yang umum digunakan untuk menjelaskan munculnya prasangka pada kelompok sosial tertentu, maka anda perlu membuat hipotesis *auxilliary*, misalnya “*individu yang mempersepsikan dunia sebagai tempat yang berbahaya akan cenderung menyukai pemimpin yang otoriter*”. Dengan menggunakan hipotesis *auxilliary*, prediksi akan lebih mudah diuji dengan proses falsifikasi (*falsifiable*).

Selain dapat difalsifikasi, teori atau prediksi harus dicari korespondensinya dengan realitas (data) melalui pengujian secara ketat. Pengujian ketat (*severe testing*) diperlukan untuk menyimpulkan apakah teori atau prediksi bertahan (*corroborated*) atau gagal dipertahankan (*falsified*). Sebuah pengujian dikatakan ketat (*severe*) apabila berdasarkan teori yang sedang diuji, kondisi yang diprediksikan sangat mungkin terjadi, namun kecil kemungkinannya terjadi berdasarkan semua teori lain yang tidak diuji (*the rest of background knowledge*) (Dienes, 2008).

Berikut adalah ilustrasi konkritnya.

Seorang peneliti ingin mengetahui apakah minum wedang jahe dapat meredakan masuk angin. Maka peneliti tersebut melakukan pengujian pada dua kelompok yang sama-sama menderita masuk angin - dimana satu kelompok diberikan segelas wedang jahe (kelompok perlakuan) sedangkan sisanya diberi minum air putih hangat (kelompok kontrol). Apabila kelompok yang diberi wedang jahe menunjukkan intensitas gejala masuk angin yang lebih rendah daripada kelompok kontrol, maka peneliti boleh menarik kesimpulan bahwa wedang jahe mungkin efektif mengobati masuk angin.

Namun prediksi ini juga dapat terjadi apabila kelompok perlakuan memiliki tingkat kekebalan tubuh yang lebih baik daripada kelompok kontrol. Oleh karena itu, penurunan gejala masuk angin dapat terjadi pada dua kondisi; (a) ketika minum wedang jahe; dan (b) ketika tingkat kekebalan tubuh tinggi. Kondisi ini adalah sesuatu yang **tidak diinginkan oleh peneliti**, karena pengujian ketat seharusnya mengasumsikan bahwa prediksi terjadi secara spesifik pada satu kondisi (teori yang sedang diuji) dan seharusnya tidak terjadi dalam kondisi (teori) yang lain. Oleh karena itu, dalam penelitian tersebut, teori bahwa wedang jahe mengobati masuk angin tidak dapat difalsifikasi karena kita akan selalu mendapati hasil yang sama (penurunan gejala

masuk angin) terlepas apakah prediksi tersebut (minum wedang jahe mengobati masuk angin) benar atau salah.

Dalam paradigma kuantitatif, utamanya yang menggunakan pendekatan Neyman-Pearson (Dienes, 2008; Perezgonzalez, 2015), pengujian ketat hanya mungkin dilakukan apabila peneliti memiliki peluang yang besar untuk mendeteksi bukti yang mendukung teori, apabila bukti tersebut benar-benar ada. Misalnya, ketika peneliti ingin tahu apakah minum wedang jahe benar-benar mengobati masuk angin, maka peneliti harus memiliki peluang yang besar untuk mendeteksi adanya perbedaan intensitas gejala masuk angin antara kelompok perlakuan dengan kelompok kontrol - kalau perbedaan tersebut benar-benar ada. Peluang untuk mendeteksi adanya efek (apabila efek tersebut benar-benar ada) dikenal sebagai *statistical power*, yang akan dijelaskan lebih lanjut di bagian selanjutnya.

Apabila peneliti memiliki peluang yang kecil untuk mendeteksi efek (*statistical power* rendah), dan ketika peneliti tidak menemukan perbedaan intensitas gejala masuk angin antara kelompok perlakuan dengan kelompok kontrol, maka bukti tersebut tidak dapat menggugurkan (memfalsifikasi) teori bahwa wedang jahe menyembuhkan masuk angin. Oleh karena itu, dapat disimpulkan bahwa temuan penelitian dapat dianggap kredibel, apabila peneliti memiliki peluang (*statistical power*) yang besar untuk mendeteksi adanya efek, apabila efek tersebut benar-benar ada.

2. Isu mengenai pengukuran Psikologi

Pengukuran adalah bagian yang tidak mungkin dipisahkan dari proses penelitian. Tentu sulit bagi peneliti untuk menarik kesimpulan apakah dua kejadian berkaitan tanpa sebelumnya melakukan pengukuran pada dua kejadian tersebut. Oleh karena itu, penelitian yang baik tentu

didahului oleh strategi pengukuran yang baik pula (Fried & Flake, 2018). Pengukuran dalam Psikologi pada prinsipnya sangat berbeda dengan mengukur gejala yang kasat mata, seperti berat badan, tinggi badan, atau warna rambut.

Sebelum melakukan pengukuran, kita perlu mengetahui perbedaan antara **konsep**, **konstruk**, dan **variabel**. **Konsep** merujuk pada deskripsi atas kejadian yang sifatnya umum dan merupakan kumulasi atau kumpulan dari beberapa konstruk. Sedangkan **konstruk** sendiri merujuk pada gejala yang sifatnya spesifik dan merupakan komponen kecil yang menjadi bagian dari konsep yang lebih besar. **Variabel** adalah *konstruk yang bervariasi*, sehingga anggaphlah setelah dilakukan pengukuran pada satu kelompok sampel ditemukan tidak ada variasi konstruk dalam kelompok tersebut, maka **konstruk tidak dapat disebut sebagai variabel**.

Berikut ini adalah ilustrasi konkritnya.

Ilustrasi 1: Seorang Lurah ingin mengetahui gambaran kematangan fisik pada remaja di desanya dengan melakukan pengukuran tinggi dan berat badan. Setelah dilakukan pengukuran pada sampel sejumlah 100 remaja di desanya, maka ditemukan bahwa semua responden memiliki berat badan yang sama, yaitu 50kg, namun tinggi badannya bervariasi antara 140-156cm dengan rata-rata 152cm.

Ilustrasi 2: Seorang peneliti Psikologi Politik ingin menyelidiki persepsi pemilih mengenai calon Presiden dan Wakil Presiden dengan melakukan pengukuran pada tingkat keterpilihan pasangan calon Presiden dan Wakil Presiden yang sedang berlaga, dengan cara bertanya pada responden "*dari 0% (pasti tidak memilih) sampai 100% (pasti memilih), seberapa mungkin anda memilih pasangan A?*". Setelah dilakukan pengukuran pada sekelompok sampel, pasangan A mendapatkan tingkat keterpilihan yang cenderung bervariasi antara 43-56% dengan rata-rata sebesar 45 persen.

Berdasarkan ilustrasi di atas maka **kematangan fisik** dan **persepsi pemilih** adalah **konsep**, sedangkan **tinggi, berat badan, dan tingkat keterpilihan** adalah **konstruk ukur**. Juga

berdasarkan ilustrasi di atas, setelah dilakukan pengukuran maka diketahui **tinggi badan dan tingkat keterpilihan bervariasi** sehingga dapat disebut sebagai **variabel**. Namun **tidak ada variasi** pada **berat badan** di ilustrasi 1 sehingga meskipun berat badan merupakan konstruk ukur, **tidak dapat dikatakan sebagai variabel**.

Setelah membandingkan antara ilustrasi 1 dan 2, mungkin anda sudah mulai menangkap kesan mengenai kekhususan pengukuran Psikologi. Sebagian besar konstruk Psikologi **tidak dapat secara langsung diukur** melainkan diukur melalui manifestasi atau gejala yang dapat diamati secara langsung. Tentu kita dapat dengan mudah mengukur berat atau tinggi badan seseorang, namun mengukur konstruk Psikologi seperti intelegensi, persepsi, emosi, atau motivasi bukan pekerjaan yang mudah. Jangankan mengukur, mendefinisikan konstruk psikologi dengan lugas merupakan sesuatu yang sangat menantang. Sub-disiplin dalam Psikologi yang secara spesifik menjawab persoalan mengenai konstruksi dan evaluasi alat ukur Psikologi adalah Psikometri.

Dalam Psikometri, ada beberapa pendekatan yang umum digunakan untuk mengkonstruksi dan mengevaluasi alat ukur Psikologi. Diantaranya adalah pendekatan *latent variable modeling* (Skronal & Rabe-Hesketh, 2007) dan *latent response model* (Maris, 1995). Namun pendekatan yang paling populer (dan yang paling sederhana) adalah Model Skor Klasik (*Classical True Score Model* atau CTM) (Mair, 2018). Berikut adalah persamaan dalam CTM:

$$X = T + e$$

Ide dasar dari CTT amat sederhana. Prinsipnya, X adalah skor yang langsung didapatkan dari suatu alat ukur (*observed score*) atau disebut juga sebagai skor kasar (*raw score*). Skor kasar mengandung dua elemen, yaitu skor murni (*true score*) atau T dan kesalahan pengukuran

(*measurement error*) atau e . Yang menarik, T dan e tidak mungkin diketahui nilainya dengan pasti. Dengan begitu kita dapat menyimpulkan bahwa:

1. Tidak ada satupun alat ukur Psikologi yang mampu mengukur konstruk Psikologi dengan sempurna sehingga peneliti harus meminimalisasi dan menoleransi kesalahan pengukuran dalam kadar tertentu.
2. Ketika peneliti melakukan pengukuran berulang pada orang yang sama di waktu yang berbeda, maka tidak realistis apabila peneliti tersebut mengharapkan hasil pengukuran yang *identik* padahal konsistensi hasil pengukuran merupakan aspek penting untuk mengevaluasi apakah alat ukur tersebut bekerja dengan baik.
3. Yang paling krusial dari CTM adalah kesalahan pengukuran (e). Apabila kita tidak mungkin mengetahui nilai e , lalu bagaimana caranya mengetahui apakah alat ukur kita akurat atau tidak? Meskipun secara realitanya kita tidak mungkin mengetahui nilai e , namun karena nilai e dapat bervariasi, maka kita dapat mengestimasi variansi dari e dengan menghitung *standard error of measurement* (σ_E). SoE dan reliabilitas (akan dijelaskan di bagian selanjutnya) merupakan indikator yang penting yang dapat digunakan peneliti untuk menakar apakah pengukurannya akurat atau tidak.

Untuk mengetahui pengukuran yang dilakukan sudah tepat, kita dapat mengestimasi melalui dua hal; (a) apakah alat ukur benar-benar mengukur objek yang ingin diukur (validitas), dan (b) dengan mengasumsikan tidak ada perubahan berarti pada konstruk yang diukur, apakah alat ukur akan memberikan hasil yang cenderung konsisten (reliabilitas). Dua fitur inilah yang kemudian menentukan apakah hasil pengukuran dari suatu alat ukur Psikologi dapat dipercaya.

2.1 Reliabilitas

Reliabilitas adalah indikasi kualitas alat ukur dalam konteks CTM yang juga merefleksikan keterkaitan antara X , T , dan e . Alat ukur yang reliabel akan memberikan hasil pengukuran yang konsisten ketika ia diujikan pada orang yang sama pada waktu yang berbeda. Dengan kata lain, reliabilitas adalah indikator akurasi sebuah tes karena menunjukkan kemampuan alat ukur memberikan estimasi skor yang mendekati skor murni (Mair, 2018).

Ada dua skenario yang mungkin terjadi - ketika alat ukur memiliki reliabilitas yang baik, maka varians kesalahan pengukuran (σ_E) akan mengecil sehingga X memiliki kadar kesalahan pengukuran yang kecil dan makin mendekati nilai T . Kemungkinan yang kedua dan yang tak diinginkan peneliti adalah ketika alat ukur memiliki kadar reliabilitas yang buruk, maka σ_E akan membesar sehingga X terkontaminasi kesalahan pengukuran yang besar sehingga nilai X makin menjauh dari T .

Untuk menakar kadar reliabilitas alat ukur, ada beberapa pendekatan yang dapat diadopsi oleh peneliti, diantaranya adalah: *test-retest*, tes paralel, dan konsistensi internal. ***Test-retest*** dapat dilakukan dengan mengujikan alat tes pada kelompok sampel yang sama, namun pada waktu yang berbeda. Apabila peneliti melakukan **tes paralel**, maka ia mengujikan alat ukur pada dua kelompok sampel yang berbeda, namun memiliki karakteristik yang identik (homogen). Baik *test-retest*, maupun tes paralel dianggap kurang praktis karena membutuhkan sedikitnya dua kali pengambilan data. Oleh karena itu, pendekatan yang terakhir (konsistensi internal) adalah yang paling sering digunakan.

Pendekatan **konsistensi internal** menguji reliabilitas alat ukur psikologi dengan melihat konsistensi antar butir pertanyaan/ Pernyataan (aitem). Pendekatan ini bercabang pada dua asumsi yang berbeda, yaitu peneliti dapat mengasumsikan bahwa kontribusi setiap aitem **sama besarnya** atau **bervariasi/berbeda-beda** dalam menjelaskan konstruk yang diukur. Apabila kontribusi aitem **sama besarnya** dalam menjelaskan konstruk psikologis yang diukur, maka alat ukur tersebut memenuhi asumsi *τ equivalence* sehingga teknik Cronbach's α dan *Split-Half* dapat digunakan untuk mengestimasi reliabilitas alat ukur (Cho, 2016). Namun yang perlu diingat, asumsi *τ equivalence* **tidak realistis** karena pada kenyataannya, tidak mungkin peneliti mengharapkan bahwa seluruh aitem dalam alat ukurnya berkontribusi setara dalam menjelaskan

konstruk. Menariknya, meskipun asumsi τ *equivalence* tidak realistis, teknik Cronbach's α adalah pilihan yang sangat populer dan sayangnya, paling sering disalahgunakan oleh peneliti (McNeish, 2018). Ketika menggunakan Cronbach's α , peneliti seringkali abai pada asumsi yang menyertainya (Peters, 2018).

Alternatif lainnya adalah peneliti mengantisipasi bahwa masing-masing aitem dalam alat ukurnya **berkontribusi secara berbeda** dalam menjelaskan konstruk. Asumsi ini lebih fleksibel dan lebih dekat dengan realitas yang dihadapi oleh peneliti daripada τ *equivalence*. Asumsi ini dikenal sebagai *model konjenerik* dan untuk mengestimasi reliabilitas alat ukur Psikologi dengan asumsi konjenerik, peneliti dapat menggunakan beberapa alternatif, yaitu *greatest lower bound* (glb) (Sijtsma, 2008) dan *McDonald's Omega* (ω) (Dunn, Baguley, & Brunsten, 2014). Apabila peneliti tertarik untuk mengestimasi reliabilitas pada alat ukur yang mengukur konstruk yang sifatnya unidimensional, maka Omega Total (ω_t) adalah teknik yang terbaik. Namun untuk konstruk yang multi-dimensional atau memiliki struktur tertentu, maka pendekatan Omega Hirarkial (ω_h) adalah yang terbaik (Revelle & Zinbarg, 2008). Program statistik dengan sumber terbuka seperti [jamovi](#), [JASP](#), atau R dengan [package psych](#) dapat membantu peneliti untuk melakukan kalkulasi reliabilitas dengan teknik ω .

2.2 Validitas

Isu mengenai **validitas** alat ukur Psikologi berfokus untuk memastikan bahwa alat ukur benar-benar mengukur konstruk yang ingin diukur dan bukan konstruk lainnya. Apabila kita mengukur gejala tampak, mengevaluasi validitas alat ukur sangat mudah dilakukan. Misalnya, kita dapat dengan mudah menyimpulkan bahwa penggaris bukan alat ukur yang valid untuk mengukur berat badan. Namun bagaimana dengan konstruk Psikologi?

Pendekatan tradisional yang lazim digunakan untuk menyelidiki validitas alat ukur Psikologi membagi validitas berdasarkan tiga kategori, yaitu: validitas isi (*content validity*), validitas kriteria (*criterion validity*), dan validitas konstruk (*construct validity*) (Messick, 1995). **Validitas isi** dapat diperoleh dengan meminta bantuan ahli (*expert judgement*) untuk memberikan skor pada setiap aitem dalam skala, berdasarkan beberapa dimensi penilaian, yaitu **kejelasan** penulisan aitem, **relevansinya** dengan konstruk yang akan diukur, dan apakah aitem tersebut sudah **representatif** mewakili konstruk laten yang diukur. Alat ukur kemudian dinilai oleh setidaknya tiga orang rater pakar/ahli dan tiga orang rater awam (Rubio, Berg-Weger, Tebb, Lee, & Rauch, 2003). Dengan menghitung persentase kesepakatan antar-rater (*inter-rater agreement*), peneliti dapat memperkirakan apakah alat ukur sudah mencerminkan konstruk yang ingin diukur (Wynd, Schmidt, & Schaefer, 2003).

Validitas kriteria dapat diperoleh dengan mengkorelasikan hasil pengukuran dengan kriteria lain yang relevan. Mengestimasi validitas konstruk dapat dilakukan dengan mengkorelasikan skor alat ukur yang akan diuji dengan konstruk lain yang dihipotesiskan berkorelasi linier dan positif (*convergent validity*) atau dengan konstruk lain yang dihipotesiskan sumbang (*divergent validity*) (Messick, 1995). Misalnya apabila seorang peneliti ingin mengestimasi validitas alat ukur yang mengukur depresi, maka peneliti tersebut akan mengkorelasikan skornya dengan kecemasan dan kebahagiaan. Asumsinya, apabila alat ukur tersebut valid, maka korelasinya dengan depresi akan kuat dan positif, sedangkan korelasi skor alat ukur tersebut akan cenderung negatif dengan kebahagiaan. Validitas kriteria juga dapat dicek dengan melakukan kedua teknik tersebut sekaligus (*convergent* dan *divergent*) dengan membuat matriks korelasi yang menggambarkan korelasi antara skor alat ukur yang diuji dengan alat ukur lain yang sama-sama mengukur *trait* atau konstruk yang sama (bisa juga dengan metode yang

berbeda). Pendekatan ini populer dikenal dengan *Multitrait-Multimethod* (MTMM) (Dumenci, 2000).

Yang terakhir adalah **validitas konstruk**. Sebenarnya kedua tipe validitas yang diuraikan sebelumnya tidak cukup ampuh dan cermat untuk mengevaluasi validitas alat ukur Psikologi karena pada dasarnya, apabila kita ingin tahu apakah alat tes Psikologi benar-benar mengukur konstruk yang ingin diukur, maka peneliti harus memastikan bahwa butir pertanyaan/pernyataan (aitem) mengukur konstruk laten (yang sama). Definisi tersebut adalah definisi dari validitas konstruk (Cronbach & Meehl, 1955) dan mayoritas ahli Psikometri sepakat bahwa validitas alat ukur harus selalu merujuk pada validitas konstruk, bukan pada jenis validitas yang lain (Messick, 1995). Messick (1995) bahkan mengusulkan *unified validity* dimana pembagian tiga kategori validitas tidak perlu lagi dilakukan. Ketika seorang peneliti ingin mengetahui apakah alat ukurnya valid atau tidak, maka langsung saja merujuk pada pendekatan validitas konstruk.

Ada beberapa alternatif pendekatan validitas alat ukur, yaitu: *incremental validity* yang berfokus pada pertanyaan: apakah alat ukur yang diujikan menambah pemahaman (atau kekuatan prediksi) peneliti dibandingkan dengan alat ukur lain yang sudah lebih dulu tersedia (Hunsley & Meyer, 2003). Pendekatan lainnya yang tersedia adalah *processed-focused model* yang lebih banyak berkuat pada penjelasan mengenai keterlibatan partisipan tes dalam proses pengukuran dan apakah keterlibatan tersebut sudah sesuai dengan sifat dan situasi tes yang sudah diantisipasi sebelum tes berlangsung (Bornstein, 2011).

3. Ragam desain penelitian dalam studi-studi Psikologi Politik

Setelah peneliti memahami cara kerja sains dan mampu mendesain strategi pengukuran yang sesuai, maka peneliti dapat mulai memilih desain penelitian yang sesuai dengan pertanyaan

penelitian yang ingin dijawab atau hipotesis yang akan diuji. Apabila menganalogikan kegiatan meneliti dengan memasak, maka memilih desain penelitian yang sesuai dengan pertanyaan penelitian seperti memilih alat yang digunakan untuk memasak. Untuk memilih alat masak yang tepat, maka kita harus benar-benar memahami apa yang ingin kita masak. Serta untuk memastikan bahwa masakan dapat dihidangkan sebagaimana mestinya, maka kita harus mengikuti tahapan memasak yang tepat. Melewati beberapa langkah atau tidak melakukan tahapan memasak dengan berurutan akan berdampak pada kualitas masakan.

Paralel dengan kegiatan meneliti - bahwa peneliti harus benar-benar memahami apa yang ia hendak cari dengan merumuskan pertanyaan penelitian dan hipotesis yang tepat. Agar temuan penelitian kredibel, maka peneliti perlu memilih desain yang paling sesuai dalam menjawab pertanyaan penelitian atau menguji hipotesis yang ia ajukan. Terakhir, apabila peneliti menginginkan temuan yang meyakinkan, maka ia perlu cermat dalam mengikuti tahapan atau prosedur yang sistematis dalam melakukan penelitian.

Di bagian ini, penulis akan menguraikan secara singkat beragam desain penelitian yang lazim digunakan dalam studi Psikologi Politik.

3.1 Survei

Bayangkan ada sebuah ceret yang berisi kopi di hadapan anda saat ini. Untuk mengetahui rasa kopi, apakah anda harus meminum seluruh kopi yang di dalam ceret tersebut? Kalau dengan mencicip sedikit saja sudah cukup, seberapa banyak kopi yang harus diminum agar dapat menyimpulkan rasanya dengan akurat?

Logika dan persoalan yang sama juga dihadapi oleh peneliti Psikologi Politik yang menggunakan desain survei. Prinsipnya, untuk mendapatkan berbagai informasi mengenai sekelompok orang, kita tidak perlu melakukan pengujian pada seluruh anggota kelompok

(sensus), namun cukup dengan melakukan pengujian pada beberapa orang yang mewakili kelompok tersebut (survei).

Penelitian survei umumnya dapat berupa **survei *cross-sectional***, yaitu ketika peneliti melakukan pengambilan data pada satu kelompok sampel dalam satu waktu. Survei juga dapat dilakukan dengan desain **longitudinal** (*time series* atau *panel study*), yaitu ketika peneliti melakukan pengambilan data secara berulang pada kelompok sampel yang sama dalam periode waktu tertentu.

Data yang diperoleh dari penelitian survei memiliki kegunaan praktis yang luas, bahkan melampaui tujuan akademik. Hasil survei dapat digunakan sebagai dasar perumusan kebijakan dan pengambilan keputusan lainnya di berbagai konteks. Survei skala besar seperti Survei Sosial Ekonomi Nasional (SUSENAS) oleh Badan Pusat Statistik (BPS), Riset Kesehatan Dasar (RISKESDAS) oleh Badan Penelitian dan Pengembangan Kesehatan (Balitbangkes) Kementerian Kesehatan, atau Indonesian Family Life Survey (IFLS) oleh RAND, menyediakan data yang amat kaya dan memberikan banyak informasi penting yang dapat digunakan untuk mendukung perumusan kebijakan di berbagai sektor.

Penelitian survei merupakan desain yang amat efisien dan paling luas diaplikasikan pada penelitian sosial dan perilaku, termasuk dalam studi Psikologi Politik. Penelitian survei dapat dilakukan untuk kepentingan akademik dan juga lazim digunakan untuk memberikan informasi kepada pemilih mengenai kandidat yang akan mereka pilih di pemilihan umum. Di bagian ini, penulis akan lebih banyak menjelaskan mengenai survei dalam konteks studi akademik, meskipun di bagian akhir tersedia sedikit ulasan mengenai survei opini publik yang dilakukan oleh lembaga survei non-pemerintah (*pollster*), utamanya yang menjadi bagian penting dari proses politik elektoral.

3.1.1 Populasi dan sampel

Survei merupakan desain penelitian yang tak hanya dapat digunakan untuk membuat profil yang mendeskripsikan sekelompok orang, namun juga dapat digunakan untuk menguji teori atau prediksi. Namun seringkali peneliti memiliki sumberdaya yang terbatas sehingga tidak mungkin melibatkan seluruh anggota populasi (sensus) dalam pengambilan data. Yang juga sering terjadi adalah ukuran populasi tidak diketahui sehingga peneliti harus memilih sebagian kecil responden yang dapat mewakili populasi yang ingin diteliti. Tidak hanya itu, kualitas data yang diperoleh melalui proses *sampling* justru lebih baik daripada data sensus (Fowler, 2014). Proses pemilihan responden ini disebut dengan **teknik *sampling***.

Ada beberapa istilah yang perlu diketahui agar dapat melakukan proses pemilihan sampel dengan baik. **Populasi** adalah sekumpulan individu yang memiliki karakteristik atau kriteria tertentu yang telah ditetapkan oleh peneliti sebelum studi dilakukan. Populasi juga mencerminkan konteks yang ingin diteliti dan merupakan bagian penting dari studi yang dilakukan. Kriteria yang ditetapkan oleh peneliti untuk mendefinisikan populasi penelitiannya disebut juga **kriteria inklusi**. Populasi biasanya disimbolkan dengan N dan harus didefinisikan secara eksplisit, hati-hati, dan menyeluruh dengan memperhatikan pertanyaan penelitian yang ingin dijawab (Ruel, Wagner, & Gillespie, 2016).

Mendefinisikan populasi tidak semudah kelihatannya. Selain menentukan kriteria inklusi, peneliti juga perlu menerapkan **kriteria eksklusi** yang kemudian menghasilkan **populasi target**. **Kriteria eksklusi** adalah karakteristik yang mengecualikan individu tertentu dari proses pemilihan sampel. Pengecualian ini biasanya berkaitan dengan keterbatasan sumberdaya yang dimiliki oleh peneliti. Misalnya, apabila seorang peneliti ingin melakukan penelitian pada Warga Negara Indonesia (WNI), kadang-kadang peneliti harus mengecualikan WNI yang tinggal di luar

negeri karena sumberdaya yang dimiliki peneliti tidak cukup untuk melibatkan WNI yang tinggal di luar negeri.

Sampel adalah subset atau bagian kecil dari populasi, yang biasanya disimbolkan dengan n . Elemen sampel dapat berbentuk **unit analisis** yang beragam, mulai dari individu, kelompok (perusahaan, ormas, universitas, dll.), objek, tempat (RT, RW, Kabupaten/Kota, Propinsi, Desa, dll.), atau kejadian yang menarik untuk diteliti. Apabila populasi penelitian terdiri dari sekumpulan individu, maka sampel juga terdiri dari individu-individu. Untuk menentukan anggota populasi yang menjadi sampel, peneliti perlu menjamin bahwa sampel tersebut benar-benar representatif mewakili populasi. Apabila sampel yang dipilih representatif mewakili populasi, maka temuan penelitian yang diperoleh dari proses *sampling* dapat **digeneralisasi** pada populasi yang diwakilinya. Untuk menjamin **generalisasi**, peneliti perlu memberikan kesempatan yang sama pada seluruh anggota populasi untuk terpilih menjadi sampel. Pendekatan ini disebut juga sebagai *probability sampling*.

Bayangkan anda sedang membuat kopi dengan gula aren sebagai pemanis. Yang anda lakukan adalah menuang gula aren terlebih dahulu, baru menuang kopi yang sudah dicampur dengan sedikit air. Untuk mendapatkan rasa yang optimal, maka yang harus anda lakukan adalah **mengaduk** semua cairan yang ada di dalam gelas. Apabila anda tidak mengaduknya, maka kopi tidak terasa manis karena gula aren masih mengendap di bagian bawah gelas. Dengan mengaduk campuran di dalam gelas, anda mencampur dengan rata semua elemen yang ada di dalam gelas sehingga dengan mencicip sedikit, anda sudah dapat merasakan profil kopi secara keseluruhan. Namun apabila tidak diaduk, anda hanya akan merasakan rasa kopi dan meninggalkan rasa manis yang diberikan oleh gula aren. Cara kerja *probability sampling* persis seperti analogi pengadukan ini. Mengaduk cairan yang ada di dalam gelas berfungsi sebagai **pengacakan**. Dengan melakukan **pengacakan**, berarti anda memberikan **kesempatan yang sama** pada seluruh anggota populasi untuk terpilih menjadi sampel. Dengan begitu, anda dapat lebih percaya diri untuk menyimpulkan bahwa sampel anda representatif sehingga dapat dilakukan generalisasi.

Untuk melakukan *probability sampling*, maka peneliti harus memiliki **sampling frame**, yaitu daftar yang memuat seluruh anggota populasi. Apabila peneliti tertarik melakukan studi dengan populasi WNI, maka untuk melakukan *probability sampling* peneliti harus memiliki data kependudukan yang memuat informasi mengenai seluruh individu dengan status kependudukan WNI. Salah satu kesalahan yang umum terjadi dalam membuat *sampling frame* adalah *coverage error*, yaitu situasi dimana tidak semua anggota populasi tercantum dalam *sampling frame*.

Coverage error dapat menimbulkan **bias**, yaitu perbedaan sistematis antara kondisi sesungguhnya dari suatu populasi dengan kondisi yang diprediksikan melalui analisis pada kelompok sampel (Ruel et al., 2016). Dengan melakukan *probability sampling*, peneliti punya peluang lebih besar untuk mendapatkan kelompok sampel yang lebih bervariasi. Ingat, variasi (varians) adalah hal yang amat krusial dalam generalisasi. Semakin besar variabilitas kelompok sampel, maka semakin akurat prediksi atau kesimpulan yang ditarik oleh peneliti (Fowler, 2014).

Ada beberapa strategi yang dapat digunakan untuk melakukan *probability sampling*, yaitu: **simple random sampling** yang juga dikenal dengan *equal probability sample* yang mengasumsikan bahwa seluruh anggota populasi punya peluang yang sama persis untuk terpilih menjadi sampel melalui prosedur pengacakan yang sama. Seandainya anda ingin mengambil sampel dari populasi yang beranggotakan 1000 orang, maka peluang satu orang untuk terpilih menjadi sampel adalah setara, yaitu 1/1000. *Simple random sampling* dapat dilakukan dengan misalnya menggunakan *random number generator*. Google juga memiliki layanan ini dan dapat diakses dengan mengetikkan “*random number generator*” pada kolom pencarian. Meskipun kelihatannya ideal, *simple random sampling* justru menghasilkan variasi sampel yang amat kecil dan akibatnya kualitas sampel menjadi buruk, terutama apabila peneliti melibatkan populasi yang memiliki struktur di dalamnya.

Selanjutnya adalah *systematic random sampling*, yaitu teknik *sampling* yang pengambilan sampelnya mengikuti interval waktu atau jumlah tertentu. Misalnya, seorang petugas kendali mutu melakukan pemeriksaan kualitas produk dengan mengambil sampel sebanyak 1 produk untuk setiap 1000 produk yang diproduksi. Atau seorang peneliti Psikologi Politik yang mengambil sampel sebanyak 10 responden untuk setiap 100.000 penduduk. Namun perlu diingat, pengambilan sampel dengan interval tertentu menimbulkan masalah *periodicity* yang merupakan penyebab timbulnya bias karena akan menghasilkan kelompok sampel dengan variabilitas yang rendah, terutama apabila populasi memiliki struktur di dalamnya. Kedua teknik *probability sampling* yang telah dijelaskan sebelumnya tidak cocok diterapkan apabila peneliti menginginkan sampel yang representatif dari populasi yang memiliki struktur. Misalnya, apabila peneliti ingin melakukan studi pada Kelurahan A yang profil demografinya beragam, maka peneliti menginginkan perwakilan sub-populasi (misalnya gender, tingkat pendidikan, dan tingkat penghasilan) dicakup dalam kelompok sampelnya. Dengan kedua teknik *sampling* yang dijelaskan sebelumnya, sangat mungkin sampel yang ditarik justru tidak proporsional karena mengabaikan struktur yang ada di populasi.

Alternatifnya, peneliti dapat menggunakan: *cluster random sampling*, *stratified random sampling*, atau *multistage cluster sampling*. *Cluster sampling* berarti peneliti membuat *sampling frame* terpisah untuk masing-masing kategori non-strata pada populasi, misalnya sekolah, kelurahan, desa, RT, gender, dsb., lalu mengacak dan menentukan sampel di masing-masing kategori tersebut. Implikasinya, setiap kategori memiliki perwakilan dalam kelompok sampel. *Stratified sampling* adalah strategi yang sama, namun kategori yang digunakan untuk menentukan sampel adalah kategori dengan strata atau berjenjang, misalnya: tingkat pendidikan, tingkat penghasilan, dsb. Sedangkan yang terakhir, *multistage cluster sampling* atau *multilevel cluster sampling* menggunakan strategi yang lebih kompleks, yaitu mengambil sampel secara

acak dari kategori yang berlapis. Pendekatan yang terakhir menghasilkan kualitas sampel yang terbaik (dengan variabilitas yang lebih besar), utamanya ketika peneliti tidak memiliki *sampling frame*.

Seorang peneliti Psikologi Politik tertarik untuk meneliti tingkat partisipasi politik pada pemilih pemula dengan kriteria: remaja yang berusia 18-23 tahun dan mahasiswa aktif pada jenjang S1. Agar mendapatkan sampel yang representatif, peneliti melakukan *multistage cluster sampling* dengan tahapan sebagai berikut: (a) menentukan secara acak sejumlah propinsi yang menjadi sampel dari 34 propinsi di Indonesia; (b) menentukan secara acak sejumlah perguruan tinggi yang menjadi sampel di masing-masing propinsi yang terpilih menjadi sampel pada tahap (a); (c) menentukan secara acak sejumlah program studi S1 pada masing-masing perguruan tinggi yang sudah terpilih menjadi sampel pada tahap (b); dan (d) menentukan secara acak sejumlah responden penelitian di masing-masing program studi S1 yang sudah terpilih pada tahap (c).

Problem *sampling* berikutnya berkaitan dengan jumlah sampel. Pertanyaan yang sering diajukan adalah berapa banyak jumlah sampel yang harus diambil oleh peneliti agar generalisasinya akurat? Meskipun kelihatannya sederhana, persoalan ini tidak mudah diatasi dan sangat bergantung pada tujuan survei. Apabila tujuan survei adalah membuat profil atau deskripsi, maka akurasi penarikan kesimpulan bergantung pada kadar *sampling error* (atau yang juga dikenal sebagai *margin error*). Namun ketika peneliti melakukan survei dengan tujuan menguji teori, hipotesis, atau prediksi, maka selain *sampling error*, peneliti harus memperhatikan *statistical power*, ukuran efek (*effect size*) yang ingin dideteksi, dan desain penelitian yang digunakan. Untuk topik yang terakhir, akan dibahas pada bagian 4.2.

Sampling error merupakan selisih antara rerata (*mean*) atau proporsi pada sampel dengan yang sebenarnya terjadi di populasi. Ingat, peneliti tak mungkin tahu apa yang terjadi di populasi sehingga yang dapat dilakukan adalah memperkirakan seberapa jauh menyimpang estimasi yang disimpulkan peneliti dengan mengamati kelompok sampel dengan yang terjadi sebenarnya di

populasi. Dalam statistik dikenal *central limit theorem* yang menyatakan apabila jumlah kelompok sampel (n) mendekati tak terhingga (∞), maka distribusi rerata dari kelompok sampel tersebut akan mengikuti **distribusi normal** (*gaussian distribution*), meskipun apabila distribusi data di populasi tidak mengikuti distribusi normal. Selanjutnya *the law of large numbers* menyebutkan apabila $n=\infty$, maka rerata sampel sama dengan rerata populasi.

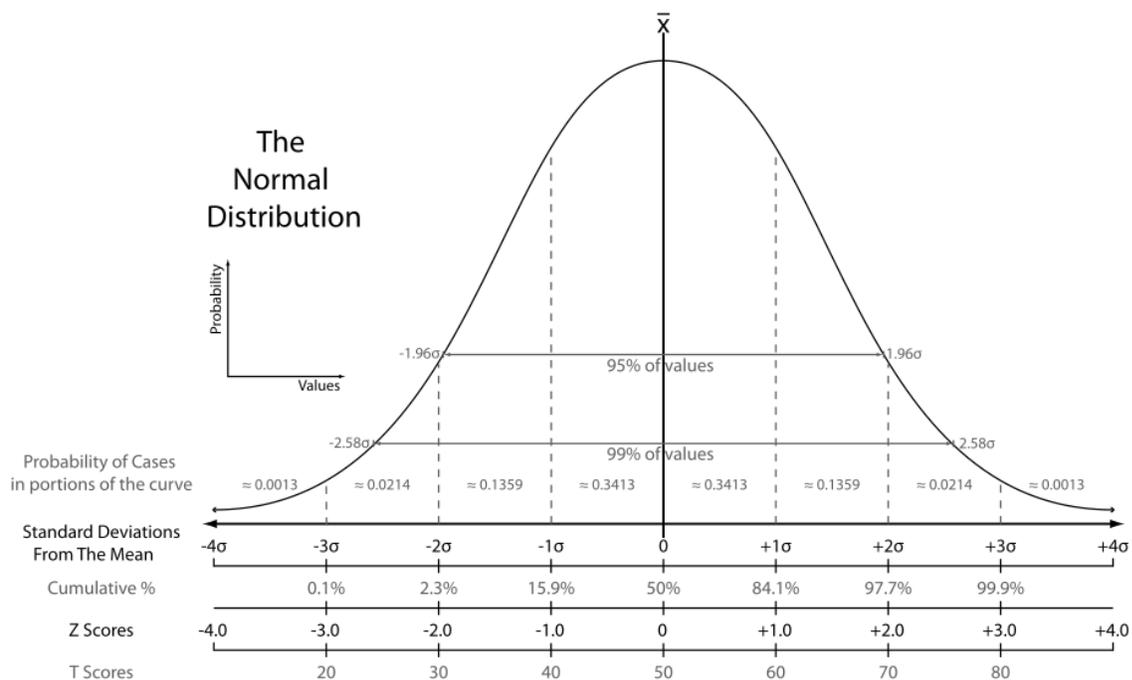


Figure 2.: Distribusi normal

Distribusi normal merupakan distribusi yang bentuk kurvanya secara visual mirip seperti lonceng, dimana mayoritas anggota kelompok sampel berada di tengah-tengah kurva (lihat gambar 2). Apabila distribusi sampel mengikuti distribusi normal, maka 68% dari jumlah total kelompok sampel akan jatuh pada rentang 1 standar deviasi masing-masing di kiri dan kanan

rerata sampel, sedangkan 95% dari seluruh kelompok sampel akan jatuh pada rentang 1.96 standar deviasi masing-masing di kiri dan kanan rerata sampel. Karena tidak mungkin mengetahui standar deviasi populasi, maka yang dapat kita lakukan adalah menghitung *standard error*, yaitu parameter statistik yang menunjukkan akurasi distribusi sampel dalam merepresentasikan populasi, dengan menggunakan standar deviasi kelompok sampel (Ruel et al., 2016).

Rumus *standard error of mean* (SE_{μ}) adalah..

$$SE_{\mu} = \frac{S_y}{\sqrt{n}}$$

..dimana S_y adalah **standar deviasi** pada kelompok sampel y dan n adalah jumlah sampel.

Apabila peneliti tertarik menghitung proporsi (persentase), maka rumus *standard error of proportion* (SE_p) adalah..

$$SE_p = \sqrt{\frac{p_y(1 - p_y)}{n}}$$

..dimana p_y adalah proporsi pada kelompok sampel y , sedangkan n adalah jumlah sampel.

Dengan mengetahui *standard error*, peneliti dapat menghitung *sampling error* (*margin error*) sekaligus rentang kepercayaan (*confidence interval*). Rentang kepercayaan adalah rentang di sekitar rerata atau proporsi sampel, dimana peneliti yakin bahwa rerata atau proporsi populasi jatuh di dalam rentang tersebut (Ruel et al., 2016). Semakin panjang rentang kepercayaan, estimasi menjadi kurang akurat, sedangkan rentang kepercayaan yang cenderung pendek

menunjukkan bahwa estimasi pada kelompok sampel semakin dekat dengan nilai sesungguhnya di populasi.

Untuk memperoleh *sampling error*, kita tinggal mengalikan *standard error* dengan nilai kritis z , yaitu nilai yang berkaitan seberapa luas area kurva normal yang ingin diestimasi oleh peneliti. Nilai kritis z tergantung pada taraf kepercayaan (α) yang ditetapkan peneliti sebelum mengambil data. Apabila peneliti menetapkan $\alpha=95\%$, maka nilai $z=1.96$, sehingga *sampling error* (E)..

$$E = 1.96 \cdot SE$$

Sedangkan untuk menghitung rentang kepercayaan (pada taraf kepercayaan 95%) adalah $\bar{y} \pm E$.

Ilustrasi 1: Seorang peneliti Psikologi Politik melakukan survei pada 1000 responden di kota Lumajang dan menyimpulkan bahwa 32% responden menyatakan akan memilih ibu Paulina sebagai Walikota, lalu 34% responden menyatakan mendukung bapak Fernando Jose pada pemilihan umum bulan depan. Sedangkan sisanya tidak bersedia menjawab, tidak tahu, dan belum memutuskan. Berdasarkan informasi tersebut, maka SE_p dapat diketahui sebesar 0.014.

Apabila peneliti tersebut menetapkan taraf kepercayaan (α) sebesar 95%, maka *sampling error* (E) adalah $1.96 \cdot 0.014 = 0.028$ atau 2.8 persen. Oleh karena itu, dapat disimpulkan peneliti tersebut yakin (dengan peluang sebesar 95%) bahwa dukungan warga Lumajang pada ibu Paulina berkisar antara 29.2-34.8% ($32\% \pm 2.8\%$) dan dukungan pada bapak Fernando Jose berkisar antara 31.2-36.2 persen ($34\% \pm 2.8\%$).

Namun karena taraf kepercayaan yang ditetapkan sebesar 95%, maka masih ada peluang sebesar 5% bahwa persentase dukungan warga kota Lumajang pada masing-masing kandidat, jatuh di luar rentang kepercayaan tersebut. Karena rentang kepercayaan dukungan pada ibu Paulina dan bapak Fernando Jose tumpang

tindih, maka meskipun pada kelompok sampel bapak Fernando Jose mendapatkan suara terbanyak, belum tentu ia memenangkan pemilihan umum.

Ilustrasi 2: Seorang peneliti Psikologi Politik melakukan survei pada 100 responden di kota Magetan untuk mengetahui berapa kali responden melihat iklan calon legislatif dalam sehari. Apabila responden penelitian rata-rata melihat iklan calon legislatif sebanyak 12 kali dalam sehari dengan standar deviasi sebesar 8 kali, maka $SE_{\mu}=0.8$. Apabila α ditetapkan sebesar 95%, maka E sebesar $1.96*0.8=1.56$ kali (dibulatkan ke atas menjadi 2 kali).

Dari informasi tersebut, umumnya (dengan peluang sebesar 95%) warga kota Magetan rata-rata melihat iklan calon legislatif antara 10-14 (10 ± 2) kali dalam sehari. Namun karena α ditetapkan sebesar 95%, maka masih ada peluang sebesar 5% rerata intensitas warga Magetan melihat iklan calon legislatif dalam sehari, jatuh di luar rentang tersebut.

Apabila memperhatikan kembali formula *standard error* dan *sampling error* kita dapat menyimpulkan bahwa estimasi survei akan semakin akurat ketika sampel memiliki variasi yang rendah (ditunjukkan oleh standar deviasi yang kecil) dan ketika peneliti mengambil sampel dalam jumlah besar. Yang menarik, ukuran populasi tidak berkaitan dengan akurasi sehingga bertentangan dengan yang banyak dipercayai oleh orang awam, $n = 1000$ akan menghasilkan tingkat akurasi yang sama besarnya berapapun ukuran populasi yang diwakilinya.

Ketika melakukan teknik *probability sampling*, peneliti juga harus mempertimbangkan taraf respon (*response rate*). Seandainya peneliti mengundang 1000 orang yang terpilih menjadi sampel dan hanya 100 orang yang bersedia dan menyelesaikan partisipasi, artinya taraf respon hanya sekitar 10% saja. Padahal apabila taraf respon kurang dari 70 persen, maka sangat besar kemungkinannya bahwa banyaknya partisipan yang tidak merespon tidak terjadi secara kebetulan (*random*) sehingga sangat mungkin terjadi bias (Ruel et al., 2016). ***Nonresponse error*** merupakan sumber kesalahan yang langsung berdampak pada kualitas temuan penelitian survei sehingga apabila taraf respon rendah, maka kualitas data yang didapatkan menjadi kurang baik.

Menentukan sampel dengan teknik *probability sampling* adalah strategi yang ideal, namun yang lebih sering terjadi, peneliti menghadapi kondisi dimana *probability sampling* tidak dapat dilakukan. Kendala yang paling umum adalah peneliti tidak memiliki informasi yang cukup untuk membuat *sampling frame* sehingga peluang terpilihnya satu unit sampel tidak dapat diketahui. Bisa juga kondisi ini terjadi ketika penelitian survei melibatkan populasi dengan kriteria yang sangat spesifik sehingga sulit diakses. Dalam kondisi ini, peneliti dapat menggunakan ***non-probability sampling*** dimana sampel ditarik tanpa proses pengacakan. Implikasinya memang tidak menyenangkan - bias dan *sampling error* tidak dapat diestimasi sehingga generalisasi sulit sekali dilakukan (Fowler, 2014).

Beberapa teknik *non-probability sampling* yang umumnya dilakukan (Ruel et al., 2016) adalah; ***convenience sampling***, yaitu pemilihan sampel berdasarkan kemudahan dan ketersediaan akses. Contohnya ketika peneliti merekrut keluarga, teman, kolega, dan kenalan lainnya sebagai responden survei. Strategi ini tentu berisiko membiarkan subjektivitas peneliti mengkontaminasi keputusan pemilihan sampel (*selection bias*). Selanjutnya adalah ***quota sampling***, yaitu *convenience sampling* yang ditambah batasan jumlah (kuota) pada kategori demografis tertentu (misalnya, 50% laki-laki dan sisanya perempuan).

Berikutnya adalah ***purposive atau judgemental sampling***, yang merupakan salah satu bentuk *convenience sampling*. Teknik ini digunakan ketika sampel dipilih berdasarkan pengetahuan mereka yang spesifik, yang berkaitan dengan topik penelitian. Terminologi lain untuk teknik ini adalah *key informant interview*, yaitu ketika hanya informan yang dianggap menguasai isu yang sedang diteliti, yang dicakup sebagai sampel. Teknik *purposive sampling* cocok digunakan ketika meneliti komunitas marjinal karena umumnya *sampling frame* pada

komunitas marjinal (misalnya, anak jalanan, pekerja sosial, aktivis LSM, dsb.) tidak tersedia dan tidak terkonsentrasi pada satu area tertentu.

Yang terakhir, *snowball sampling* atau yang juga dikenal sebagai *chain referral* atau *chain sampling*, yaitu strategi rekrutmen responden dengan cara meminta responden penelitian untuk merekomendasikan atau merujuk calon responden lainnya yang sesuai dengan kriteria yang ditetapkan oleh peneliti. Teknik ini sangat cocok apabila peneliti menghadapi populasi yang sulit diakses, lebih kecil cakupannya dari populasi umum, dan umumnya berada di lokasi yang saling berjauhan.

3.1.3 Menilai kualitas temuan penelitian survei

Di banyak laporan penelitian survei, *sampling error* (atau *margin error*) dilaporkan sedemikian rupa sehingga menimbulkan kesan bahwa seolah-olah *sampling error* adalah satu-satunya indikator yang mencerminkan kualitas survei secara keseluruhan. Padahal faktanya, sumber kesalahan (*source of error*) lainnya justru lebih penting untuk dikendalikan, terutama pada survei yang melibatkan jumlah sampel atau populasi target yang besar. Selain itu, tidak jarang peneliti melaporkan *sampling error*, padahal peneliti tidak mempertimbangkan struktur populasi ketika proses pengacakan, atau bahkan ketika ia tidak melakukan *probability sampling* sama sekali. Padahal tidak mungkin *sampling error* dapat dihitung ketika peneliti tidak melakukan *probability sampling* sehingga dalam situasi seperti ini, memberikan informasi mengenai *sampling error* tentu akan memberikan impresi yang keliru mengenai proses penelitian.

Banyak peneliti survei sepakat perlu adanya kerangka kerja yang lebih luas untuk menilai kualitas survei sehingga paradigma *total survey error* (TSE) digagas sebagai kerangka kerja yang

dapat membantu peneliti memperkirakan kualitas temuan penelitian survei. TSE pada dasarnya adalah **akumulasi seluruh sumber kesalahan (yang menyebabkan ketidaktepatan estimasi) yang melekat pada desain, pengumpulan, pemrosesan, dan analisis data penelitian survei** (Biemer, 2010; Groves & Lyberg, 2010). Dalam konteks ini, *error* merujuk pada penyimpangan (atau selisih) antara estimasi pada kelompok sampel dengan nilai parameter yang sesungguhnya di populasi. TSE mencakup beberapa sumber kesalahan yang semuanya memiliki dampak langsung dalam menentukan kualitas temuan penelitian survei.

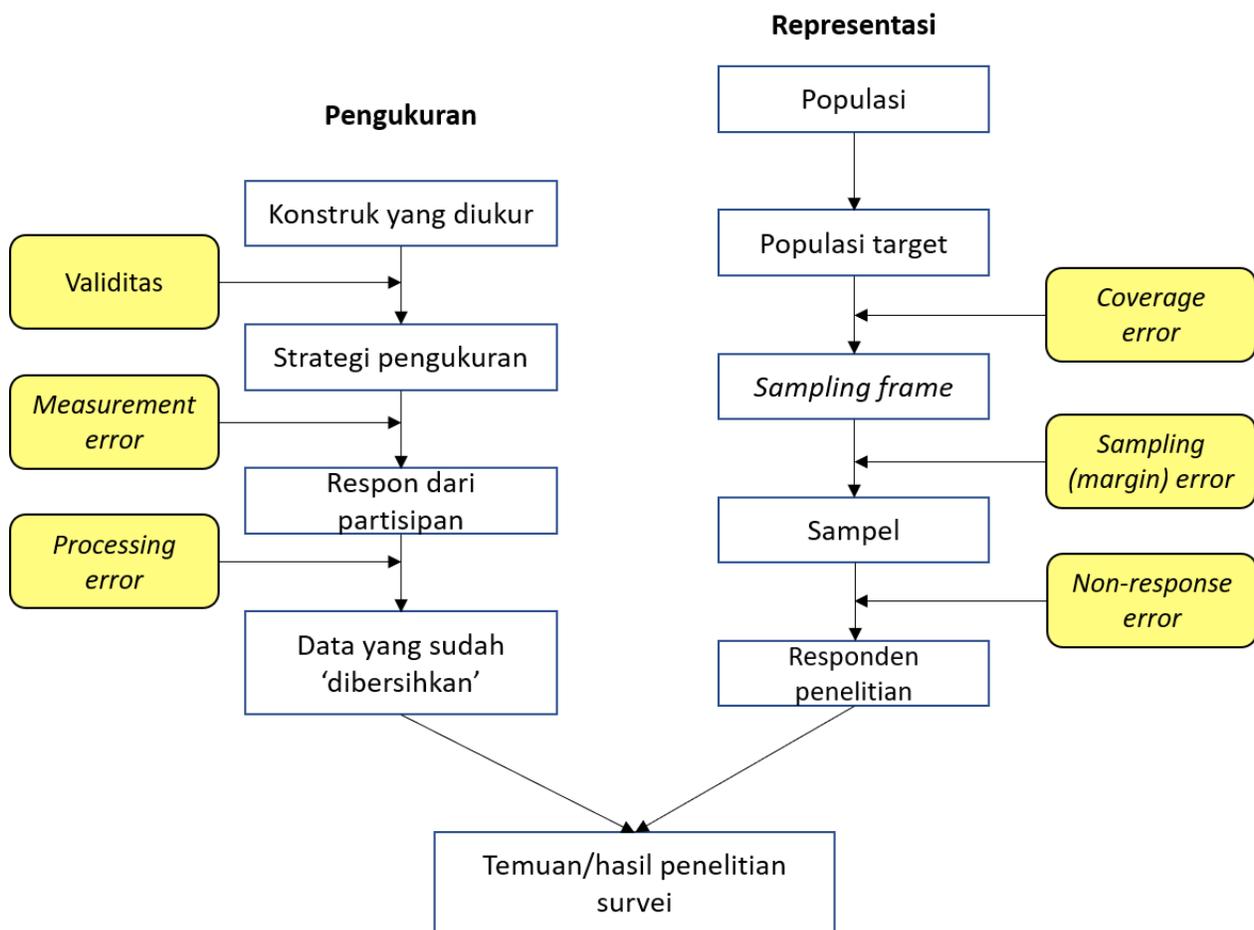


Figure 3: Total Survey Error, diadopsi dari Groves dan Lyberg (2010).

TSE pada dasarnya mencakup semua kemungkinan kesalahan yang muncul dari proses penelitian survei yang tidak hanya melibatkan *sampling error* saja. TSE mencakup semua kemungkinan kesalahan yang terjadi pada dua proses utama dalam survei, yaitu penarikan sampel dan pengukuran konstruk yang diteliti (Groves & Lyberg, 2010). Beberapa diantaranya (*validitas, measurement error/reliabilitas, coverage error, dan nonresponse error*) telah dijelaskan di bagian sebelumnya. Sedangkan *processing error* merupakan kesalahan yang mungkin terjadi ketika proses *input* data (apabila menggunakan survei dengan administrasi *paper-based*), pembersihan (*data cleaning*), pembobotan (*weighting*), pengorganisasian dan transformasi data (*data wrangling*).

Meskipun TSE telah mencakup lebih banyak aspek yang mempengaruhi akurasi temuan survei, banyak peneliti belum puas dan menyebutnya terlalu sederhana karena mengabaikan aspek kualitas dari kacamata pengguna survei. Apalagi pengguna survei biasanya tidak terlalu memperhatikan, bahkan menerima begitu saja, aspek akurasi ini (Biemer, 2010). Dalam menilai kegunaan dan kualitas temuan survei pengguna lebih memprioritaskan ketepatan waktu, aksesibilitas, kegunaan data, dan desain instrumen yang relevan dengan pertanyaan penelitian yang akan dijawab (Biemer, 2010). Oleh karena itu, dapat disimpulkan bahwa kualitas survei merupakan konsep yang kompleks, multidimensional, dan lebih komperhensif melampaui cakupan TSE.

Dengan mengintegrasikan standar kualitas yang ditetapkan oleh berbagai Biro Statistik milik pemerintah di berbagai negara dan kawasan, seperti Eurostat, Australian Bureau of Statistics, Statistics Canada, Stats NZ (Selandia Baru), dan U.S. Census Bureau, Biemer (2010) mengagas kerangka kerja yang lebih komperhensif dalam menilai kualitas survei yang disebut

total survey quality framework (SQF). SQF dapat menjadi daftar tilik (*checklist*) untuk menilai kualitas survei secara keseluruhan dan mencakup sembilan dimensi (lihat tabel 1).

Tabel 1. Dimensi *Survey Quality Framework* (Biemer, 2010)

Dimensi	Deskripsi
Akurasi	<i>Total survey error</i> diminimalisasi
Kredibilitas	Temuan survei dianggap terpercaya atau kredibel oleh komunitas profesional
Komparabilitas	Perbandingan temuan survei pada kategori demografis, spasial, dan temporal yang berbeda tepat dan meyakinkan (<i>robust</i>)
Kegunaan/Kemudahan interpretasi data	Dokumentasi dan metadata disimpan dengan baik dan mudah digunakan
Relevansi	Data/temuan hasil survei sesuai dengan kebutuhan pengguna
Aksesibilitas	Akses pada data mentah tersedia dan mudah diakses
Ketepatan waktu	Proses survei diselesaikan tepat pada waktunya
Kelengkapan	Data sudah cukup kaya sehingga analisis data dapat menjawab pertanyaan penelitian, tanpa harus membebani partisipan secara berlebihan
Koherensi	Apabila temuan dicek silang dengan data lain dari sumber yang berbeda, akan menghasilkan kesimpulan yang tidak jauh berbeda

3.1.4 Teknik pengumpulan data survei

Memilih metode administrasi survei merupakan keputusan penting yang harus diambil oleh peneliti. Survei dapat dilakukan dengan wawancara terstruktur, yaitu dilakukan dengan bertanya langsung pada responden lalu merekam jawabannya, atau instrumen dapat diisi secara mandiri oleh responden (*self-report*). Ketika diputuskan bahwa survei diadministrasi dengan

wawancara, peneliti dapat mewawancarai responden melalui telepon (*telephone-based survey*), *interactive voice response* (IVR), atau langsung dengan tatap muka. Apabila instrumen diisi secara mandiri oleh partisipan, survei dapat menggunakan cara klasik, yaitu menggunakan kertas (*paper-based*). Alternatif yang saat ini populer digunakan adalah menggunakan *platform* penyedia layanan kuesioner daring, seperti [Google Forms](#), [LimeSurvey](#), [Qualtrics](#), [SosSci Survey](#), dsb. Kuesioner dapat diisi secara klasikal, dimana partisipan dikumpulkan dalam satu ruangan lalu mengisi kuesioner bersama-sama, atau dapat juga diisi secara mandiri dengan perangkat yang disediakan peneliti atau yang dimiliki sendiri oleh responden.

Peneliti juga punya banyak pilihan strategi dalam merekrut responden, yaitu dapat dengan mengirim surat elektronik, mengeposkan kuesioner ke alamat responden, merekrut melalui *platform crowdworkers* seperti Amazon Mechanical Turk (MTurk), Clickworker, atau Prolific. Peneliti juga dapat memasang iklan atau undangan berpartisipasi di media sosial atau menyebarkannya secara berantai melalui aplikasi *instant messaging*, seperti WhatsApp, LINE, atau Telegram. Yang perlu diperhatikan, merekrut responden melalui *platform crowdworkers* atau melalui pesan berantai dan pemasangan iklan di media sosial atau aplikasi *instant messaging* berimplikasi pada tidak mungkinnya proses *sampling* dilakukan karena keputusan berpartisipasi sangat bergantung pada kesediaan responden. Artinya, responden yang berpartisipasi adalah orang adalah yang secara sukarela bersedia berpartisipasi, bukan yang dipilih oleh peneliti melalui proses penentuan sampel. Oleh karena itu, merekrut dengan strategi ini berisiko menimbulkan *self-selection bias* (Bethlehem, 2010).

Dalam memilih teknik pengumpulan data, metode administrasi, dan strategi perekrutan responden yang tepat, peneliti perlu memperhatikan beberapa hal yang berkaitan dengan tujuan dan desain penelitiannya (Fowler, 2014). Faktor pertama yang perlu dipertimbangkan adalah

strategi penarikan *sampling*. Strategi yang digunakan peneliti untuk menarik sampel akan berimplikasi pada cara pengambilan data. Apabila peneliti hanya memiliki *sampling frame* yang berisi nama anggota populasi tanpa alamat pos, nomor telpon, alamat surat elektronik, atau nomor ponsel, maka mengumpulkan data dengan model korespondensi tidak mungkin dilakukan. Beberapa peneliti memilih langsung mendatangi tempat tertentu dimana responden dapat ditemui (misalnya, tempat kerja, sekolah, dsb.) sehingga dalam konteks ini banyak pilihan teknik pengambilan data yang bisa dilakukan, baik dengan wawancara langsung, menggunakan kuesioner cetak, atau menggunakan kuesioner dengan alat bantu seperti tablet, komputer *desktop*, atau ponsel - semuanya dapat dilakukan.

Faktor yang kedua adalah **karakteristik populasi target**. Model *self-report* lebih cocok diterapkan pada responden dengan kemampuan literasi yang memadai sehingga pada populasi dengan tingkat pendidikan yang cenderung rendah, wawancara terstruktur akan menghasilkan data yang lebih baik. Apabila peneliti memilih untuk mengadministrasikan kuesioner dengan menggunakan perangkat tertentu dan membutuhkan internet, maka peneliti berisiko mengecualikan responden yang tidak memiliki dan/atau tidak mampu mengoperasikan perangkat, serta yang tidak memiliki akses internet. Menggunakan model *self-report* juga berpotensi meningkatkan jumlah responden yang tidak menyelesaikan pengisian kuesioner dan semakin banyak jumlah pertanyaan yang tidak dijawab (*missing*). Apabila penyelesaian pengisian kuesioner dan kelengkapan respon adalah prioritas utama peneliti, maka administrasi kuesioner dengan wawancara akan menghasilkan data dan taraf respon yang lebih memuaskan.

Faktor berikutnya adalah **bentuk dan substansi kuesioner**. Apabila kuesioner banyak berisi pertanyaan terbuka (*open-ended question*), maka mengadministrasikannya dengan model *self-report* akan memperbesar kemungkinan kuesioner tidak seluruhnya diisi karena merespon

pertanyaan terbuka membutuhkan beban kognitif yang sangat besar. Kalaupun pertanyaan terbuka diisi oleh responden, seringkali respon tersebut tidak terlalu berguna. Untuk kuesioner dengan pilihan ganda yang melibatkan banyak opsi jawaban, wawancara terstruktur ataupun via telpon akan mempersulit pewawancara dan responden sehingga *self-report* lebih cocok digunakan. Ketika aitem dalam kuesioner menggunakan stimulus atau petunjuk visual, maka wawancara terstruktur lewat telepon juga tidak bisa dilakukan.

Selain bentuk aitem, substansi aitem dalam kuesioner juga perlu menjadi pertimbangan. Banyak ahli sepakat apabila substansi kuesioner menanyakan hal-hal yang dianggap sensitif, maka mewawancarai responden, baik secara langsung maupun melalui telepon, akan mendorong responden untuk memberikan jawaban yang diinginkan secara sosial (*socially desirable*) bukan jawaban yang sebenarnya. Apabila peneliti membutuhkan respon yang sangat detail mengenai aktivitas partisipan, misalnya berapa kali partisipan melihat baliho iklan calon anggota legislatif, atau berapa lama dalam sehari waktu yang dihabiskan untuk membaca berita politik, maka peneliti perlu meminimalisasi beban responden untuk mengingat kembali aktivitas yang mereka lakukan. Strategi terbaik yang dapat diterapkan meminta responden mengisi semacam diari yang dapat disimpan untuk merekam aktivitas mereka sehari-hari. Atau peneliti dapat menggunakan teknologi yang dapat memungkinkan responden melaporkan aktivitas mereka secara periodik via *short messaging service* (SMS), surat elektronik, atau dapat menggunakan aplikasi khusus yang didesain untuk kepentingan pengambilan data. Pendekatan ini juga dikenal sebagai *ecological momentary assessment* (EMA), *experience sampling method* (ESM), atau *ambulatory assessment*.

3.1.5 Survei opini publik, hitung cepat (*quick count*), dan *exit poll*

Menjelang pemilihan umum, aktivitas survei opini publik yang diselenggarakan oleh lembaga survei non-pemerintah marak menghiasi pemberitaan. Sejak pertama kali diperkenalkan oleh ilmuwan Psikologi, George Gallup, yang melakukan survei opini publik menjelang pemilihan Presiden Amerika Serikat pada tahun 1933, survei opini publik merupakan bagian penting dari proses demokrasi di beberapa negara (Donsbach, 2015). Di Indonesia, survei opini publik marak dilakukan pasca pemerintahan Orde Baru dan mulai menjadi bagian penting dari politik elektoral di Indonesia sejak pemilihan umum tahun 2004. Sejak era Orde Baru berakhir, masyarakat nampaknya sudah memiliki aspirasi yang konkrit mengenai kualitas figur yang mereka harapkan untuk menempati jabatan publik. Kualitas ini lebih mengarah pada kinerja daripada ikatan primordial sehingga politisi mulai tertarik untuk mendapatkan lebih banyak informasi mengenai calon pemilih mereka. Survei opini publik yang dilakukan oleh lembaga survei dapat mengakomodasi kebutuhan ini (Mietzner, 2009).

Tidak hanya survei opini publik yang lazimnya dilakukan sebelum atau pada masa kampanye, lembaga survei juga melakukan hitung cepat (*quick count*) dan beberapa diantaranya melakukan *exit poll*. Berbeda dengan survei opini publik yang menggunakan individu pemilih sebagai unit analisis, hitung cepat menggunakan tempat pemungutan suara (TPS) sebagai sampel untuk memprediksi hasil pemilihan umum. Hasil penghitungan suara di TPS sampel kemudian diakumulasi dan dijadikan informasi sementara yang dapat diakses publik mengenai hasil pemilihan umum, sembari menunggu hasil perhitungan dan verifikasi suara yang dilakukan Komisi Pemilihan Umum yang biasanya membutuhkan waktu kurang lebih sebulan setelah pemungutan suara. *Exit poll* sedikit berbeda karena data didapatkan dengan mewawancarai pemilih segera setelah ia keluar dari TPS. Dari segi kecepatan, *exit poll* memungkinkan lembaga survei menyimpulkan temuan lebih cepat, setidaknya tidak jauh setelah waktu pemungutan suara berakhir, sedangkan hitung cepat baru dapat dikumpulkan ketika penghitungan suara selesai

dilakukan di TPS. Namun dari segi akurasi, hitung cepat biasanya lebih akurat karena menggunakan data riil dari penghitungan suara di tingkat TPS.

Meskipun kerap kali dipertanyakan kredibilitasnya, seperti yang diuraikan penulis sebagai pembuka bab ini, mayoritas lembaga survei di Indonesia menyediakan informasi yang substansial mengenai perilaku pemilih. Dalam pemilihan Presiden tahun 2019, misalnya, sebagian besar temuan dari survei opini publik yang dilakukan lembaga survei, menyebutkan Joko Widodo (Jokowi)-Ma'ruf Amin mendapatkan lebih banyak dukungan, yaitu sekitar mendekati sampai sedikit di atas 50 persen, sedangkan kompetitornya hanya mendapat sekitar 31-37 persen (Soderborg, 2019). Temuan ini sejalan dengan hasil pemilihan umum 2019, dimana Jokowi-Ma'ruf Amin meraup suara hingga 55.5 persen. Hasil hitung cepat sebagian besar lembaga survei juga terbukti amat akurat dengan rata-rata *sampling error* hanya kurang dari 1 persen (Intan, 2019).

Yang menarik, lembaga-lembaga survei di Indonesia memiliki rekam jejak yang kurang baik dalam memprediksikan dukungan pemilih pada partai-partai Islam dari survei opini publik yang mereka selenggarakan. Pada pemilihan legislatif 2014 dan 2019 misalnya, suara yang diperoleh Partai Keadilan dan Sejahtera (PKS), Partai Amanat Nasional (PAN), dan Partai Persatuan Pembangunan (PPP) secara konsisten lebih tinggi daripada yang diprediksikan dari survei opini publik yang dilakukan oleh kebanyakan lembaga survei (Fealy, 2014; Soderborg, 2019). Adanya kesenjangan antara survei opini publik mengenai dukungan pada partai-partai Islam dengan hasil pemilihan umum memantik pertanyaan-pertanyaan menarik; apakah responden sengaja 'menyembunyikan' dukungannya pada partai Islam? Atau apakah ada kemungkinan desain kuesioner yang digunakan mengandung bias yang merugikan pendukung partai Islam?

Soderborg (2019) menemukan bukti pemilih PPP dan PKS lebih mungkin “menyembunyikan” pilihan mereka ketika diwawancarai oleh lembaga survei, dibandingkan dengan pemilih partai lainnya. Mengingat dukungan pada partai Islam juga dapat dijelaskan oleh lokasi geografis pemilih karena pemilih partai Islam biasanya terkonsentrasi pada lokasi-lokasi tertentu, maka desain pengambilan sampel yang diterapkan lembaga survei dapat juga menjadi penyebab inakurasi ini. Soderborg (2019) juga menemukan bukti yang menguatkan dugaan ini, yaitu ada korelasi yang jelas antara jumlah sampel yang diambil lembaga survei dengan dukungan pada partai-partai Islam. Artinya, survei yang menggunakan jumlah sampel lebih banyak akan melaporkan tingkat keterpilihan partai-partai Islam yang lebih tinggi daripada survei dengan jumlah responden yang lebih sedikit. Lebih lanjut, ada juga kemungkinan partai-partai Islam diuntungkan oleh proses kampanye yang lebih intensif di hari-hari akhir menjelang pemungutan suara.

Pertanyaan mengenai kredibilitas lembaga survei bukan hal baru dan sebenarnya dapat diperiksa dengan cukup mudah dengan standar yang jelas, yaitu dengan memperhatikan *survey quality framework* (SQF) (Groves & Lyberg, 2010). Namun yang kerap kali terjadi, dalam mengkomunikasikan temuannya, lembaga survei terlalu berfokus pada *sampling error* dan tidak banyak informasi yang tersedia untuk mengevaluasi apakah lembaga survei melakukan pekerjaannya dengan baik dalam mengendalikan sumber kesalahan yang lain. Laporan yang dirilis lembaga survei biasanya hanya berupa rangkuman eksekutif dengan informasi yang sangat minimal sehingga sulit menakar akurasi temuan survei yang mereka lakukan, lebih-lebih apabila memperhatikan berbagai dimensi dalam *total survey error*. Laporan yang dirilis juga seringkali hanya mencantumkan persentase atau proporsi absolut, tidak sekaligus dengan rentang kepercayaannya. Hal ini konsisten dengan yang dituliskan Biemer (2010), yaitu meskipun peneliti di lembaga akademik dan biro statistik milik pemerintah sudah mulai menetapkan standar

kualitas yang ketat dengan mengadopsi SQF, praktik yang sama tidak ditemui pada lembaga survei non-pemerintah.

Dalam mengkomunikasikan temuan penelitian survei, utamanya untuk kepentingan akademik, peneliti sangat disarankan untuk selalu melaporkan rentang kepercayaan (*confidence interval*) untuk memberikan informasi kepada pembaca mengenai akurasi estimasi yang dilakukan oleh peneliti. Sebagian besar *outlet* publikasi ilmiah terkemuka sudah mensyaratkan pelaporan rentang kepercayaan, utamanya jurnal-jurnal yang diterbitkan oleh American Psychological Association (APA) (Appelbaum et al., 2018). Misalnya, apabila berdasarkan hasil survei kandidat A memperoleh 64% suara dengan *sampling error* sebesar 6 persen, maka seharusnya dalam laporan disebutkan, "...berdasarkan hasil survei, kandidat A mendapatkan dukungan terbanyak, yaitu sekitar 64% (95% CI 59-70%) responden penelitian.."

Kurangnya transparansi dan kontrol publik merupakan kritik yang paling sering dilontarkan pada lembaga survei. Laporan lengkap, data mentah, dokumentasi, dan metadata dari survei opini publik yang mereka umumkan hasilnya juga tidak bisa diakses terbuka sehingga sulit untuk menakar kredibilitas temuannya. Meskipun beberapa lembaga survei yang dipandang profesional sudah memulai tradisi baik dengan bersedia memaparkan data hitung cepat yang dikumpulkan pada pemilihan umum serentak tahun 2019 yang lalu (Intan, 2019), informasi yang diberikan sangat terbatas sehingga sulit menakar apakah temuan tersebut dapat direka-ulang (*reproducibility*). Data hitung cepat yang dipaparkan Cyrus Network dan Center for Strategic and International Studies (CSIS) di momen tersebut, misalnya, disajikan dalam bentuk statis dalam format .html dan nyaris tidak memiliki kegunaan sama sekali untuk diperiksa, apalagi disimpulkan akurasi estimasinya. Informasi krusial lainnya seperti desain *sampling* juga tidak ditemukan.

Lembaga survei di Indonesia juga menghadapi dilema yang sama seperti kolega mereka di Amerika Serikat. Banyak literatur yang menyebutkan potensi kerugian yang ditimbulkan akibat

pengaruh lembaga survei pada demokrasi modern. Yang pertama, hasil survei dapat mendorong kebijakan yang cenderung populis yang kemungkinan justru bertentangan dengan prinsip-prinsip rasionalitas ataupun praktik baik pemerintahan (*good governance*). Yang kedua, ada tendensi bahwa hasil survei opini publik mungkin kurang akurat, bias, dan merupakan instrumen yang cenderung manipulatif (karena sebagian ditujukan untuk membentuk opini publik dan bagian dari pemasaran politik) dalam kompetisi antar-elit politik. Persoalan ini amat relevan dengan kondisi politik elektoral di Indonesia yang punya problem klasik, yaitu politik uang (*vote buying*) dan patrimonialisme (pembagian kekuasaan berdasarkan hubungan kekerabatan) (Mietzner, 2009).

Sejak pemilihan Presiden dan Kepala Daerah dilakukan secara langsung, politisi menyadari bahwa meningkatkan popularitas dirinya di mata pemilih akan meningkatkan peluang dirinya untuk benar-benar terpilih. Implikasinya, politisi yang berlaga di pemilihan umum akan sangat memperhatikan profil pemilih dan mewujudkan aspirasi pemilih yang tercermin dari hasil survei opini publik. Akhirnya politisi tergoda untuk menggunakan jasa konsultan pemasaran politik dan *branding* agar dapat (secara artifisial) meningkatkan popularitas mereka (Mietzner, 2009). Akibatnya, selain biaya politik menjadi semakin besar, lembaga survei membaca permintaan ini sebagai peluang bisnis dengan sekaligus menyediakan jasa konsultan politik (Hidayat, 2018). Celakanya, lembaga survei yang menyediakan jasa konsultan tidak mengungkapkan konflik kepentingan ini ketika mengumumkan temuannya, membuat publik semakin ragu dengan kredibilitas mereka. Padahal, menyertakan seluruh informasi yang mungkin menjadi sumber konflik kepentingan adalah kewajiban akademisi ketika melaporkan temuan penelitian.

Dalam situasi yang tidak ideal, dimana informasi yang diperlukan untuk memeriksa kesahihan temuan survei tidak banyak tersedia, pemilih dapat melakukan tiga hal agar informasi

dari survei opini publik dapat berguna. **Yang pertama**, hindari mengambil informasi secara eksklusif hanya dari satu lembaga survei. Lebih bijaksana apabila pemilih membandingkan temuan beberapa lembaga survei sekaligus, kemudian setelahnya membuat kesimpulan atas berbagai temuan yang dirilis beberapa lembaga survei yang berbeda. **Yang kedua**, apabila selisih antara hasil survei opini publik, hitung cepat, atau *exit poll* yang dikeluarkan suatu lembaga survei dengan hasil pemilu yang sebenarnya (*real count*) lebih atau kurang dari *sampling error* yang dilaporkan, maka kemungkinan desain *sampling* lembaga tersebut kurang andal. **Yang ketiga**, apabila lembaga survei mengadopsi sekian derajat transparansi (misalnya, menyediakan rilis pers atau ringkasan eksekutif yang bisa diakses publik), maka setidaknya lembaga tersebut lebih bisa dipercaya daripada yang tidak melakukannya sama sekali.

Ada banyak misteri dan problem yang meliputi survei opini publik yang dilakukan lembaga survei sehingga meskipun mengadopsi metode ilmiah, sulit rasanya mengkonsiderasi temuan survei opini publik sama kualitasnya dengan penelitian yang dilakukan akademisi (yang biasanya melalui proses tinjauan sejawat) atau survei yang dilakukan oleh statistisi di biro statistik dan lembaga penelitian milik pemerintah seperti BPS atau Balitbangkes Kementerian Kesehatan. Namun yang perlu diingat, seluruh survei, terlepas dari siapapun yang menyelenggarakannya, tidak mungkin benar-benar terbebas dari sumber kesalahan dan bias. Lalu apabila survei tidak mungkin terbebas dari kesalahan, lalu survei seperti apa yang benar-benar kredibel?

Edward Deming (1944) memiliki jawaban yang menarik..

“...uraian sebelumnya mengenai sumber kesalahan survei jangan diartikan bahwa kita perlu berkecil hati atau kemudian menyimpulkan bahwa survei tidak berguna sama sekali. Yang saya maksudkan disini, akurasi yang disyaratkan agar temuan survei dianggap berkualitas seringkali dilebih-lebihkan — bahkan mungkin sama sekali

tidak mungkin dicapai sepenuhnya. Namun yang perlu diingat, data survei yang tersedia ternyata bermanfaat untuk memberikan dasar yang rasional untuk bertindak..(hal. 369)”

Memang ada banyak problem yang meliputi kredibilitas hasil survei opini publik. Tetapi setidaknya mengambil keputusan yang terpandu oleh data (*informed decision-making*) jauh lebih baik dan lebih bisa diandalkan daripada hanya mengandalkan intuisi.

3.2 Penelitian eksperimen

John Darley dan Bibb Latané (1968) melakukan percobaan untuk menguji hipotesis yang sederhana namun amat menarik: apabila semakin banyak orang yang menyaksikan keadaan darurat, maka semakin kecil kemungkinannya korban mendapat bantuan. Teori *diffusion of responsibility* yang diajukan Latane dan Darley ini terinspirasi dari kasus pembunuhan Kitty Genovese di kota New York yang terjadi pada tahun 1964. Meskipun “disaksikan” oleh setidaknya 38 saksi, tidak ada satupun orang yang menolong Kitty ketika diserang oleh tersangka yang memperkosa dan kemudian membunuhnya.

Untuk menguji prediksi tersebut, Darley dan Latané merekrut 72 mahasiswa (59 perempuan dan 13 laki-laki) untuk berpartisipasi dalam percobaan tersebut. Tim eksperimenter menciptakan simulasi dalam laboratorium, dimana responden diminta untuk sendirian memasuki sebuah ruangan kecil dan diberi informasi bahwa ia akan melakukan diskusi dengan mahasiswa lain, yang berperan sebagai aktor, mengenai kehidupan kampus yang berada di ruangan yang lain. Diskusi tersebut dilakukan melalui interkom yang memungkinkan diskusi tersebut dilakukan, meskipun responden dan aktor berada di ruangan yang terpisah.

Tak lama setelah diskusi dimulai, aktor kemudian menyatakan kepada responden bahwa ia kemungkinan mengalami kejang dengan mengatakan, “...sepertinya saya sangat membutuhkan bantuan. Sepertinya saya akan segera mati, tolong... saya mungkin akan mati karena kejang..” lalu diikuti suara tercekik dan keheningan panjang. Faktanya, tidak ada mahasiswa yang mengalami kejang. Semua percakapan aktor merupakan rekaman yang telah disiapkan oleh peneliti sebelum percobaan. Yang menarik, responden penelitian menerima perlakuan yang berbeda lalu diikuti oleh respon perilaku yang berbeda pula. Responden secara acak dibagi menjadi tiga kelompok dengan kondisi (perlakuan) yang berbeda. Sebagian diberikan informasi bahwa mereka melakukan diskusi dengan

satu aktor (kelompok 1), dua (kelompok 2), dan sisanya dengan 5 orang aktor (kelompok 3). Sesuai prediksi, Darley dan Latané menemukan bahwa peluang responden untuk keluar ruangan dan memberikan pertolongan menunjukkan tren penurunan mulai dari 85%, 62%, kemudian 31% seiring dengan penambahan jumlah aktor yang dipercayai responden terlibat diskusi dengan mereka.

Penelitian yang dilakukan oleh Darley dan Latané yang diuraikan di atas adalah contoh penelitian eksperimen. Eksperimen merupakan desain penelitian yang memiliki sejarah panjang dan kontribusi besar dalam teorisasi Psikologi. Eksperimen biasanya digunakan untuk menguji hubungan sebab-akibat antara dua atau lebih variabel penelitian. Ada tiga jenis variabel dalam penelitian eksperimen, yaitu **variabel dependen** (*outcome variable*), **variabel independen** (prediktor), dan **variabel extraneous**. Penelitian eksperimen murni (*true experiment*) sedikitnya melibatkan tiga aspek, yaitu **kontrol** (dengan pengacakan), **manipulasi**, dan **pengukuran (observasi)** atas efek yang ditimbulkan dari manipulasi yang dilakukan. **Variabel independen** paling sedikit memiliki dua variasi (atau kondisi), yaitu kondisi perlakuan (*treatment*) dan yang kedua adalah kontrol (atau perbandingan). Pengukuran yang dilakukan oleh peneliti untuk mendeteksi perubahan di masing-masing kondisi tersebut disebut juga **variabel dependen**. Oleh karena itu, disimpulkan bahwa perubahan yang terjadi pada individu (variabel dependen) **disebabkan oleh** perbedaan perlakuan (variabel independen) yang diterima.

Berdasarkan ilustrasi penelitian eksperimen yang dilakukan Darley dan Latané, variabel independen yang diteliti adalah **jumlah aktor** yang dipercayai responden sedang berdiskusi dengannya. Peneliti sengaja melakukan manipulasi dengan menentukan variasi kondisi - dimana responden dibagi menjadi tiga kelompok dan masing-masing percaya sedang berdiskusi dengan aktor dalam jumlah yang berbeda, yaitu satu, tiga, atau lima orang aktor. Dalam penelitian ini, ada **satu variabel independen** dengan **tiga kondisi** atau level yang berbeda. Sedangkan variabel

dependennya adalah jumlah partisipan yang memutuskan keluar ruangan dan memberikan pertolongan kepada aktor.

Penelitian eksperimen adalah desain penelitian yang andal untuk menguji hubungan sebab-akibat karena memungkinkan peneliti untuk memenuhi syarat penyimpulan hubungan sebab-akibat, berbeda dengan penelitian non-eksperimental seperti survei. Untuk mengkonfirmasi adanya hubungan sebab-akibat, tiga syarat berikut ini harus terpenuhi (Shaughnessy, Zechmeister, & Zechmeister, 2012). **Yang pertama** adalah **kovariansi**, yang dapat dipenuhi peneliti dengan menemukan bukti bahwa ada korelasi/hubungan antara variabel dependen dan independen.

Yang kedua adalah hubungan tersebut harus memenuhi asumsi **urutan dan waktu kejadian**. Menemukan korelasi antar dua variabel dengan desain survei *cross-sectional*, misalnya, tidak cukup memberikan bukti bahwa kedua variabel tersebut memiliki hubungan sebab-akibat. Logikanya, sebab dan akibat selalu terikat pada urutan dan waktu kejadian - sebab selalu lebih dulu muncul, kemudian diikuti oleh akibat yang terjadi setelahnya. Survei *cross-sectional* tidak mengakomodasi waktu dalam desainnya, namun pada survei dengan desain longitudinal atau *time-series*, hubungan sebab-akibat masih mungkin untuk diinvestigasi. Oleh karena itu, ketika survei *cross-sectional* menemukan kaitan antara kepuasan pemilih atas kinerja calon Presiden dengan tingkat elektabilitasnya, misalnya, tidak bisa disimpulkan keduanya memiliki hubungan sebab-akibat karena peneliti tidak memiliki informasi yang cukup untuk menentukan mana variabel yang menjadi penyebab atau akibat.

Tetapi mengakomodasi urutan dan waktu kejadian belum sepenuhnya memadai untuk mengkonfirmasi hubungan sebab-akibat. Peneliti harus mengecualikan semua variabel yang mungkin berkaitan dengan dependen variabel sehingga ia benar-benar yakin bahwa perubahan

tersebut disebabkan oleh variabel independen, bukan oleh variabel lainnya (*extraneous*) (**catatan:** ingat kembali definisi *severe testing* yang diuraikan pada bagian pertama). Oleh karena itu, untuk mengklaim hubungan sebab-akibat, peneliti perlu **melakukan prosedur kontrol** yang dapat dilakukan dengan cara; (a) membuat variabel *extraneous* bernilai tetap/konstan (dengan teknik konstansi); (b) melakukan penugasan acak, yaitu pengacakan ketika menentukan responden mana yang menerima kondisi kontrol dan perlakuan (*random assignment*); dan (c) mengacak urutan pemberian perlakuan apabila responden menerima lebih dari satu perlakuan (*balancing*). Apabila meninjau penelitian yang dilakukan Darley dan Latané di atas, peneliti melakukan kontrol dengan menentukan pembagian kelompok perlakuan secara acak.

Apabila penelitian eksperimen dapat memenuhi ketiga syarat yang sudah disebutkan sebelumnya, maka dapat dikatakan penelitian eksperimen memiliki **validitas internal**, artinya peneliti benar-benar yakin bahwa perubahan yang terjadi pada variabel dependen disebabkan oleh perubahan/perbedaan/variasi pada variabel independen. Namun apabila karena alasan tertentu peneliti tidak mungkin menerapkan kontrol dengan melakukan pengacakan, maka penelitian tersebut tidak dapat disebut eksperimen murni, melainkan ***quasi-experiment*** (Price, Jhangiani, Chiang, Leighton, & Cuttler, 2017).

Salah satu praktik yang dianggap sebagai standar baku emas dalam menjamin validitas internal penelitian adalah ***double-blind randomised experiment*** karena dapat menekan bias paling optimal. Artinya dalam kondisi ini, baik peneliti maupun responden tidak mengetahui responden mana yang menerima perlakuan/kondisi tertentu. Apabila *double-blind randomisation* tidak mungkin dilakukan, maka setidaknya peneliti dapat melakukan ***single-blind randomised experiment***, yaitu kondisi dimana peneliti dapat mengidentifikasi responden yang menerima

perlakuan tertentu, tetapi responden tidak tahu ia masuk pada kondisi kontrol atau kondisi eksperimen.

(**Catatan:** validitas internal dalam penelitian eksperimen adalah **konsep yang berbeda** dengan validitas alat ukur Psikologi)

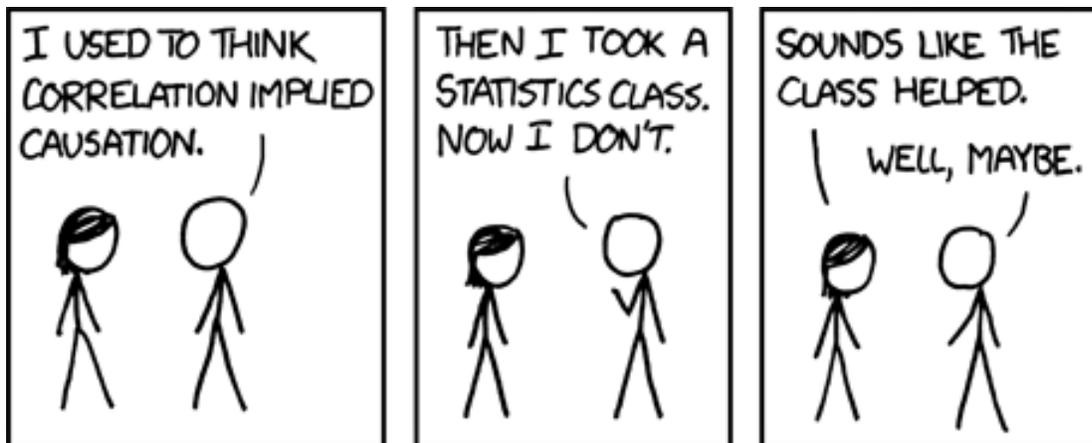


Figure 4.: Korelasi dan kausalitas. Sumber: <https://xkcd.com>

3.2.1 Ragam desain eksperimen (*within-subjects* dan *between-group design*)

Ada dua jenis desain eksperimen yang paling lazim diterapkan pada penelitian-penelitian Psikologi pada umumnya, yaitu perbandingan kelompok independen (*between-group design*) dan pengukuran berulang (*repeated measurement* atau *within-subjects design*). Pemilihan desain ini berimplikasi pada penerapan strategi kontrol yang berbeda.

3.2.1.1 *Between-group design*

Dalam desain *between-group* setiap responden hanya menerima satu jenis perlakuan. Desain ini adalah yang diterapkan oleh Darley dan Latané karena masing-masing responden hanya menerima satu jenis kondisi/perlakuan. Peneliti dapat melakukan kontrol dengan menerapkan penugasan acak, yaitu dalam menentukan responden mana yang masuk di kelompok

apa, peneliti melakukan pengacakan. Dalam asumsinya yang paling ketat, supaya melakukan pengacakan dengan sempurna, peneliti setidaknya harus memenuhi dua asumsi, yaitu (a) setiap responden memiliki peluang yang sama untuk masuk di setiap kondisi yang ada (apabila ada dua kondisi, maka satu responden memiliki peluang yang sama, yaitu 50%, pada masing-masing kondisi) dan (b) penentuan kondisi yang diterima responden harus independen dan tidak boleh dipengaruhi oleh responden lainnya (Price et al., 2017).

Cara yang paling sederhana untuk melakukan penugasan acak adalah dengan mengundi dengan melempar koin. Tetapi sayangnya cara ini berpotensi menghasilkan jumlah responden yang tidak setara pada masing-masing kondisi. Meskipun sebenarnya hal ini bukan masalah besar, tetapi secara praktis, jauh lebih efisien ketika membagi responden dalam kelompok yang sama besarnya (Price et al., 2017; Shaughnessy et al., 2012). Untuk memastikan jumlah responden di tiap kondisi sama besar, peneliti dapat melakukan **block randomisation** dengan bantuan perangkat lunak, misalnya <https://www.randomizer.org/>. Cara ini dapat dilakukan dengan **pertama**, membuat urutan kondisi secara acak, lalu **kedua**, memasang satu responden pada masing-masing kondisi dalam urutan tersebut. Proses ini dilakukan berulang-ulang sesuai dengan jumlah responden yang tersedia.

Tabel 2. Contoh **Block Randomisation** Menggunakan Contoh Studi Darley dan Latané (1968)

Nomor responden (diacak)	Kondisi (diacak)	Keterangan
6	Satu aktor	Urutan 1
1	Lima aktor	Urutan 1
2	Dua aktor	Urutan 1

7	Lima aktor	Urutan 2
5	Satu aktor	Urutan 2
3	Dua aktor	Urutan 2
9	Dua aktor	Urutan 3
8	Satu aktor	Urutan 3
4	Lima aktor	Urutan 3
..dst	..dst	..dst

Melakukan *block randomisation* tidak dapat menjamin variabel *extraneous* dapat dikontrol sepenuhnya. Karena menggunakan pengacakan, sangat mungkin peneliti secara acak, mendapati situasi yang tidak setara di masing-masing kondisi. Bisa jadi ada ketidaksetaraan proporsi gender, misalnya ada kelompok yang berisi lebih banyak perempuan, atau lebih banyak laki-laki. Dengan begitu, prosedur tambahan, yaitu teknik *matching* (atau teknik konstansi) diperlukan. Yang perlu diingat, meskipun penugasan acak tidak dapat sepenuhnya mengeliminasi pengaruh variabel *extraneous*, melakukannya tetap dianggap sebagai kecermatan dan kekuatan suatu desain penelitian (Price et al., 2017).

Alternatifnya, dalam melakukan penugasan acak, peneliti dapat mempertimbangkan agar variabel *extraneous* bernilai konstan pada setiap kondisi. Misalnya, apabila gender adalah variabel *extraneous*, maka peneliti dapat mengacak sambil memastikan bahwa proporsi (bukan jumlah) responden laki-laki dan perempuan sama di setiap kondisi. Contoh yang lain, apabila peneliti mendeteksi bahwa intelegensi merupakan variabel *extraneous*, maka peneliti dapat mengukur intelegensi responden terlebih dahulu (sebelum penugasan acak), kemudian mengacak sambil memastikan bahwa rerata skor intelegensi tidak berbeda pada masing-masing kondisi.

3.2.1.2 *Within-subjects design*

Seorang peneliti Psikologi Politik tertarik untuk mengetahui dampak kategorisasi sosial pada perilaku menolong. Peneliti tersebut membuat tiga rekaman *closed-circuit television* (CCTV) yang merekam kejadian kecelakaan dengan kronologi yang persis sama. Perbedaannya adalah kaus yang dikenakan oleh korban kecelakaan. Satu video CCTV menunjukkan korban kecelakaan yang mengenakan kaus peraga kampanye pasangan Joko Widodo-Ma'ruf Amin (video 1), video yang lain menampilkan korban yang memakai kaus peraga kampanye pasangan Prabowo Subianto-Sandiaga Uno (video 2), sedangkan video yang lain menampilkan korban yang mengenakan kaus dengan warna netral (hitam - video 3). Peneliti memperlihatkan ketiga video CCTV tersebut secara berurutan pada 100 responden yang melaporkan memilih Joko Widodo-Ma'ruf Amin pada pemilihan umum yang lalu. Peneliti memprediksikan bahwa intensi responden menolong korban kecelakaan akan menguat ketika melihat video 1, sedikit menurun setelah melihat pada video 3, dan paling rendah ketika melihat video 2.

Desain yang digunakan pada ilustrasi di atas berbeda dengan yang digunakan oleh Darley dan Latané karena responden penelitian mendapat lebih dari satu kali perlakuan. Dengan menggunakan desain *within-subjects*, peneliti memiliki kontrol yang lebih besar. Apabila responden memberikan reaksi yang berbeda ketika diberikan perlakuan yang berbeda pula, dampak variabel *extraneous* yang mungkin mengganggu penarikan kesimpulan dapat diminimalisasi sehingga validitas internal eksperimen lebih mudah dicapai. Menggunakan desain *within-subjects* juga memungkinkan prosedur analisis statistik yang mengecualikan peranan variabel *extraneous* ini dalam menjelaskan perubahan variabel dependen. Oleh karena itu, efek variabel independen dalam menyebabkan perubahan pada variabel dependen akan lebih mudah dideteksi (Price et al., 2017).

Ada beberapa potensi masalah yang harus dihadapi peneliti ketika memilih menggunakan desain *within-subjects* (Price et al., 2017). Karena diberikan beberapa perlakuan sekaligus, ada kemungkinan responden dapat 'menebak' hipotesis yang diuji oleh peneliti sehingga responden

berpeluang memberikan respon yang diharapkan oleh peneliti. Perubahan variabel dependen juga bisa jadi disebabkan oleh urutan pemberian perlakuan (*order effect*) bukan karena perlakuan itu sendiri. Risiko yang mungkin muncul selanjutnya adalah terjadinya *carry-over effect*, yaitu ketika pengukuran sebelumnya berdampak pada respon yang diberikan responden pada pengukuran berikutnya. Risiko lainnya yang mirip dengan *carry-over effect* adalah *practice effect*, yaitu ketika responden memberikan performa yang lebih baik ketika mengerjakan suatu tugas karena telah mendapatkan kesempatan berlatih dari mengerjakan tugas yang sebelumnya ia lakukan.

Persoalan berikutnya adalah *fatigue effect* yang terjadi ketika responden mengerjakan tugas dengan buruk karena kelelahan akibat harus mengerjakan banyak sekali tugas yang diberikan oleh eksperimenter. Selanjutnya, ada peluang responden merubah reaksi mereka ketika diberikan stimulus tertentu yang disebabkan oleh pengalaman mereka ketika diberikan perlakuan sebelumnya (*context effect*). Misalnya pada contoh di atas, responden yang sebelumnya melihat tayangan video 1 dan mengindikasikan intensi yang besar untuk menolong kemudian memberikan respon yang kurang lebih sama ketika diberikan video 2. Responden memberikan reaksi tersebut agar tidak terlihat terlalu partisan dan lebih toleran.

Solusi yang dapat dipertimbangkan untuk mengoreksi efek urutan (*order effect*) adalah dengan menerapkan teknik *counterbalancing* (Price et al., 2017; Shaughnessy et al., 2012). Cara terbaik melakukan *counterbalancing* adalah dengan menerapkan *complete counterbalancing*, yaitu dilakukan dengan prosedur: **pertama**, mendeteksi kombinasi urutan yang mungkin dari seluruh kondisi eksperimen, misalnya kalau menggunakan contoh di atas (tiga kondisi) maka ada enam urutan yang mungkin (123, 132, 213, 231, 312, 321). **Kedua**, peneliti membagi responden secara acak ke dalam sejumlah kelompok (mengikuti jumlah urutan yang mungkin) sehingga

seluruh urutan perlakuan dicobakan pada responden penelitian. Selain itu, setiap urutan perlakuan dicobakan pada responden dengan jumlah yang sama. Misalnya apabila peneliti merekrut 120 responden, maka masing-masing urutan akan diujikan pada 20 responden.

Complete counterbalancing masih mungkin dilakukan ketika penelitian memiliki jumlah perlakuan yang tidak terlalu banyak. Namun ketika peneliti memiliki banyak sekali perlakuan, maka untuk menerapkan *complete counterbalancing*, peneliti perlu merekrut responden dalam jumlah besar. Misalnya apabila peneliti ingin mencobakan 8 perlakuan, maka setidaknya ada 64 urutan (8x8) yang mungkin. Kalau masing-masing urutan diujikan pada 10 responden saja, maka peneliti membutuhkan setidaknya 640 responden. Untuk mengatasi masalah ini, peneliti dapat melakukan *random counterbalancing*, yaitu urutan perlakuan langsung ditentukan secara acak untuk setiap responden. Namun kerugiannya, sangat mungkin ada urutan perlakuan yang terlewat tidak diujikan. Teknik ini mungkin tidak seandal *complete counterbalancing* namun apabila peneliti mengantisipasi efek urutan yang tidak terlalu substansial atau desain eksperimen mengandung jumlah perlakuan/kondisi yang cukup banyak, maka opsi ini yang paling rasional untuk dilakukan (Price et al., 2017).

3.2.2 Pendekatan survei eksperimen

Beberapa tahun terakhir, desain yang menggabungkan kekuatan penelitian survei dan eksperimen cukup sering digunakan. Survei eksperimen adalah desain penelitian eksperimen yang dikombinasikan dengan desain survei *cross-sectional* dengan tujuan menguji hubungan kausalitas dan melakukan inferensi temuan penelitiannya pada populasi target yang lebih besar (Gaines, Kuklinski, & Quirk, 2007). Survei eksperimen disebut sebagai terobosan penting yang memungkinkan peneliti melakukan penelitian eksperimen dengan sampel yang representatif dalam skala nasional (Mullinix, Leeper, Druckman, & Freese, 2015). Dengan melakukan survei

eksperimen, temuan penelitian eksperimen murni, yang awalnya problematik ketika digeneralisasikan pada konteks di luar laboratorium, memiliki **validitas eksternal** yang lebih baik.

Berbagai perangkat lunak dan *platform* penyedia layanan kuesioner daring, sudah menyediakan fitur pengacakan dan menyertakan opsi penyertaan stimulus (dapat berupa visual, audio, bahkan multimedia) dan dapat dilakukan secara otomatis. Mengkustomisasi pengaturan kuesioner sesuai dengan kebutuhan peneliti - misalnya menambah perintah pengacakan dan *counterbalancing* juga semakin mudah dengan bantuan bahasa pemrograman yang sederhana. Merekrut responden dalam jumlah besar juga dapat dilakukan melalui *platform crowdsourcing*.

Dalam Ilmu Politik, pendekatan survei eksperimen sering juga digunakan untuk menyelidiki respon publik terhadap suatu kebijakan dan aktornya. Misalnya penelitian yang dilakukan oleh Isani dan Silverman (2016) menunjukkan bahwa masyarakat Amerika Serikat cenderung membentuk opininya atas suatu kebijakan luar negeri pemerintah Amerika Serikat tergantung dari latar belakang primordial tokoh asing yang menjadi target kebijakan tersebut. Responden penelitian cenderung menilai sangat negatif tokoh asing yang beragama Islam, dibandingkan dengan yang beragama Kristen. Ekspresi identitas politik yang sifatnya retorik (ucapan *Allahu Akbar*), berupa kebijakan (penerapan syariat Islam), dan label (Islam radikal) juga menghasilkan kekuatan sikap yang berbeda.

3.4 Penelitian meta (tinjauan sistematis dan meta-analisis)

Satu penelitian empirik lazimnya menggunakan jumlah sampel yang tak terlalu banyak sehingga punya keterbatasan daya generalisasi. Pembaca juga sering dibingungkan karena penelitian-penelitian yang menguji hipotesis yang sama, seringkali berakhir pada kesimpulan

yang saling bertolak belakang. Untuk mengetahui apa yang sebenarnya terjadi di populasi, peneliti sebaiknya tidak terlalu mengandalkan hanya satu hasil studi empirik, melainkan mempertimbangkan semua bukti, meskipun bukti-bukti tersebut seringkali bertentangan satu sama lain.

Untuk menjawab kebutuhan ini, peneliti metodologi mengusulkan model tinjauan sistematis atas temuan-temuan penelitian yang sudah ada (*research-on-research*) (Ioannidis, 2018). Penelitian meta (*meta-research*) bertujuan untuk melakukan sintesis atas akumulasi pengetahuan yang sudah tersedia dengan dua desain yang dapat dipilih, yaitu tinjauan sistematis (*systematic review*) (Khan, 2003) dan meta-analisis (Israel & Richter, 2011). Perbedaan yang menonjol dari penelitian meta dengan desain lain yang sebelumnya telah dijelaskan adalah unit analisisnya. Apabila dalam penelitian eksperimen dan survei unit analisis umumnya adalah individu, penelitian meta menggunakan hasil studi (artikel penelitian) sebagai sampel. Apabila di penelitian survei dan eksperimen jumlah sampel disimbolkan dengan n , maka simbol jumlah (artikel) sampel dalam penelitian meta disimbolkan dengan k .

Beberapa ahli sepakat menempatkan penelitian meta di puncak hirarki bukti saintifik karena mengandung bias yang paling kecil sekaligus kecermatan ilmiah yang paling tinggi (Ioannidis, 2018; Israel & Richter, 2011; Wampold, Ahn, & Kim, 2000).

5*	Tinjauan sistematis dan meta analisis	Setelah mempertimbangkan semua bukti dari studi yang menyelidiki efektivitas strategi <i>vote-buying</i> (politik uang) dalam meningkatkan jumlah suara yang diperoleh kandidat, disimpulkan bahwa strategi ini tidak efektif mendulang suara.	Bukti yang andal ..dan dapat digunakan secara terbatas pada konteks tertentu
5	Eksperimen murni (<i>randomized controlled experiments</i>)	Siswa SMA yang dipilih secara acak menerima perlakuan inokulasi akan menunjukkan resistensi terhadap berita bohong yang lebih tinggi dan lebih mampu bersikap kritis ketika membaca isi berita bohong, daripada siswa yang tidak menerima perlakuan inokulasi.	
4	Perbandingan kondisi sebelum-sesudah dengan melibatkan beberapa kelompok, penelitian longitudinal, dan <i>cohort studies</i>	Angka persepsi korupsi cenderung lebih rendah di berbagai kabupaten/kota yang menerapkan sistem <i>e-budgeting</i> , daripada kabupaten/kota yang tidak menerapkannya.	Temuan menjanjikan ..dan tentu saja amat penting untuk dikonfirmasi melalui studi lanjutan dengan metode yang lebih cermat
3	<i>Quasi-experiment</i> (perbandingan kondisi sebelum-sesudah) kemudian dibandingkan dengan satu kelompok yang lain	Angka kriminalitas menurun setelah perda Syariah disahkan di kota A, namun hal yang sama tidak terjadi di kabupaten B.	
2	Perbandingan <i>cross-sectional</i> antara kelompok <i>treatment</i> dengan kontrol, atau perbandingan kondisi sebelum dan sesudah diberi perlakuan	Pemilih yang lebih sering terpapar teori-teori konspirasi dan berita bohong akan lebih mungkin bersikap partisan sebagai pendukung salah satu kandidat calon Presiden.	Temuan menarik ..dan mungkin dapat diteliti lebih lanjut dengan metode yang lebih baik
1	Survei <i>cross-sectional</i> tanpa melibatkan perbandingan kelompok	Di Sumatera Barat, calon anggota legislatif dari partai Islam lebih mungkin terpilih daripada caleg dari partai nasionalis.	
0	Laporan penelitian internal yang bersifat komersial dan tidak melewati proses tinjauan sejawat	Hasil survei elektabilitas yang dikeluarkan oleh lembaga survei yang menyediakan jasa konsultan pemasaran politik.	Cenderung meragukan ..gunakan hanya ketika tidak ada bukti lain yang tersedia
0	Opini ahli, anekdot, dan studi kasus	Pendapat ahli dalam tulisan opini yang dimuat di media massa.	

Figure 5.: Hirarki Bukti Saintifik

Untuk memilih penelitian yang akan dianalisis, peneliti meta menggunakan prosedur penentuan sampel yang sistematis. Sebelum memilih sampel, peneliti wajib membuat protokol yang berisi kriteria, prosedur pemilihan sampel, dan pemeriksaan kualitas sampel. Panduan yang paling umum digunakan untuk membantu peneliti menghindari bias dalam pemilihan sampel adalah Preferred Reporting Items for Systematic Reviews and Meta-Analysis (PRISMA) (Moher et al., 2015).

Perbedaan tinjauan sistematis dengan meta-analisis terletak pada tingkat keandalan simpulan yang diperoleh. Meskipun sama-sama menggunakan sejumlah penelitian yang dipilih melalui prosedur yang sistematis, meta-analisis melibatkan analisis statistik yang dapat menghasilkan agregat ukuran efek (*pooled effect size*) dari seluruh *k* yang dianalisis. Di sisi lain, proses analisis data pada tinjauan sistematis murni mengandalkan interpretasi peneliti.

Misalnya, apabila seorang peneliti tertarik melakukan meta-analisis mengenai korelasi antara kepuasan pemilih dengan tingkat elektabilitas, maka peneliti dapat mengumpulkan semua penelitian yang menyelidiki korelasi antara kedua variabel tersebut, lalu melakukan analisis statistik yang menghasilkan agregat dari seluruh koefisien korelasi di sampel yang dianalisis. Dalam penelitian korelasional, ukuran efek dapat dikenali dari koefisien korelasi yang dilaporkan. Namun persoalannya, penelitian yang dijadikan sampel dilakukan di konteks yang berbeda dan menggunakan kelompok sampel dengan karakteristik yang berbeda pula. Pertanyaannya, apakah prosedur ini mungkin dilakukan?

Dengan melakukan meta-analisis, peneliti dapat melakukan prosedur statistik yang dapat memperkirakan derajat heterogenitas ukuran efek yang dianalisis. Idealnya dan secara teoritik, ukuran efek seharusnya homogen sehingga dapat langsung dibandingkan antar-penelitian, tetapi yang sering terjadi justru kebalikannya. Apabila variasi ukuran efek dari sampel penelitian yang dipilih terlalu heterogen sehingga sulit diagregat, maka peneliti dapat melakukan *meta-regression* (Borenstein, Hedges, Higgins, & Rothstein, 2009) untuk mencari tahu variabel yang menyebabkan ukuran efek menjadi bervariasi. Misalnya pada contoh yang disebutkan sebelumnya, peneliti meta dapat melakukan *meta-regression* untuk mengetahui apakah usia responden, perbandingan jumlah responden yang laki-laki dengan yang perempuan, dan domisili responden (urban/rural) untuk menyelidiki mengapa korelasi antara kepuasan pemilih dengan tingkat elektabilitas bervariasi antar-penelitian.

Meta-analisis umumnya lazim digunakan oleh peneliti di bidang kesehatan untuk mengumpulkan bukti uji klinis mengenai keampuhan suatu tindakan medis, obat, atau akurasi teknik diagnosis tertentu, dan sering dijadikan prosedur standar dalam praktik pengobatan berbasis bukti (*evidence-based medicine*) (Zlowodzki, Poolman, Kerkhoffs, Tornetta, &

Bhandari, 2007). Justru pada awalnya, meta-analisis merupakan teknik yang diperkenalkan oleh Gene V. Glass, seorang Psikoterapis, yang berupaya untuk mengumpulkan bukti mengenai efektivitas Psikoterapi (Wampold et al., 2000). Namun saat ini, peneliti Psikologi Politik juga seringkali menggunakan teknik yang sama, untuk melakukan sintesis atas temuan penelitian yang sudah ada.

Umumnya diyakini bahwa dampak berita palsu dapat dikoreksi dengan melakukan cek fakta (*debunking*), namun penelitian meta-analisis yang dilakukan Chan, dkk. (2017) pada 52 penelitian sebelumnya menunjukkan hal yang sebaliknya. Individu umumnya akan semakin keras menolak mengubah keyakinannya, meskipun telah ditunjukkan bahwa keyakinannya keliru melalui cek fakta. Penolakan ini semakin kuat ketika individu mampu menemukan alasan yang mendukung keyakinannya yang keliru tersebut. Yang menarik, penelitian yang sama menunjukkan bahwa semakin detail cek fakta yang dipaparkan kepada orang yang mempercayai berita palsu, justru akan menguatkan (bukannya melemahkan) keyakinan mereka yang keliru tersebut.

Meta-analisis lainnya yang cukup menarik adalah penelitian (2019) yang menyelidiki 115 penelitian mengenai *extended contact hypothesis* selama kurun waktu 20 tahun terakhir. *Extended contact hypothesis* prinsipnya sedikit berbeda dengan *contact hypothesis*, yaitu mengasumsikan bahwa sikap positif dan toleransi pada anggota kelompok sosial lain dapat ditumbuhkan tidak harus dengan menjalin relasi langsung antara individu dengan anggota kelompok sosial lain. Efek yang sama dapat ditimbulkan dengan sekedar mengetahui bahwa ada persahabatan yang dijalin oleh anggota kelompoknya dengan anggota kelompok sosial yang lain. Hasil meta-analisis menunjukkan bahwa korelasi antara *extended contact* dengan *intergroup attitudes* berkisar antara kecil sampai sedang, dan semakin mengecil ketika mengecualikan efek pertemanan langsung.

Temuan ini menunjukkan bahwa *direct contact* memberikan dampak yang lebih besar dalam menimbulkan toleransi daripada *extended contact*.

Meskipun memberikan bukti yang cenderung lebih andal daripada metode lainnya, meta-analisis bukanlah metode yang bebas dari masalah. Persoalan yang paling sulit diselesaikan dan berdampak besar pada kredibilitas temuan meta-analisis adalah bias publikasi, yang akan lebih lanjut dijelaskan di bagian berikutnya.

3.5 Penyimpulan karakter tokoh politik dengan pendekatan *at a distance*

Peneliti yang tertarik menginvestigasi kondisi psikologis, bahkan kepribadian dan kondisi kesehatan mental seorang tokoh politik, perlu mengembangkan strategi asesmen yang inovatif karena akses langsung yang memungkinkan pengumpulan data primer tidak mudah didapatkan. Akhirnya, peneliti mengandalkan data-data yang tersedia di media massa atau di ruang publik lainnya untuk kemudian dianalisis dengan pendekatan *at a distance* (Schafer, 2000).

Salah satu contoh yang paling menarik adalah kasus pemilihan Presiden Amerika Serikat pada tahun 1964 yang melibatkan dua kandidat, yaitu Barry Goldwater dari partai Republik dan Lyndon Johnson dari partai Demokrat. Pada masa kampanye, majalah *Fact* menerbitkan sebuah artikel provokatif yang berjudul, “1.189 Psikiater menyatakan bahwa Goldwater, secara psikologis, tidak mumpuni menjadi Presiden!” Substansi artikel tersebut ditulis berdasarkan hasil survei pada sejumlah Psikiater, yang pertanyaannya mencakup stabilitas emosi dan kemampuan memimpin kedua kandidat. Celakanya, hasil “riset” tersebut dimanfaatkan oleh rivalnya yang kemudian memenangkan pemilihan umum, untuk melancarkan sebuah iklan kampanye negatif yang sangat merugikan pihak Goldwater. Tim pemenangan Goldwater mengajukan dan kemudian memenangkan gugatan hukum atas majalah *Fact*, lalu diikuti keluarnya pengumuman dari

American Psychiatric Association (APA) yang melarang Psikiater untuk memberikan diagnosis atau evaluasi psikologis seorang tokoh publik tanpa pemeriksaan langsung ataupun persetujuan dari tokoh yang dimaksud. Larangan ini dikenal sebagai *Goldwater rule* (Davis, 2017; McNally, 2018).

Usai pemilihan umum yang brutal tersebut, *Goldwater rule* sempat sementara dilupakan publik Amerika Serikat, namun kembali muncul dan kembali menuai kontroversi ketika pemilihan Presiden Amerika Serikat pada tahun 2016 yang lalu. Donald Trump, kandidat Presiden dari partai Republik menunjukkan serangkaian perilaku yang sangat tidak biasa, berbahaya, dan menurut beberapa Psikolog sudah mengarah pada diagnosis gangguan kepribadian narsistik (Lilienfeld, Miller, & Lynam, 2018). Meskipun begitu, para Psikiater memilih untuk menghindari memberikan komentar karena terikat *Goldwater rule*. Namun yang sesungguhnya terjadi, para Psikiater dan Psikolog sebenarnya tidak satu suara ketika dimintai pendapat tentang etis tidaknya metode *at a distance*.

Sebagian Psikolog mengkritik “kekolotan” para Psikiater dan menekankan bahwa mengedukasi pemilih mengenai buruknya kondisi psikologis Donald Trump, akan menyelamatkan publik dari bahaya yang mungkin timbul akibat kebijakan-kebijakan yang diambil Trump, kalau ia benar-benar menjadi Presiden. Karena lebih besarnya kepentingan publik yang harus diselamatkan, Lilienfeld, dkk. (Lilienfeld et al., 2018) menyebutkan *Goldwater rule* sudah tidak relevan lagi di masa kini. Lilienfeld, dkk. (2018) juga menekankan bahwa meskipun American Psychological Association (APA) memperingatkan Psikolog untuk ekstra hati-hati ketika memberikan opini profesional di depan publik, Psikolog tidak terikat pada *Goldwater rule* sehingga memiliki “kewajiban moral” untuk melakukan edukasi kepada pemilih.

Alasan tidak adanya persetujuan (*informed consent*) dari tokoh publik yang dianalisis juga dipandang bukan persoalan besar karena metode *at a distance* bukan diagnosis formal yang dihasilkan dari suatu pemeriksaan medis, melainkan sekadar komentar atau opini profesional. Selain itu, data yang digunakan untuk menyusun profil psikologis seorang tokoh publik merupakan data yang tersedia di media massa dan ruang publik lainnya, bukan informasi primer yang diperoleh dari relasi Psikolog/Terapis dengan klien dalam sesi terapi atau konseling sehingga tidak ada etika hubungan profesional (*confidentiality*) yang dilanggar (Lilienfeld et al., 2018).

Persoalannya, masyarakat awam yang menjadi target edukasi tidak benar-benar memahami perbedaan antara diagnosis dengan opini profesional sehingga di luar konteks etika, ada pertanyaan besar mengenai apakah informasi yang diperoleh dari metode *at a distance* akan berguna bagi pemilih untuk membuat keputusan yang rasional. Lilienfeld, dkk. (2018) juga tidak menafikkan kemungkinan bahwa peneliti yang partisan akan menggunakan metode *at a distance* dengan motivasi mendiskreditkan kandidat yang tidak disukainya, lebih-lebih ketika dilakukan di masa kampanye. Kritik yang dilontarkan oleh McNally (2018) pada Lilienfeld, dkk. (2018) amat tajam, yaitu ia menyebutkan bahwa menggunakan metode *at a distance* untuk mengedukasi publik mengenai status mental seorang kandidat yang berlaga dalam pemilihan umum justru tindakan yang tidak perlu, tidak efektif, dan kontraproduktif karena sesungguhnya publik bukanlah pihak yang diuntungkan.

McNally (2018) menyebutkan bahwa dengan menggunakan akal sehat saja, rekam jejak dan riwayat perilaku Trump sudah lebih dari cukup untuk meyakinkan masyarakat agar tidak memilihnya. Namun pendukung garis keras Trump mengabaikan fakta ini sehingga kecil kemungkinannya opini profesional dari Psikolog atau Psikiater akan mengubah keputusan

mereka. Justru sebaliknya, ada potensi bahwa opini profesional mengenai status mental Trump justru akan memancing kemarahan dan membuat pendukungnya semakin partisan. Antusiasme pendukung Trump sesungguhnya akan dengan sendirinya memudar ketika ia gagal mewujudkan janji-janji kampanyenya dalam kebijakan yang ia rumuskan selama menjabat.

Meskipun ada banyak kontroversi, ketika metode ini diarahkan untuk mendeskripsikan karakter tokoh publik dalam kerangka preferensi kebijakan yang dipilihnya, sebenarnya akan memberikan informasi yang bermanfaat bagi publik. Para ahli yang berkumpul di Simposium *Issues in Assessing Psychological Characteristics at a Distance* pada konferensi tahunan International Studies Association pada tahun 1998 menghasilkan *The Operational Code* (Schafer, 2000) yang merupakan panduan yang dapat digunakan Psikolog Politik untuk mengevaluasi pandangan umum (*worldview*) seorang pemimpin politik yang diukur dari kebijakan luar dan dalam negeri yang dipilihnya. Asumsinya, metode ini seharusnya dilakukan pada pemimpin politik yang sedang menjabat (dengan begitu memiliki kewenangan untuk membuat kebijakan) dan tidak dilakukan pada masa kampanye. Dengan lebih banyak berfokus pada kebijakan, bukan status mental atau *trait* yang sifatnya amat subjektif, fungsi edukasi publik akan lebih mudah dicapai dan peneliti yang melakukannya tidak perlu menghadapi dilema etis.

Di Indonesia, metode *at a distance* pernah dilakukan dan juga menimbulkan pro-kontra. Namun sampai saat ini, belum ada kesepakatan yang jelas dan mengikat mengenai apakah memberikan opini profesional mengenai status mental seorang kandidat Presiden, utamanya ketika masa kampanye, adalah tindakan yang etis untuk dilakukan.

(Catatan: pembaca dapat membaca lebih lanjut mengenai kontroversi metode ini di

[Buletin Psikologi Indonesia edisi pertama \(2019\)](#))

3.6 Pendekatan interpretif (kualitatif), pengukuran implisit, dan pemrosesan teks

Penelitian-penelitian di Ilmu Politik banyak dilakukan dengan menggunakan **paradigma interpretif** yang mengandalkan kekuatan dan kekayaan narasi, analisis historis dan konseptual, bukan mengandalkan metode kuantitatif dan statistik. Meskipun paradigma yang sama agak jarang digunakan oleh peneliti Psikologi Politik, penelitian dengan pendekatan interpretif berpotensi dapat menghasilkan *insight* penting, yang melengkapi temuan-temuan dengan pendekatan kuantitatif.

Ada banyak sekali opsi desain penelitian dengan paradigma interpretif yang dapat digunakan oleh peneliti, mulai dari studi kasus (Kaarbo & Beasley, 1999), fenomenologi (Giorgi, 2012), analisis diskursus dan *conversational analysis* (Hammack & Pilecki, 2014), *content analysis* (Erişen, Erişen, & Özkeçeci-Taner, 2013), dan *grounded theory*. Penelitian kualitatif juga dapat dikombinasikan dengan pendekatan kuantitatif sebagai *mixed-method research*, meskipun ada banyak kritik yang menyebutkan pendekatan *mixed-methods* sebagai desain yang tidak praktis dilakukan, mengingat jenis data dan proses yang dilakukan untuk memperoleh data sangat berbeda antara pendekatan kuantitatif dan kualitatif (Symonds & Gorard, 2010).

Berikut adalah beberapa contoh penelitian di Psikologi Politik yang menggunakan pendekatan interpretif dan *mixed-methods*. Penelitian yang dilakukan oleh Hendry, dkk. (2007) yang menggunakan pendekatan *grounded theory* memberikan penjelasan yang menarik mengenai bagaimana remaja di Wales membentuk identitas kultural mereka dan utamanya menyelidiki penghayatan menjadi mayoritas/minoritas dapat menjelaskan proses pembentukan identitas ini. Penelitian McAdams, dkk. (McAdams et al., 2008) menggunakan desain *mixed-methods* untuk menyelidiki strategi orang-orang liberal dan konservatif di Amerika Serikat dalam menyimbolkan ideologi politik dan keyakinan moral mereka dengan menggunakan metafor keluarga.

Selain pendekatan interpretif, beberapa penelitian Psikologi Politik menggunakan **pengukuran sikap implisit**, utamanya dalam studi-studi *implicit political cognition* (Stone et al., 2014). Untuk topik-topik riset yang cenderung sensitif, seperti prasangka pada kelompok sosial tertentu, yang berpotensi menghasilkan respon yang *socially desirable*, pengukuran implisit dengan menggunakan *implicit association test* (IAT) amat populer digunakan. Komponen kunci dari IAT adalah waktu reaksi (*reaction time*) karena IAT berfungsi untuk mengungkap sikap tersembunyi yang sifatnya tak sadar (Jost, 2019). Meskipun sering dipertanyakan korespondensinya pada perilaku pemilih dalam konteks yang riil, IAT sering digunakan untuk mendeteksi efek bias rasial dalam menentukan keputusan memilih kandidat tertentu dalam pemilihan umum. Oleh karena itu, beberapa peneliti menyimpulkan bahwa IAT memberikan informasi yang berguna dalam memprediksi hasil pemilihan umum (Gawronski, Galdi, & Arcuri, 2015).

Metode penelitian yang terakhir adalah **pemrosesan teks otomatis** (*automated text processing*). Metode ini merupakan hasil interaksi berbagai disiplin ilmu, yaitu Ilmu Komputer, Linguistik, dan Psikologi. Unit analisis metode ini bukan individu, melainkan teks. Metode ini sangat berguna ketika diaplikasikan untuk menganalisis preferensi kebijakan, sentimen dalam orasi politik, bahkan kepribadian tokoh politik. Metode ini sedang berkembang pesat dan juga mulai sering digunakan untuk mengumpulkan informasi mengenai perilaku pemilih, berdasarkan unggahan dan komentar mereka di media sosial (Schoonvelde, Schumacher, & Bakker, 2019). Sub-disiplin Ilmu Komputer dan Kecerdasan Buatan, *Natural Language Processing* (NLP) yang umumnya digunakan untuk mengembangkan teknologi *speech recognition*, juga sangat membantu peneliti Psikologi Politik dalam melakukan analisis pada komponen teks yang awalnya tak mampu dilakukan oleh mesin, seperti komponen afektif (dengan analisis sentimen) sampai ekspresi emosi yang lebih spesifik.

Penelitian yang dilakukan oleh Rheault, dkk. (2016) pada transkrip digital seluruh debat di Parlemen Inggris selama kurang lebih 100 tahun menemukan bukti menarik, yaitu respon emosi yang ditunjukkan oleh anggota Parlemen Inggris selama berdebat ternyata berkaitan dengan kondisi resesi ekonomi. Menggunakan metode yang sama, penelitian yang dilakukan oleh Parackal, dkk. (2018) pada 858 responden di New Zealand menunjukkan nilai-nilai yang diyakini pemilih, yang dieksplorasi melalui jawaban partisipan atas beberapa pertanyaan terbuka yang diajukan peneliti, dapat memprediksi dengan baik keputusan memilih, bahkan lebih jauh lagi, dapat memberikan prediksi mengenai hasil pemilihan umum.

4. Pengujian hipotesis

Dalam melakukan pengujian hipotesis, peneliti masih dihadapkan oleh masalah akurasi prediksi diluar yang sudah dijelaskan sebelumnya dalam bab ini, yaitu **kesalahan inferensi** dan *bias-variance tradeoff* (Singh, 2018). Prediksi yang diperoleh melalui model statistik akan semakin akurat apabila bias dalam desain penelitian dan proses *sampling*, serta variabilitas (atau varians) data dalam kelompok sampel ditekan hingga ke level yang paling minimal. Namun kenyataannya, varians dan bias adalah dua hal yang harus *tradeoff*, yaitu ketika peneliti meminimalisasi bias, maka varians akan meningkat, dan begitu pula sebaliknya.

Seorang peneliti melakukan survei *cross-sectional* yang tujuannya untuk menyelidiki determinan yang dapat menjelaskan partisipasi politik. Untuk itu, ia perlu mengidentifikasi variabel prediktor (independen) yang akan diuji keterkaitannya dengan tingkat partisipasi politik. Apabila ia hanya meneliti satu-dua variabel independen, maka model statistik yang ia gunakan untuk menganalisis data akan terkontaminasi bias yang tinggi, namun memiliki varians yang rendah. Dengan begitu, besar kemungkinannya ia memiliki model yang *underfitting*, yaitu ketika model tersebut tak mampu mendeteksi efek prediktor dalam menjelaskan variabel dependen yang ada pada data.

Namun apabila ia memasukkan banyak sekali prediktor dalam modelnya, maka yang terjadi sebaliknya. Modelnya akan mengandung bias yang kecil, namun varians menjadi sangat tinggi sehingga model akan *overfitting*. Peneliti mungkin akan mendapati model yang “sempurna” dalam mendeteksi efek prediktor dalam menjelaskan variabel dependen yang ada pada data, namun pola yang sama tidak akan dideteksi ketika penelitian dicoba-ulang (replikasi) pada kelompok sampel yang berbeda.

4.1 Kesalahan penarikan kesimpulan dalam paradigma *null hypothesis significant testing* (NHST)

Paradigma statistik yang paling luas digunakan peneliti untuk melakukan pengujian hipotesis adalah paradigma *null hypothesis significant testing* (NHST). Hipotesis yang diuji dengan pendekatan ini adalah **hipotesis nol (H_0)** yang menyatakan bahwa **variabel independen tidak mempengaruhi, tidak berefek, tidak berdampak, atau tidak berkorelasi dengan variabel dependen**. Pendekatan NHST selalu dimulai dengan asumsi bahwa H_0 secara *default* adalah benar (Shaughnessy et al., 2012) dan tugas peneliti adalah mencari bukti untuk menggugurkan (atau menolak/memfalsifikasi) H_0 . Selanjutnya, dengan memanfaatkan teori probabilitas, peneliti dapat menentukan seberapa besar peluangnya bahwa efek variabel dependen, perbedaan antara dua kelompok, atau korelasi antar dua variabel yang berhasil ditemukan peneliti, dapat dijadikan bukti untuk **menolak H_0** atau efek tersebut muncul secara kebetulan saja.

Apabila suatu temuan dikatakan **signifikan secara statistik**, maka peneliti dapat menyimpulkan bahwa **temuan tersebut kecil kemungkinannya terjadi seandainya H_0 benar** sehingga **mungkin** peneliti dapat menolak H_0 . Untuk menyatakan apakah temuannya signifikan secara statistik, peneliti bergantung pada **taraf signifikansi** (nilai *p/p-value*) yang kemudian dibandingkan dengan nilai α (yang umumnya ditetapkan sebesar 0.05). Apabila nilai **p lebih**

kecil daripada α , maka temuan dikatakan signifikan. Sebaliknya apabila nilainya **lebih besar** dari α , maka temuan tersebut tidak signifikan.

Nilai p mungkin adalah konsep yang paling sering disalahpahami sebagai **batas antara ada dengan tiadanya** bukti. Temuan penelitian yang tidak signifikan sering diartikan sebagai bukti bahwa tidak ada efek variabel independen, tidak ada perbedaan antar dua kelompok, dan tidak adanya korelasi antar dua variabel. Padahal..

..apabila peneliti tidak menemukan bukti adanya sesuatu, bukan berarti eksistensinya menjadi nihil (*the absence of evidence is not the evidence of absence*).. (Alderson, 2004)

Yang tak banyak disadari penggunaannya, NHST mengasumsikan bahwa **H_0 tidak dapat dibuktikan atau diterima**, meskipun secara *default* H_0 diasumsikan benar (Greenland et al., 2016; Perezgonzalez, 2015). Oleh karena itu, apabila suatu temuan penelitian ditemukan tidak signifikan, maka peneliti seharusnya melaporkan bahwa ia **gagal menolak/menggugurkan H_0** , bukannya menyimpulkan bahwa H_0 adalah benar. Misinterpretasi yang juga sering muncul adalah asumsi bahwa nilai p merupakan peluang yang melekat pada penelitian yang sedang dilakukan. Padahal, nilai p adalah peluang yang sifatnya jangka panjang, yaitu ketika penelitian diulang pada kelompok sampel yang berbeda di masa depan (Greenland et al., 2016).

Marimar meyakini bahwa banyaknya uang di dalam amplop “serangan fajar” tidak berdampak apapun pada keputusan memilih. Untuk menguji asumsinya tersebut, ia membandingkan intensi memilih seorang calon anggota legislatif pada sekelompok responden, yang ditentukan secara acak, menerima sejumlah uang dengan yang tidak menerima uang. Namun setelah melakukan serangkaian pengujian, ternyata kelompok responden yang menerima uang melaporkan intensi yang lebih tinggi untuk memilih caleg tersebut ketika dibandingkan dengan responden yang tidak menerima. Nilai p diketahui sebesar 0.001 (dengan $\alpha=0.05$). Maka nilai $p=0.001$ disini artinya adalah...

..apabila (a) Marimar mengulang percobaannya pada kelompok sampel (responden) yang berbeda atau (b) ada peneliti lain yang melakukan percobaan yang sama pada kelompok sampel yang juga berbeda di masa depan, maka **peluang** Marimar dan peneliti tersebut mendeteksi adanya perbedaan intensi memilih tersebut amatlah kecil (0.1%), kalau seandainya benar bahwa pemberian uang tidak berdampak apapun.

Statistisi telah lama *mewanti-wanti* obsesi peneliti yang berlebihan dalam mendapatkan nilai p yang lebih kecil daripada α , bahkan mendapatkan hasil yang tidak signifikan diartikan sebagai kegagalan besar. Padahal yang seharusnya dicari oleh peneliti adalah **ukuran efek** (*effect size*). Peneliti terlalu terfokus mencari **signifikan/tidaknya efek** bukan **besarnya efek** itu sendiri. Apabila peneliti mencari perbedaan antara dua kelompok, maka kesimpulan yang ditarik seharusnya tidak berhenti pada apakah perbedaannya signifikan atau tidak, tetapi justru pada **seberapa besar perbedaannya** (Simonsohn, Nelson, & Simmons, 2014). Sebelum krisis kredibilitas (yang akan dijelaskan pada bagian selanjutnya), peneliti terbiasa mengabaikan ukuran efek sehingga tidak melaporkannya secara eksplisit dalam laporan penelitian. Namun saat ini melaporkan ukuran efek adalah praktik standar yang disyaratkan oleh banyak *outlet* publikasi (Appelbaum et al., 2018). Melaporkan ukuran efek juga sangat membantu peneliti meta untuk melakukan agregasi ukuran efek pada beberapa penelitian sekaligus.

Ukuran efek (*effect size*) adalah unit yang menunjukkan besarnya pengaruh variabel independen, besarnya korelasi antar dua variabel, atau besarnya perbedaan antar kelompok, yang secara teoritik dapat dibandingkan antar studi dan penghitungannya tergantung pada analisis yang digunakan. Untuk analisis korelasional, ukuran efek ditunjukkan oleh koefisien korelasi (r), sedangkan penelitian yang membandingkan perbedaan dua kelompok salah satunya dapat menggunakan Cohen's d (Cohen, 1994). Pada penelitian yang menggunakan regresi linear, untuk level model sumbangan relatif (R^2) adalah indikator ukuran efek, sedangkan di level prediktor ukuran efek ditunjukkan oleh koefisien model (*slope/unstandardised β*). Kalau peneliti

menggunakan analisis varians (ANOVA) untuk membandingkan beberapa kelompok atau kondisi sekaligus, maka peneliti dapat menggunakan η^2 atau ω^2 (Kelley & Preacher, 2012).

Yang menarik, nilai p sangat sensitif dengan jumlah sampel (Panagiotakos, 2008). Apabila jumlah sampel semakin kecil, maka nilai p akan cenderung besar (tidak signifikan) meskipun ukuran efek yang ditemukan besar. Namun pada jumlah sampel yang besar, nilai p akan cenderung kecil (signifikan) meskipun ukuran efek yang dideteksi amat kecil. Oleh karena itu...

Pada sampel besar, *everything is significant*, namun pada sampel kecil *nothing is significant*

Dalam menyimpulkan ada tidaknya efek, ada dua kesalahan yang mungkin dilakukan peneliti sehingga harus dikendalikan ketika mendesain dan menganalisis data penelitian. Untuk memahami kesalahan inferensi (penarikan kesimpulan), perhatikan *confusion matrix* di bawah ini. Yang perlu diperhatikan, **bagian kolom** adalah **prediksi** yang dilakukan peneliti, sedangkan **bagian baris** merupakan **kondisi yang sesungguhnya terjadi** di populasi.

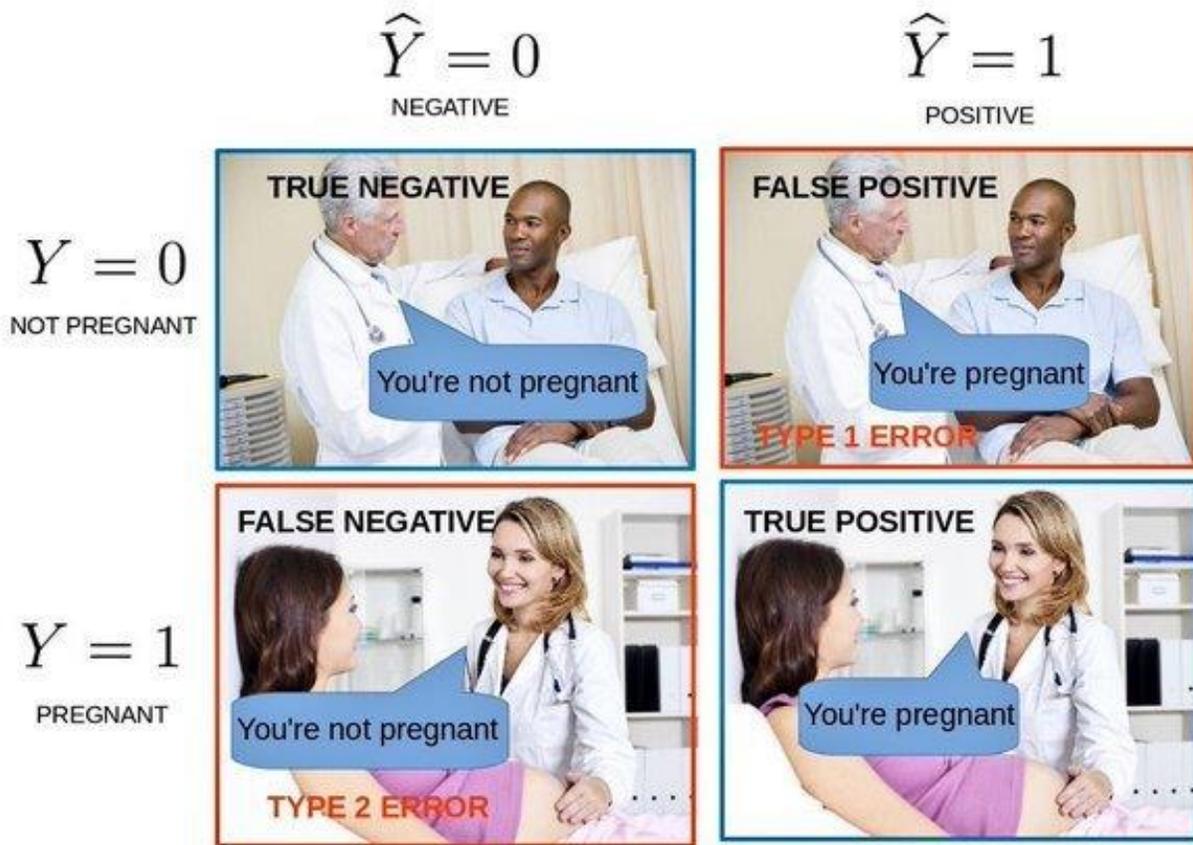


Figure 6.: Kesalahan dalam Penarikan Kesimpulan (Inferensi). Sumber:

<https://dzone.com/articles/understanding-the-confusion-matrix>

Prinsipnya, ada dua jenis kesalahan inferensi, yaitu:

1. Kesalahan tipe 1 (*type 1 error*), yaitu ketika peneliti menyimpulkan **ada** efek (ada korelasi, pengaruh, atau perbedaan), **padahal sebenarnya tidak ada**. Kesalahan ini juga disebut *false positive* (*false alarm*). Pada gambar di atas, *false positive* terjadi ketika dokter menyatakan bahwa seorang laki-laki positif hamil. **Peluang terjadinya kesalahan tipe 1** disimbolkan dengan α .
2. Kesalahan tipe 2 (*type 2 error*), yaitu ketika peneliti menyimpulkan **tidak ada** efek (tidak ada korelasi, pengaruh, atau perbedaan), **padahal sebenarnya ada**. Kesalahan ini juga

disebut *false negative*. Pada gambar di atas, *false negative* terjadi ketika dokter menihilkan kehamilan seorang ibu yang jelas-jelas sedang hamil tua. **Peluang terjadinya kesalahan tipe 2** disimbolkan dengan β .

Mari kita fokus pada kesalahan tipe dua. Apabila β adalah peluang peneliti gagal mendeteksi efek padahal efek tersebut ada, maka $1-\beta$ adalah **peluang peneliti mendeteksi adanya efek, kalau efek tersebut betul-betul ada**. Peluang ini ($1-\beta$) disebut juga sebagai **statistical power** (Cohen, 1992). Karena sibuk mengendalikan peluang terjadinya kesalahan tipe 1 (α), peneliti abai pada sesuatu yang lebih penting, yaitu memperbesar *statistical power*. Bukankah kalau peneliti ingin mendeteksi adanya efek, tentu memiliki peluang yang besar untuk mendeteksi efek tersebut (kalau efek tersebut benar-benar ada) adalah sesuatu yang diinginkan?

Statistical power adalah fungsi dari desain penelitian yang digunakan, jumlah sampel, dan ukuran efek. Desain eksperimen *within-subjects*, misalnya, memiliki *power* yang lebih baik daripada *between-group*. Ukuran efek yang besar tentu membuat peluangnya untuk ‘ditemukan’ oleh peneliti menjadi lebih besar. Yang menarik, semakin besar jumlah sampel, peluang peneliti untuk menemukan efek tersebut juga meningkat.

Bayangkan anda berada di sebuah ruang kelas dan sedang mencari dua objek, yaitu seekor kucing dan sebuah jarum. Kucing akan lebih mudah ditemukan daripada jarum karena ukurannya lebih besar (sehingga lebih mudah terlihat), namun jarum yang ukurannya kecil lebih sulit ditemukan. Untuk memperbesar peluang jarum ditemukan, maka anda harus memanggil beberapa teman anda untuk membantu anda mencari jarum tersebut. Oleh karena itu, peluang ditemukannya jarum tersebut akan meningkat dengan bertambahnya jumlah orang yang membantu anda.

Analogi diatas dapat menjelaskan hubungan antara *jumlah sampel*, *ukuran efek*, dan *statistical power* dengan sederhana, sekaligus menjawab pertanyaan klasik yang sering diajukan

peneliti, “berapa banyak jumlah responden yang saya butuhkan untuk direkrut dalam penelitian ini?”

Jawabannya sederhana, tergantung seberapa besar efek yang diasumsikan peneliti akan dideteksi dan seberapa besar peluang menemukannya. Dengan menggunakan konsep *statistical power*, peneliti dapat merencanakan jumlah sampel sebelum melakukan pengambilan data dengan teknik *a priori power analysis* (Dorey, 2011). Beberapa pilihan perangkat lunak yang dapat digunakan untuk melakukan teknik ini adalah **G*Power** (Mayr, Buchner, Erdfelder, & Faul, 2007), R (dengan menggunakan *package pwr*), atau **jamovi** (dengan memasang *module* tambahan, yaitu *jpwr*).

Yang mengejutkan, peneliti Psikologi terus menerus mengabaikan *statistical power* padahal Jacob Cohen (1988) sudah menyampaikan kegelisahannya sejak tahun 1980an. Dari hasil pengamatannya, Cohen memperkirakan bahwa rata-rata *statistical power* penelitian-penelitian Psikologi hanya sekitar 50 persen, yang artinya peluang peneliti untuk menemukan efek hanya 50% saja. Beberapa dasawarsa kemudian estimasi rerata *statistical power* pada penelitian Psikologi yang dilakukan oleh Vankov, dkk. (2014) tidak banyak berubah, yaitu masih sekitar 50-60 persen. Yang ganjil, setelah dilakukan analisis pada penelitian-penelitian yang diterbitkan di jurnal-jurnal ternama, proporsi penelitian di Psikologi dan Psikiatri yang mengklaim “menemukan efek” sangat tinggi, nyaris mencapai 90 persen (Fanelli, 2012). Ini sama sekali tidak masuk akal. Bagaimana mungkin hasil positif jumlahnya demikian banyak dipublikasikan, sedangkan rerata *power* diprediksikan hanya sekitar 50-60 persen. Kemana perginya hasil-hasil negatif?

Rendahnya *statistical power* pada studi-studi Psikologi sekaligus menandai problem yang amat serius: dapatkah temuan penelitian dan teori-teori Psikologi dipercaya?

5. Isu-isu etika dalam penelitian Psikologi Politik

Penelitian Psikologi umumnya menggunakan manusia sebagai subjek yang dipelajari sehingga peneliti memiliki kewajiban untuk menjamin bahwa partisipasi responden dalam penelitian yang dilakukan tidak mengancam atau membahayakan kesejahteraan, baik diri peneliti sendiri, responden penelitian, bahkan masyarakat secara luas. Di Indonesia, hasil konsensus yang digunakan sebagai pedoman praktik baik meneliti adalah Kode Etik Psikologi Indonesia (HIMPSSI, 2010) yang dikeluarkan oleh Himpunan Psikologi Indonesia. Beberapa isu penting akan dikombinasikan dengan The Belmont Report (Morling, 2018) yang mengandung beberapa prinsip etik yang harus dijamin oleh peneliti.

5.1 Prinsip menghormati individu (*respect for person*)

Dalam The Belmont Report disebutkan bahwa peneliti wajib menghormati individu yang melibatkan dua aspek penting. **Yang pertama**, individu harus diperlakukan sebagai entitas yang otonom sehingga mereka harus diberikan kebebasan untuk memutuskan partisipasi mereka dalam penelitian. Berdasarkan prinsip ini, maka seluruh partisipasi, termasuk mengisi kuesioner yang tanpa menanyakan identitas pribadi (anonim), wajib mendapatkan **persetujuan atas tindakan atau partisipasi** (*informed consent*) dari responden. Setelah responden diberi informasi yang cukup mengenai riset yang sedang dilakukan, risiko yang mungkin terjadi, serta keuntungan yang mungkin didapatkan dari partisipasi, mereka harus diberi kesempatan untuk memutuskan secara mandiri untuk berpartisipasi atau tidak.

Dalam Kode Etik Psikologi Indonesia disebutkan bahwa *informed consent* sedikitnya mengandung informasi berikut ini:

1. Tujuan penelitian

2. Jangka waktu dan prosedur partisipasi
3. Bentuk partisipasi yang diminta dari responden, termasuk risiko, ketidaknyamanan, dan keuntungan yang mungkin diperoleh responden dari partisipasi tersebut
4. Responden diberi hak untuk menarik diri atau membatalkan partisipasi, ketika partisipasi sudah dimulai termasuk konsekuensi yang mungkin timbul ketika responden membatalkan partisipasi
5. Bagaimana peneliti menjamin kerahasiaan identitas responden (anonimitas)
6. Penghargaan (termasuk upah) yang diterima responden setelah berpartisipasi
7. Narahubung yang dapat dihubungi oleh peneliti apabila ia membutuhkan informasi lebih lanjut mengenai penelitian tersebut

Agar pengisian *informed consent* tidak melanggar privasi responden (yang akan dijelaskan di bagian selanjutnya), maka deklarasi persetujuan tidak perlu mengharuskan responden untuk mencantumkan identitas pribadinya, misalnya nama lengkap atau tanda tangan. Peneliti cukup menanyakan apakah responden telah membaca seluruh informasi yang diberikan dan menanyakan apakah mereka bersedia berpartisipasi atau tidak. *Informed consent* juga tidak harus diperoleh secara tertulis, utamanya dalam kondisi *informed consent* tertulis tidak mungkin didapatkan, misalnya ketika responden tidak bisa baca-tulis, atau ada kondisi-kondisi tertentu lainnya. *Informed consent* dapat berupa pernyataan oral atau dapat diwakilkan oleh orang lain dengan syarat tertentu.

Ketika mendapatkan *informed consent* dari responden, peneliti **tidak boleh memaksa** (koersif), meskipun secara implisit, atau memberikan **pengaruh yang terlalu besar** (*unduly influence*) sehingga kecil kemungkinan responden menolak untuk berpartisipasi. Misalnya, dosen tidak boleh memberikan nilai yang lebih rendah pada mahasiswa yang menolak menjadi partisipan penelitiannya. Peneliti juga tidak boleh menawarkan upah yang terlalu besar yang terlalu atraktif sehingga berpartisipasi dalam penelitiannya adalah sesuatu yang sulit ditolak. Memberikan upah yang terlalu besar dapat menimbulkan peluang terjadinya eksploitasi,

utamanya pada responden penelitian dengan latar belakang sosio-ekonomi rendah (Morling, 2018).

Yang kedua, ketika responden memiliki otonomi yang lebih rendah, maka mereka berhak mendapatkan perlindungan ketika membuat keputusan berpartisipasi. Sebagai contoh, responden yang masuk kategori kelompok rentan, yaitu diantaranya adalah; anak-anak (yaitu individu yang berusia **kurang dari 18 tahun** ketika pengambilan data dilaksanakan, menurut UU No. 35 tahun 2014 mengenai perlindungan anak), individu dengan gangguan kognitif dan perkembangan, narapidana (karena rentan mendapat paksaan), lansia, orang dengan penyakit kronis yang mungkin kesulitan untuk membuat keputusan untuk berpartisipasi, harus mendapat bantuan orang terdekat (orangtua atau wali dalam konteks anak, atau orang lain yang dipercayai calon responden dalam konteks sisanya) untuk memahami informasi dalam *informed consent*, termasuk untuk memberikan pernyataan persetujuan.

5.2 Prinsip kebermanfaatan (*beneficence*)

Peneliti memiliki kewajiban untuk menjamin kesejahteraan responden yang berpartisipasi dalam penelitiannya, termasuk mengurangi risiko pengungkapan (*disclosure risk*), yaitu ketika informasi personal (yang berkaitan dengan identitas pribadi, informasi tentang perilaku, status mental, atau reaksi yang sifatnya personal) diketahui orang lain, termasuk peneliti. Untuk mencegah risiko ini, maka peneliti harus menjamin bahwa **responden berpartisipasi secara anonim** dengan tidak menanyakan segala informasi yang mengandung identitas pribadi, misalnya, nama, tanggal lahir, alamat, foto responden, nomor tanda pengenal (Nomor Induk Kependudukan, dsb.). Untuk kuesioner yang diadministrasi menggunakan survei daring, maka peneliti tidak boleh menyimpan penanda digital yang menandai perangkat yang digunakan responden, misalnya *IP address*. Apabila anonimitas tidak dapat dijamin, maka peneliti harus

menjamin kerahasiaan (*confidentiality*) identitas atau informasi personal yang dikumpulkan peneliti disimpan dengan baik dan tidak diberikan kepada pihak ketiga. Penyimpanan data juga dapat dilakukan secara terpisah, tidak dijadikan satu dengan data penelitian yang dianalisis.

Bayangkan apabila adalah salah satu responden dari penelitian yang dilakukan oleh Darley dan Latané. Apa yang anda rasakan ketika mendapati fakta bahwa aktor yang mengalami kejang ternyata hanya suara rekaman? Ada kemungkinan anda merasakan ketidaknyamanan dan kesal karena merasa ‘ditipu’ oleh peneliti. Dalam Kode Etik Psikologi Indonesia, peneliti dilarang untuk berbohong atau menutupi sebagian informasi, yang kemungkinan berdampak pada keputusan berpartisipasi karena menimbulkan cedera fisik, ketidaknyamanan, atau pengalaman emosional yang negatif. Penjelasan mengenai risiko ini **harus dilakukan** sebelum partisipasi dimulai agar responden dapat menimbang keputusannya dengan baik.

Manipulasi **hanya dibenarkan apabila** tujuan penelitian amat penting dan tidak ada cara lain yang tersedia. Ketika situasi ini terjadi, maka peneliti **tetap harus** memberikan informasi pada partisipan bahwa ada informasi yang sengaja tidak diberikan kepada calon responden sebagai bagian dari prosedur penelitian. Namun untuk memastikan tujuan manipulasi dibenarkan atau tidak, peneliti **tidak boleh memutuskannya secara sepihak** melainkan sebelumnya mendapatkan persetujuan dari lembaga yang bertanggungjawab memberikan persetujuan kelayakan etik.

5.3 Prinsip keadilan

Prinsip keadilan mewajibkan peneliti untuk memastikan bahwa orang yang berpartisipasi dan orang yang mendapatkan manfaat dari temuan penelitian, mendapatkan manfaat yang setara (Morling, 2018). Misalnya, apabila berpartisipasi dalam suatu riset dianggap berisiko, maka tentu

ini tidak adil karena responden penelitian harus “menanggung risiko” sedangkan orang yang mendapat manfaat dari riset tidak harus menanggungnya. Contoh konkretnya, semua orang prinsipnya mungkin menderita kanker sehingga tentu tidak adil ketika studi mengenai efektivitas obat yang ditengarai menghambat pertumbuhan kanker dilakukan pada responden dari keluarga miskin, atau etnis minoritas. Oleh karena itu, peneliti harus memastikan bahwa responden yang ia rekrut untuk berpartisipasi adalah sampel yang representatif mewakili populasi yang akan mengambil manfaat dari studi tersebut.

6. Revolusi kredibilitas: Coba-ulang (*reproducibility*) dan reka-ulang (*replicability*) dalam penelitian Psikologi

Di sebuah simposium yang berjudul “*False-Positive Findings are Frequent, Findable, and Fixable*” pada konvensi tahunan Society for Personality and Social Psychology (SPSP) di tahun 2012, Joseph Simmons, Leif Nelson, dan Uri Simonsohn memperkenalkan teknik yang kemudian disebut *p-curve* (Simonsohn et al., 2014), yang digunakan untuk mendeteksi praktik meragukan yang biasa dilakukan peneliti untuk mendapatkan “hasil positif” (signifikan secara statistik), yang kemudian disebut dengan *p-hacking*. Di simposium yang sama, Simmons, Nelson, dan Simonsohn juga mempresentasikan serangkaian “kebiasaan buruk” peneliti Psikologi ketika melakukan penelitian, yang kemudian disebut sebagai praktik meneliti yang meragukan (*questionable research practice*).

Penelitian dengan “hasil positif” (signifikan secara statistik) lebih disukai dan mendapatkan peluang yang lebih besar untuk diterbitkan di jurnal sehingga praktik yang amat umum ditemui adalah peneliti hanya melaporkan hasil signifikan saja (*selective reporting*) (Rodgers & Pustejovsky, 2019) dan ‘menyimpan hasil yang tidak signifikan didalam lemari’ (*file-drawer effect*) (Dalton, Aguinis, Dalton, Bosco, & Pierce, 2012). Dalam memutuskan

apakah naskah yang sedang ditinjau akan diterbitkan atau tidak, editor terlalu sering menolak hasil negatif dan terlalu sering menerbitkan hasil positif. Bias ini disebut juga dengan **bias publikasi** (Rothstein, Sutton, & Borenstein, 2005). Adanya bias publikasi juga menunjukkan *body of knowledge* yang tersedia saat ini tidak benar-benar mencerminkan, bahkan mungkin menjadi distorsi, realitas yang sesungguhnya ingin dijelaskan.

Bias publikasi adalah ancaman besar bagi meta-analisis. Prinsipnya, meta-analisis hanya akan memberikan *insight* yang berguna ketika semua bukti yang tersedia diikutsertakan dalam analisis. Karena bias publikasi, penelitian dengan hasil-hasil negatif sulit dilacak dan ditemukan karena tidak dipublikasi. Besarnya dampak bias publikasi dapat dideteksi dengan beberapa teknik dan yang paling populer adalah menggunakan *funnel plot* (Peters, Sutton, Jones, Abrams, & Rushton, 2008). Meskipun meta-analisis duduk di posisi tertinggi hirarki bukti saintifik, meta-analisis menjadi tidak terlalu berguna ketika peneliti meta tidak melakukan koreksi terhadap bias publikasi. Saat ini peneliti meta sedang mencari strategi terbaik untuk mengoreksi efek bias publikasi dengan teknik statistik, namun berbagai teknik yang tersedia saat ini belum memberikan hasil yang memuaskan (van Aert, 2019).

Hasil penelitian sesungguhnya tidak terbentuk dalam ruang hampa, tetapi merupakan hasil interaksi antara keputusan-keputusan yang diambil peneliti dan pola yang ada di dalam data itu sendiri. Simmons, Nelson, dan Simonsohn (2011) menegaskan bahwa serangkaian keputusan yang diambil peneliti akan sangat berdampak pada hasil akhir penelitian. Fleksibilitas peneliti dalam mengambil keputusan (*researchers degree of freedom*) apalagi ketika dilakukan dengan alasan pragmatis, misalnya, agar mendapatkan hasil yang signifikan, akan menimbulkan masalah dalam jangka panjang. Keputusan-keputusan yang diambil peneliti agar mendapatkan hasil yang signifikan ini cenderung berada di wilayah abu-abu, namun akan mengubah total hasil penelitian.

Selain *selective reporting*, beberapa tindakan yang tergolong sebagai praktik meneliti yang meragukan adalah:

1. *P-value hacking/optional stopping*, yaitu mencakup keputusan peneliti mengambil data terus menerus sampai memperoleh hasil yang sesuai keinginannya (signifikan secara statistik) dan/atau membuang sebagian data (utamanya yang ekstrim/*outlier*) dari analisis data (Head, Holman, Lanfear, Kahn, & Jennions, 2015). Bisa juga dengan tidak melaporkan seluruh kondisi eksperimen atau variabel dependen yang diukur dengan alasan tidak menghasilkan temuan yang signifikan secara statistik (Simmons et al., 2011).
2. *Hypothesising after the results are known* (HARK-ing), yaitu kondisi dimana peneliti melaporkan bahwa hipotesis yang diuji telah diajukan sebelum data diambil, padahal kenyataannya peneliti mencocok-cocokkan berbagai variabel dalam satu dataset dan melaporkan hasil yang signifikan saja. Artinya, hipotesis yang seharusnya dirumuskan sebelum pengambilan data, justru dirumuskan secara *post-hoc*, yaitu ketika data selesai diambil. Dengan begitu, peneliti menggunakan data yang sama untuk merumuskan (*exploratory*) dan menguji (*confirmatory*) hipotesis (Hollenbeck & Wright, 2017). Melakukan analisis eksploratif dan konfirmatori pada data yang sama rentan menimbulkan ***Texas Sharpshooter Fallacy***, yaitu seolah-olah prediksi peneliti terbukti ketika menganalisis data, padahal yang ‘terbukti’ adalah prediksi, yaitu kesimpulan setelah melihat data.



Figure 7.: Texas Sharpshooter Fallacy. Sumber: <https://www.bayesianspectacles.org/origin-of-the-texas-sharpshooter/>

3. Pelaporan yang tidak lengkap dan pembulatan nilai p yang terlalu banyak (*incomplete reporting* dan *generous rounding*), yaitu ketika peneliti tidak melaporkan secara lengkap keputusan-keputusan penting yang menentukan hasil penelitian, seperti membuang data ekstrim (*outlier*) atau ketika peneliti tidak melakukan koreksi atas nilai p (misalnya menggunakan Tukey atau Bonferroni) ketika melakukan *post-hoc test*. Kadang-kadang ditemukan peneliti yang membulatkan ke bawah nilai p yang sedikit diatas 0.05, agar dapat dilaporkan signifikan (misalnya, melaporkan nilai $p=0.053$ menjadi $p \leq 0.05$) (Barnett, Fraser, Parker, Nakagawa, & Fidler, 2018; John, Loewenstein, & Prelec, 2012).

Kombinasi antara rendahnya *statistical power*, bias publikasi, dan praktik meneliti yang meragukan menyebabkan terjadinya krisis kredibilitas dalam penelitian-penelitian Psikologi

sehingga imbasnya, klaim dan teori Psikologi dicurigai mengandung *false positive* (Simmons et al., 2011).

Tak lama se usai Konvensi SPSP, 72 peneliti dari 41 institusi di seluruh dunia berkumpul untuk merencanakan proyek coba-ulang (replikasi) 100 penelitian psikologi yang diterbitkan di tiga jurnal ternama, yaitu *Psychological Science*, *Journal of Social and Personality Psychology*, dan *Journal of Experimental Psychology: Learning, Memory, and Cognition*. Penelitian coba-ulang multi-lokasi ini dinamai *Reproducibility Project: Psychology (RP:P)* (Open Science Collaboration, 2015), dilakukan dengan desain yang lebih baik, dan *statistical power* yang lebih tinggi daripada studi aslinya dan dilakukan di beberapa lokasi yang berbeda sekaligus. Tiga tahun setelah direncanakan, hasil penelitian tersebut dirilis pada tahun 2015 dan hasilnya mengejutkan. Sesuai dengan prediksi Cohen (1988), ternyata ukuran efek yang ditemukan oleh tim RP:P hanya setengah dari ukuran efek yang dilaporkan di studi originalnya. Artinya, studi-studi aslinya melaporkan ukuran efek yang cenderung dilebih-lebihkan.

Tidak hanya itu, beberapa teori yang dianggap sudah mapan dan populer di Psikologi, misalnya, *precognition* (Ritchie, Wiseman, & French, 2012), *ego depletion* (Hagger et al., 2016), *power posing* (Garrison, Tang, & Schmeichel, 2016), dan *mortality salience* atau *terror-management theory* (Klein et al., 2019) juga gagal ditemukan buktinya ketika dilakukan penelitian coba-ulang. Setelah mulai banyak teori yang gagal dicoba-ulang, mulai banyak muncul pertanyaan, apakah klaim-klaim dan teori-teori Psikologi masih bisa dipercayai kebenarannya?

Krisis kredibilitas ilmu pengetahuan merupakan kekusaran yang banyak dibincangkan oleh komunitas akademik global sejak satu dekade terakhir, dan dialami oleh banyak sekali komunitas akademik di berbagai disiplin ilmu. Tidak hanya Psikologi, krisis kredibilitas juga ditengarai membelit Ekonomi (Camerer et al., 2016), Ilmu Politik (Lupia & Elman, 2014),

Biomedis (Davis, 2014), Kedokteran (Goodman, Fanelli, & Ioannidis, 2016), Farmakologi (Prinz, Schlange, & Asadullah, 2011), Hidrologi (Stagge et al., 2019), Fisika (Stein, Smith, & Holmes, 2018), dan Kimia (Cooper, 2018). Beberapa peneliti menyebut krisis kredibilitas sebagai krisis replikasi (coba-ulang) (Yong, 2018), beberapa yang lain menyebut krisis *reproducibility* (reka-ulang) (Fanelli, 2018).

Meskipun ada banyak kebingungan istilah, definisi coba-ulang dan reka-ulang mulai mencapai kesepakatan. Suatu teori dikatakan berhasil **dicoba-ulang (replikasi)**, apabila setelah dilakukan pengambilan data di lokasi yang berbeda (dengan tim peneliti yang berbeda) menghasilkan kesimpulan yang konsisten. Sedangkan suatu penelitian dapat dikatakan berhasil **direka-ulang (reproducible)** ketika temuan penelitian dianalisis ulang oleh peneliti lain dengan menggunakan data mentah, perintah (*syntax/codes*), metode, prosedur, dan rencana analisis yang sama dengan peneliti aslinya, akan menghasilkan temuan yang sama pula (Committee on Reproducibility and Replicability in Science et al., 2019).

Untuk menunjukkan adanya kemungkinan bahwa data yang sama akan disimpulkan berbeda ketika dianalisis oleh peneliti yang berbeda, Silberzahn, dkk. (2018) meminta 61 peneliti yang bekerja dalam 29 tim peneliti yang berbeda untuk menganalisis dataset yang sama, dalam rangka menjawab pertanyaan yang sama pula, “apakah wasit pertandingan sepak bola akan cenderung memberikan kartu merah pada pemain yang kulitnya lebih gelap daripada yang kulitnya lebih terang?” Hasilnya, 20 tim peneliti (69%) menemukan korelasi positif dan signifikan antara warna kulit pemain dengan peluang mendapat kartu merah, sedangkan sisanya tidak menemukan korelasi apapun. Silberzahn, dkk. (2018) mendeteksi setidaknya ada 21 kombinasi keputusan unik yang diambil oleh responden penelitiannya. Dari penelitian Silberzahn, dkk. (2018) dapat disimpulkan bahwa penelitian coba-ulang gagal menemukan

ukuran efek sebesar penelitian originalnya, bisa jadi karena peneliti kurang transparan dalam melaporkan bagaimana pengambilan keputusan yang mereka lakukan selama proses penelitian.

Mengecek kredibilitas temuan penelitian dengan melakukan coba-ulang bukan hal yang mudah. Karena peneliti tidak melaporkan secara lengkap proses penelitian yang dilakukan, jangankan mengulangi analisis datanya, sekadar membuat protokol dari artikel penelitian yang sudah dipublikasi merupakan pekerjaan yang amat sulit. Sebagai ilustrasi, peneliti yang terlibat dalam Reproducibility Project: Cancer Biology (RP:CB) mencoba-ulang 51 penelitian preklinik yang diterbitkan di jurnal-jurnal prestisius, termasuk Nature, Science, dan Cell. Dari 51 penelitian tersebut, tidak ada satupun yang menyertakan data mentah penelitiannya dan tidak ada satupun protokol yang berhasil ditulis peneliti RP:CB dengan hanya mengandalkan informasi yang ditulis dalam 51 naskah publikasi tersebut (Errington, 2019).

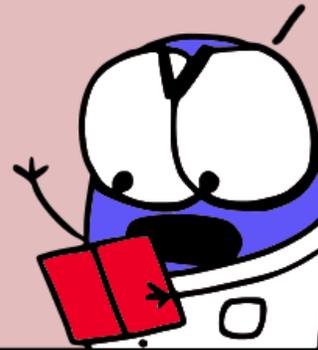
Real scientist

We need you
to replicate this
top-secret research.



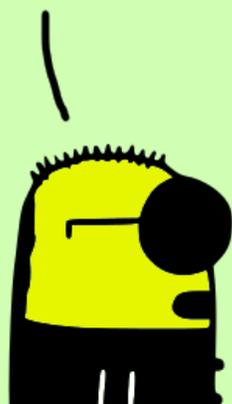
REPLICATE?!

I can barely understand the writing!
The graphs have no legends,
there's raw data pasted everywhere,
and it has no experimental
context whatsoever!



Movie scientist

We need you
to replicate this
top-secret research.



REPLICATE?!

Give me an hour
and I can do it better.

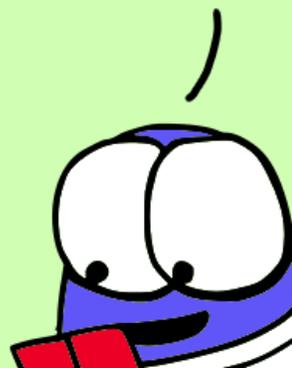


Figure 8: Reka-ulang Temuan Penelitian. Sumber: <https://theupturnedmicroscope.com/>

Sejak saat disadari, komunitas akademik mulai berbenah diri dengan mendorong peneliti untuk mengubah kebiasaan-kebiasaan yang dulu sering dilakukan. Salam satunya yaitu mendorong perubahan kultur riset sehingga membuat riset lebih mudah diakses, transparan, akuntabel, dan mengedepankan kolaborasi karena praktik meneliti meragukan berkaitan dengan nuansa kompetitif dan tekanan kewajiban publikasi yang terlalu besar (Tijdink, Verbeke, & Smulders, 2014). Para peneliti yang mengadvokasi praktik sains terbuka (Spellman, Gilbert, & Corker, 2017) terus berusaha meyakinkan peneliti untuk mengubah cara mereka bekerja dan mengadvokasi pengambil kebijakan untuk memberikan penguatan positif pada peneliti yang bersedia mengadopsinya.

6.1 Petunjuk praktis agar penelitian dapat direka-ulang

Sebagai peneliti, tentu kita menginginkan agar temuan penelitian yang kita lakukan dianggap kredibel dan bermanfaat bagi banyak pihak, baik bagi penelitian selanjutnya, maupun bagi masyarakat luas. Oleh karena itu, agar dapat direka-ulang ada beberapa tips yang dapat dipraktikkan oleh peneliti.

6.1.1 Pra-registrasi

Salah satu penyebab temuan penelitian gagal dicoba-ulang dan direka-ulang adalah akibat peneliti merumuskan dan menguji hipotesis dengan data yang sama padahal prediksi (merumuskan kesimpulan setelah melihat data) dan prediksi (mengajukan dugaan sebelum mengambil data) seharusnya dilakukan pada kelompok sampel yang berbeda (Nosek, Ebersole, DeHaven, & Mellor, 2018). Untuk menjamin transparansi sekaligus membantu peneliti

memisahkan analisis yang sifatnya eksploratif (yang menghasilkan hipotesis) dengan konfirmatori (menguji teori) adalah dengan melakukan **pra-registrasi**.

Praregistrasi adalah kegiatan mendaftarkan (melakukan registrasi) protokol atau rencana penelitian, yang terdiri dari; kriteria inklusi dan eksklusi, strategi pengukuran, aturan penghentian pengambilan data (*stopping rule*), perencanaan jumlah sampel, dan strategi analisis data. Protokol dapat disimpan di repositori publik, yang mudah diakses peneliti lain apabila diperlukan, yang memungkinkan dokumen pra-registrasi mendapatkan stempel waktu (Veldkamp et al., 2018).

Ada kekhawatiran bahwa ide penelitian dapat dicuri atau ditiru peneliti lainnya ketika dokumen pra-registrasi dapat diakses terbuka. Kegelisahan ini sangat wajar dan beralasan, namun dapat diatasi peneliti dengan cara mengatur agar akses pada dokumen pra-registrasi hanya bisa didapatkan oleh kalangan terbatas (misalnya, editor atau *reviewer* jurnal) dan membuatnya dapat diakses oleh publik ketika naskah sudah diterbitkan.

6.1.2 Manajemen data penelitian

Manajemen data penelitian adalah kegiatan yang amat penting dan sentral peranannya dalam menentukan kredibilitas riset. Data penelitian yang tidak dikelola dengan baik merupakan masalah yang dapat membuat penelitian sulit direka-ulang. Untuk itu, peneliti amat disarankan untuk membagikan datanya secara terbuka sebagai bagian dari naskah publikasi (misalnya sebagai *supplementary materials*) dan agar data tersebut bermanfaat, maka sebaiknya disimpan dengan memperhatikan prinsip mudah dicari (*findable*), mudah diakses (*accessible*), mudah dimengerti (*interoperable*), dan mudah digunakan kembali (*reusable*) (FAIR) (Wilkinson et al., 2016). Berikut adalah beberapa tips yang dapat dilakukan:

1. Agar data mudah ditemukan (*findable*), maka peneliti dapat menyimpan datanya pada repositori yang memberikan *persistent identifier* seperti nomor *digital object identification* (DOI). Dengan begitu, peneliti juga mendapat rekognisi ketika datanya digunakan kembali.
2. Agar datanya mudah diakses (*accessible*) maka sebaiknya data disimpan di repositori terbuka (publik) yang dapat diakses oleh siapapun. Menyimpan data di repositori institusi juga disarankan, selama tidak ada pembatasan akses.
3. Agar data mudah dimengerti (*interoperable*) maka dataset sebaiknya dilengkapi dengan metadata berupa kamus data (*codebook*) yang dapat disusun sesuai kaidah yang disepakati oleh komunitas akademik di masing-masing disiplin.
4. Agar data dapat digunakan kembali (*reusable*), maka data sebaiknya diberikan lisensi yang memungkinkan penggunaan ulang, misalnya Creative Commons (CC) atau General Public License (GNU) dan dikelola sedemikian rupa sehingga dapat dibaca oleh mesin (*machine readable*)

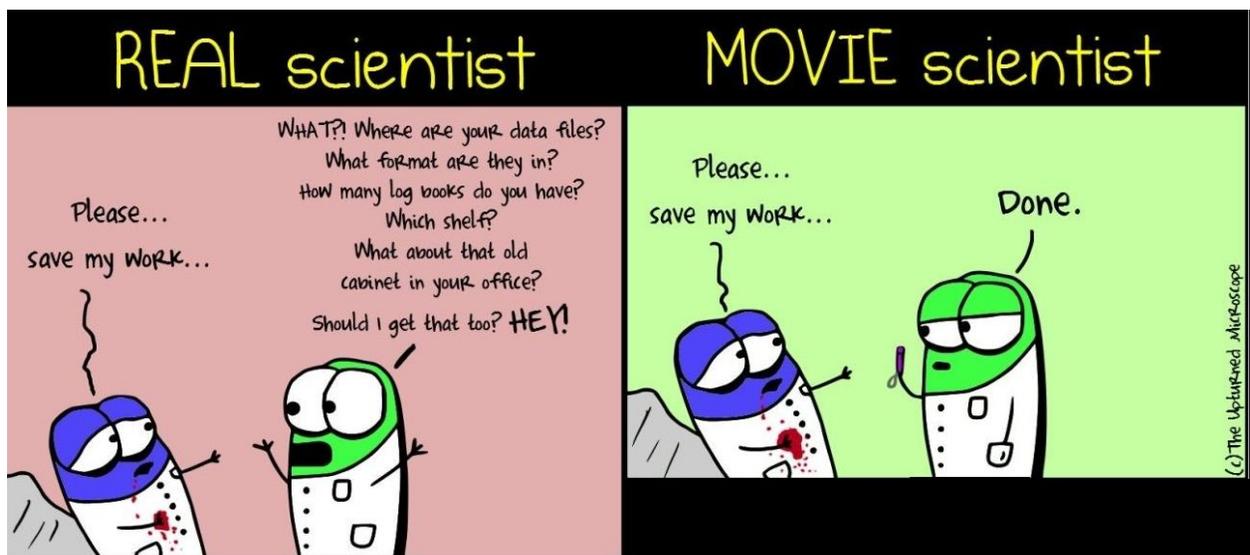


Figure 9: Reka-ulang Data Penelitian. Sumber: <https://theupturnedmicroscope.com/>

Ketika membagikan data penelitian, peneliti harus memastikan bahwa dataset yang dibagikan sifatnya anonim, tidak mengandung informasi personal yang dapat memudahkan identifikasi responden yang berpartisipasi (*de-identified dataset*). Peneliti juga perlu menginformasikan kepada responden bahwa data penelitian akan disimpan di repositori dan dapat diakses terbuka. Apabila karena beberapa hal dataset mengandung risiko pengungkapan (*disclosure risk*) yang tak dapat diantisipasi, maka peneliti dapat membatasi akses pada dataset

hanya apabila ada permintaan akses. Opsi lain yang dapat dilakukan adalah membuat dataset sintetis, yaitu dataset yang berbeda dengan karakteristik yang sama persis dengan dataset aslinya (Quintana, 2019).

Terakhir, untuk menjamin transparansi dan membantu peneliti mengingat-ingat keputusan yang ia ambil ketika menganalisis data, pendekatan kendali versi (*version control*) dapat digunakan untuk merekam semua perubahan yang dilakukan, sekaligus sebagai *logbook* pengelolaan data (Sandve, Nekrutenko, Taylor, & Hovig, 2013). Repositori seperti [GitHub](#) dan [Open Science Framework \(OSF\)](#) menyediakan fitur kendali versi ini, sehingga semua perubahan atas dokumen yang disimpan dalam repositori akan terekam dengan baik.

References

- Alderson, P. (2004). Absence of evidence is not evidence of absence. *BMJ : British Medical Journal*, 328(7438), 476–477.
- Appelbaum, M., Cooper, H., Kline, R. B., Mayo-Wilson, E., Nezu, A. M., & Rao, S. M. (2018). Journal article reporting standards for quantitative research in psychology: The APA Publications and Communications Board task force report. *American Psychologist*, 73(1), 3–25. <https://doi.org/10.1037/amp0000191>
- Barnett, A., Fraser, H., Parker, T. H., Nakagawa, S., & Fidler, F. (2018). Questionable Research Practices (QRPs) in Ecology and Evolution. *PLoS ONE*, 13(7), e0200303. <https://doi.org/10.1371/journal.pone.0200303>
- Bethlehem, J. (2010). Selection Bias in Web Surveys: Selection Bias in Web Surveys. *International Statistical Review*, 78(2), 161–188. <https://doi.org/10.1111/j.1751-5823.2010.00112.x>
- Biemer, P. P. (2010). Total Survey Error: Design, Implementation, and Evaluation. *Public Opinion Quarterly*, 74(5), 817–848. <https://doi.org/10.1093/poq/nfq058>
- Borenstein, M., Hedges, L. V., Higgins, J. P. T., & Rothstein, H. R. (2009). Meta-Regression.
- Bornstein, R. F. (2011). Toward a process-focused model of test score validity: Improving psychological assessment in science and practice. *Psychological Assessment*, 23(2), 532–544. <https://doi.org/10.1037/a0022402>

Camerer, C. F., Dreber, A., Forsell, E., Ho, T.-H., Huber, J., Johannesson, M., ... Wu, H. (2016).

Evaluating replicability of laboratory experiments in economics. *Science*, 351(6280), 1433–1436. <https://doi.org/10.1126/science.aaf0918>

Chan, M.-p. S., Jones, C. R., Hall Jamieson, K., & Albarracín, D. (2017). Debunking: A Meta-Analysis of the Psychological Efficacy of Messages Countering Misinformation.

Psychological Science, 28(11), 1531–1546. <https://doi.org/10.1177/0956797617714579>

Cho, E. (2016). Making Reliability Reliable: A Systematic Approach to Reliability Coefficients.

Organizational Research Methods, 19(4), 651–682.

<https://doi.org/10.1177/1094428116656239>

Cohen, J. (1988). *Statistical Power Analysis for the Behavioral Sciences* (2nd ed.). Hillsdale, NJ:

Lawrence Erlbaum Associates, Inc.

Cohen, J. (1992). A Power Primer. *Psychological Bulletin*, 112(1), 155.

<https://doi.org/10.1038/141613a0>

Cohen, J. (1994). The earth is round ($p < 0.05$). *American Psychologist*, 49(12),

997–1003. <https://doi.org/10.1037/0003-066X.50.12.1103>

Committee on Reproducibility and Replicability in Science, Board on Behavioral, Cognitive, and Sensory Sciences, Committee on National Statistics, Division of Behavioral and Social Sciences and Education, Nuclear and Radiation Studies Board, Division on Earth and Life Studies, ... National Academies of Sciences, Engineering, and Medicine. (2019).

Reproducibility and Replicability in Science. Washington, D.C.: National Academies Press. <https://doi.org/10.17226/25303>

- Cooper, M. M. (2018). The Replication Crisis and Chemistry Education Research. *Journal of Chemical Education*, 95(1), 1–2. <https://doi.org/10.1021/acs.jchemed.7b00907>
- Cronbach, L. J., & Meehl, P. E. (1955). Construct Validity in Psychological Test. *Psychological Bulletin*, 52(4), 281–302.
- Dalton, D. R., Aguinis, H., Dalton, C. M., Bosco, F. A., & Pierce, C. A. (2012). REVISITING THE FILE DRAWER PROBLEM IN META-ANALYSIS: AN ASSESSMENT OF PUBLISHED AND NONPUBLISHED CORRELATION MATRICES: PERSONNEL PSYCHOLOGY. *Personnel Psychology*, 65(2), 221–249. <https://doi.org/10.1111/j.1744-6570.2012.01243.x>
- Darley, J. M., & Latané, B. (1968). Bystander intervention in emergencies: Diffusion of responsibility. *Journal of Personality and Social Psychology*, 8(4), 377–383. <https://doi.org/10.1037/h0025589>
- Davis, N. (2017). The Goldwater rule: Why commenting on mental health from a distance is unhelpful. *The Guardian*.
- Davis, R. J. (2014). Reproducibility Project: Cancer Biology. *eLife*. <https://elifesciences.org/collections/9b1e83d1/reproducibility-project-cancer-biology>.
- Deming, W. E. (1944). On Errors in Surveys. *American Sociological Review*, 9(4), 359–369.
- Dienes, Z. (2008). *Understanding psychology as a science*. London: Palgrave Macmillan.
- Donsbach, W. (2015). Public Opinion Polls. In G. Mazzoleni (Ed.), *The International Encyclopedia of Political Communication*. New York: Wiley-Blackwell.

Dorey, F. J. (2011). In Brief: Statistics in Brief: Statistical Power: What Is It and When Should It Be Used? *Clinical Orthopaedics and Related Research*, 469(2), 619–620.

<https://doi.org/10.1007/s11999-010-1435-0>

Duckitt, J. (2001). A dual-process cognitive-motivational theory of ideology and prejudice. In *Advances in experimental social psychology* (Vol. 33, pp. 41–113).

[https://doi.org/10.1016/S0065-2601\(01\)80004-6](https://doi.org/10.1016/S0065-2601(01)80004-6)

Dumenci, L. (2000). Multitrait-Multimethod Analysis. In H. E. A. Tinsley & S. D. Brown (Eds.), *Handbook of Applied Multivariate Statistics and Mathematical Modeling* (pp. 583–611).

San Diego: Elsevier. <https://doi.org/10.1016/B978-0-12-691360-6.X5000-9>

Dunn, T. J., Baguley, T., & Brunsdon, V. (2014). From alpha to omega: A practical solution to the pervasive problem of internal consistency estimation. *British Journal of Psychology*, 105(3), 399–412. <https://doi.org/10.1111/bjop.12046>

Erişen, C., Erişen, E., & Özkeçeci-Taner, B. (2013). Research Methods in Political Psychology. *Turkish Studies*, 14(1), 13–33. <https://doi.org/10.1080/14683849.2013.766979>

Errington, T. (2019). Reproducibility Project: Cancer Biology - Barriers to Replicability in the Process of Research. Stanford University.

Fanelli, D. (2012). Negative results are disappearing from most disciplines and countries.

Scientometrics, 90(3), 891–904. <https://doi.org/10.1007/s11192-011-0494-7>

Fanelli, D. (2018). Opinion: Is science really facing a reproducibility crisis, and do we need it to? *Proceedings of the National Academy of Sciences*, 115(11), 2628–2631.

<https://doi.org/10.1073/pnas.1708272114>

- Fealy, G. (2014). Resurgent political Islam, or astute Islamic parties? *New Mandala*.
- Fowler, F. J. (2014). *Survey research methods* (Fifth edition). Los Angeles: SAGE.
- Fried, E. I., & Flake, J. K. (2018). Measurement Matters. *APS Observer*, 31(3).
- Gaines, B. J., Kuklinski, J. H., & Quirk, P. J. (2007). The Logic of the Survey Experiment Reexamined. *Political Analysis*, 15(1), 1–20. <https://doi.org/10.1093/pan/mpi008>
- Garrison, K. E., Tang, D., & Schmeichel, B. J. (2016). Embodying Power: A Preregistered Replication and Extension of the Power Pose Effect. *Social Psychological and Personality Science*, 7(7), 623–630. <https://doi.org/10.1177/1948550616652209>
- Gawronski, B., Galdi, S., & Arcuri, L. (2015). What Can Political Psychology Learn from Implicit Measures? Empirical Evidence and New Directions: Implicit Measures in Political Psychology. *Political Psychology*, 36(1), 1–17. <https://doi.org/10.1111/pops.12094>
- Giorgi, A. (2012). The descriptive phenomenological psychological method. *Journal of Phenomenological Psychology*, 43(1), 3–12. <https://doi.org/10.1163/156916212X632934>
- Goodman, S. N., Fanelli, D., & Ioannidis, J. P. A. (2016). What does research reproducibility mean? *Science Translational Medicine*, 8(341), 341ps12–341ps12. <https://doi.org/10.1126/scitranslmed.aaf5027>
- Greenland, S., Senn, S. J., Rothman, K. J., Carlin, J. B., Poole, C., Goodman, S. N., & Altman, D. G. (2016). Statistical tests, P values, confidence intervals, and power: A guide to misinterpretations. *European Journal of Epidemiology*, 31(4), 337–350. <https://doi.org/10.1007/s10654-016-0149-3>

- Groves, R. M., & Lyberg, L. (2010). Total Survey Error: Past, Present, and Future. *Public Opinion Quarterly*, 74(5), 849–879. <https://doi.org/10.1093/poq/nfq065>
- Hagger, M. S., Chatzisarantis, N. L. D., Alberts, H., Anggono, C. O., Batailler, C., Birt, A. R., ... Zwieneberg, M. (2016). A Multilab Preregistered Replication of the Ego-Depletion Effect. *Perspectives on Psychological Science*, 11(4), 546–573. <https://doi.org/10.1177/1745691616652873>
- Hammack, P. L., & Pilecki, A. (2014). Methodological approaches in political psychology: Discourse and narrative. In *The Palgrave Handbook of Global Political Psychology* (pp. 72–89). London: Palgrave Macmillan.
- 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. <https://doi.org/10.1371/journal.pbio.1002106>
- Hendry, L. B., Mayer, P., & Kloep, M. (2007). Belonging or Opposing? A Grounded Theory Approach to Young People's Cultural Identity in a Majority/Minority Societal Context. *Identity*, 7(3), 181–204. <https://doi.org/10.1080/15283480709336930>
- Hidayat, R. (2018). Rawan Kepentingan: Campur Aduk Lembaga Survei & Jasa Konsultan. *tirto.id*. <https://tirto.id/rawan-kepentingan-campur-aduk-lembaga-survei-jasa-konsultan-cJkL>.
- HIMPSI. (2010). *Kode Etik Psikologi Indonesia* (Pertama (Kongres XI HIMPSI 2010)). Jakarta: Pengurus Pusat Himpunan Psikologi Indonesia (HIMPSI).

- Hollenbeck, J. R., & Wright, P. M. (2017). Harking, Sharking, and Tharking: Making the Case for Post Hoc Analysis of Scientific Data. *Journal of Management*, 43(1), 5–18.
<https://doi.org/10.1177/0149206316679487>
- Hunsley, J., & Meyer, G. J. (2003). The Incremental Validity of Psychological Testing and Assessment: Conceptual, Methodological, and Statistical Issues. *Psychological Assessment*, 15(4), 446–455. <https://doi.org/10.1037/1040-3590.15.4.446>
- Intan, G. (2019). Dituduh Tukang Bohong, Lembaga Survei Ungkap Data dan Metodologi Quick Count. *VOA Indonesia*. <https://www.voaindonesia.com/a/dituduh-tukang-bohong-lembaga-survei-ungkap-data-dan-metodologi-quick-count/4885243.html>.
- Ioannidis, J. P. A. (2018). Meta-research: Why research on research matters. *PLOS Biology*, 16(3), e2005468. <https://doi.org/10.1371/journal.pbio.2005468>
- Isani, M., & Silverman, D. (2016). Foreign Policy Attitudes toward Islamic Actors: An Experimental Approach. *Political Research Quarterly*, 69(3), 571–582.
<https://doi.org/10.1177/1065912916654988>
- Israel, H., & Richter, R. R. (2011). A Guide to Understanding Meta-analysis. *Journal of Orthopaedic & Sports Physical Therapy*, 41(7), 496–504.
<https://doi.org/10.2519/jospt.2011.3333>
- John, L. K., Loewenstein, G., & Prelec, D. (2012). Measuring the Prevalence of Questionable Research Practices With Incentives for Truth Telling. *Psychological Science*, 23(5), 524–532. <https://doi.org/10.1177/0956797611430953>

- Jost, J. T. (2019). The IAT Is Dead, Long Live the IAT: Context-Sensitive Measures of Implicit Attitudes Are Indispensable to Social and Political Psychology. *Current Directions in Psychological Science*, 28(1), 10–19. <https://doi.org/10.1177/0963721418797309>
- Kaarbo, J., & Beasley, R. K. (1999). A Practical Guide to the Comparative Case Study Method in Political Psychology. *Political Psychology*, 20(2), 369–391. <https://doi.org/10.1111/0162-895X.00149>
- Kelley, K., & Preacher, K. J. (2012). On effect size. *Psychological Methods*, 17(2), 137–152. <https://doi.org/10.1037/a0028086>
- Khan, K. S. (2003). Five Steps to Conducting a Systematic Review, 96, 4.
- Klein, R. A., Cook, C. L., Ebersole, C. R., Vitiello, C. A., Nosek, B. A., Chartier, C. R., ... Ratliff, K. A. (2019). *Many Labs 4: Failure to Replicate Mortality Salience Effect With and Without Original Author Involvement* (Preprint). PsyArXiv. <https://doi.org/10.31234/osf.io/vef2c>
- Lilienfeld, S. O., Miller, J. D., & Lynam, D. R. (2018). The Goldwater Rule: Perspectives From, and Implications for, Psychological Science. *Perspectives on Psychological Science*, 13(1), 3–27. <https://doi.org/10.1177/1745691617727864>
- Lupia, A., & Elman, C. (2014). Openness in Political Science: Data Access and Research Transparency. *PS: Political Science & Politics*, 47(01), 19–42. <https://doi.org/10.1017/S1049096513001716>
- Mair, P. (2018). *Modern Psychometrics with R*. Cham: Springer International Publishing. <https://doi.org/10.1007/978-3-319-93177-7>

- Maris, E. (1995). Psychometric latent response models. *Psychometrika*, *60*(4), 523–547.
- Mayr, S., Buchner, A., Erdfelder, E., & Faul, F. (2007). A short tutorial of GPower. *Tutorials in Quantitative Methods for Psychology*, *3*(2), 51–59. <https://doi.org/10.1037/0096-1523.32.4.932>
- McAdams, D. P., Albaugh, M., Farber, E., Daniels, J., Logan, R. L., & Olson, B. (2008). Family metaphors and moral intuitions: How conservatives and liberals narrate their lives. *Journal of Personality and Social Psychology*, *95*(4), 978–990. <https://doi.org/10.1037/a0012650>
- McNally, R. J. (2018). Diagnosing at a Distance: Is the Goldwater Rule Still Relevant Today? *Perspectives on Psychological Science*, *13*(1), 28–30. <https://doi.org/10.1177/1745691617731636>
- McNeish, D. (2018). Thanks coefficient alpha, we'll take it from here. *Psychological Methods*, *23*(3), 412–433. <https://doi.org/10.1037/met0000144>
- Messick, S. (1995). Validity of Psychological Assessment. *American Psychologist*, *9*.
- Mietzner, M. (2009). Political opinion polling in post-authoritarian Indonesia: Catalyst or obstacle to democratic consolidation? *Bijdragen Tot de Taal-, Land- En Volkenkunde / Journal of the Humanities and Social Sciences of Southeast Asia*, *165*(1), 95–126. <https://doi.org/10.1163/22134379-90003644>
- Moher, D., Shamseer, L., Clarke, M., Ghersi, D., Liberati, A., Petticrew, M., ... PRISMA-P Group. (2015). Preferred reporting items for systematic review and meta-analysis

protocols (PRISMA-P) 2015 statement. *Systematic Reviews*, 4(1), 1.

<https://doi.org/10.1186/2046-4053-4-1>

Morling, B. (2018). *Research Methods in Psychology: Evaluating a World of Information* (3rd ed.). New York, NY: W. W. Norton & Company, Inc.

Mullinix, K. J., Leeper, T. J., Druckman, J. N., & Freese, J. (2015). The Generalizability of Survey Experiments. *Journal of Experimental Political Science*, 2(2), 109–138.

<https://doi.org/10.1017/XPS.2015.19>

Nosek, B. A., Ebersole, C. R., DeHaven, A. C., & Mellor, D. T. (2018). The preregistration revolution. *Proceedings of the National Academy of Sciences*, 2017(15), 201708274.

<https://doi.org/10.1073/pnas.1708274114>

Open Science Collaboration. (2015). Estimating the reproducibility of psychological science.

Science, 349(6251), aac4716–aac4716. <https://doi.org/10.1126/science.aac4716>

Panagiotakos, D. B. (2008). The Value of p-Value in Biomedical Research. *The Open Cardiovascular Medicine Journal*, 2(1), 97–99.

<https://doi.org/10.2174/1874192400802010097>

Parackal, M., Mather, D., & Holdsworth, D. (2018). Value-based prediction of election results using natural language processing: A case of the New Zealand General Election.

International Journal of Market Research, 60(2), 156–168.

<https://doi.org/10.1177/1470785318762234>

- Perezgonzalez, J. D. (2015). Fisher, Neyman-Pearson or NHST? A tutorial for teaching data testing. *Frontiers in Psychology*, 6(MAR), 1–11.
<https://doi.org/10.3389/fpsyg.2015.00223>
- Peters, G. J. Y. (2018). *The alpha and the omega of scale reliability and validity: Why and how to abandon Cronbach's alpha and the route towards more comprehensive assessment of scale quality* (Preprint). PsyArXiv. <https://doi.org/10.31234/osf.io/h47fv>
- Peters, J. L., Sutton, A. J., Jones, D. R., Abrams, K. R., & Rushton, L. (2008). Contour-enhanced meta-analysis funnel plots help distinguish publication bias from other causes of asymmetry. *Journal of Clinical Epidemiology*, 61(10), 991–996.
<https://doi.org/10.1016/j.jclinepi.2007.11.010>
- Price, P. C., Jhangiani, R. S., Chiang, I.-C. A., Leighton, D. C., & Cuttler, C. (2017). *Research Methods in Psychology* (3rd ed.). Pullman: Washington State University.
- Prinz, F., Schlange, T., & Asadullah, K. (2011). Believe it or not: How much can we rely on published data on potential drug targets? *Nature Reviews Drug Discovery*, 10(9), 712–712. <https://doi.org/10.1038/nrd3439-c1>
- Quintana, D. (2019). Synthetic datasets: A non-technical primer for the behavioural sciences to promote reproducibility and hypothesis-generation. <https://doi.org/10.31234/osf.io/dmfb3>
- Revelle, W., & Zinbarg, R. E. (2008). Coefficients Alpha, Beta, Omega, and the glb: Comments on Sijtsma. *Psychometrika*, 74(1), 145. <https://doi.org/10.1007/s11336-008-9102-z>

- Rheault, L., Beelen, K., Cochrane, C., & Hirst, G. (2016). Measuring Emotion in Parliamentary Debates with Automated Textual Analysis. *PLOS ONE*, *11*(12).
<https://doi.org/10.1371/journal.pone.0168843>
- Ritchie, S. J., Wiseman, R., & French, C. C. (2012). Failing the Future: Three Unsuccessful Attempts to Replicate Bem's "Retroactive Facilitation of Recall" Effect. *PLOS ONE*, *7*(3), e33423. <https://doi.org/10.1371/journal.pone.0033423>
- Rodgers, M. A., & Pustejovsky, J. E. (2019). *Evaluating Meta-Analytic Methods to Detect Selective Reporting in the Presence of Dependent Effect Sizes* (Preprint). MetaArXiv.
<https://doi.org/10.31222/osf.io/vqp8u>
- Rothstein, H., Sutton, A. J., & Borenstein, M. (Eds.). (2005). *Publication bias in meta-analysis: Prevention, assessment and adjustments*. Chichester, England ; Hoboken, NJ: Wiley.
- Rubio, D. M., Berg-Weger, M., Tebb, S. S., Lee, E. S., & Rauch, S. (2003). Objectifying content validity: Conducting a content validity study in social work research. *Social Work Research*, *27*(2), 94–104. <https://doi.org/10.1093/swr/27.2.94>
- Ruel, E. E., Wagner, W. E., & Gillespie, B. J. (2016). *The practice of survey research: Theory and applications*. Thousand Oaks, CA: Sage Publications, Inc.
- Sandve, G. K., Nekrutenko, A., Taylor, J., & Hovig, E. (2013). Ten Simple Rules for Reproducible Computational Research. *PLOS Computational Biology*, *9*(10), e1003285.
<https://doi.org/10.1371/journal.pcbi.1003285>

Schafer, M. (2000). Issues in Assessing Psychological Characteristics at a Distance: An Introduction to the Symposium. *Political Psychology*, 21(3), 511–527.

<https://doi.org/10.1111/0162-895X.00201>

Schoonvelde, M., Schumacher, G., & Bakker, B. N. (2019). Friends With Text as Data Benefits: Assessing and Extending the Use of Automated Text Analysis in Political Science and Political Psychology. *Journal of Social and Political Psychology*, 7(1), 124–143–143.

<https://doi.org/10.5964/jspp.v7i1.964>

Shaughnessy, J. J., Zechmeister, E. B., & Zechmeister, J. S. (2012). *Research methods in psychology* (9th ed). New York, NY: McGraw-Hill.

Sijtsma, K. (2008). On the Use, the Misuse, and the Very Limited Usefulness of Cronbach's Alpha. *Psychometrika*, 74(1), 107. <https://doi.org/10.1007/s11336-008-9101-0>

Silberzahn, R., Uhlmann, E. L., Martin, D. P., Anselmi, P., Aust, F., Awtrey, E., ... Nosek, B. A. (2018). Many Analysts, One Data Set: Making Transparent How Variations in Analytic Choices Affect Results: *Advances in Methods and Practices in Psychological Science*.

<https://doi.org/10.1177/2515245917747646>

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. <https://doi.org/10.1177/0956797611417632>

Simonsohn, U., Nelson, L. D., & Simmons, J. P. (2014). P-Curve and Effect Size: Correcting for Publication Bias Using Only Significant Results. *Perspectives on Psychological Science*, 9(6), 666–681. <https://doi.org/10.1177/1745691614553988>

Singh, S. (2018). Understanding the Bias-Variance Tradeoff. *Medium*.

<https://towardsdatascience.com/understanding-the-bias-variance-tradeoff-165e6942b229>.

Skrondal, A., & Rabe-Hesketh, S. (2007). Latent Variable Modelling: A Survey. *Scandinavian Journal of Statistics*, 34(4), 712–745. <https://doi.org/10.1111/j.1467-9469.2007.00573.x>

Soderborg, S. (2019). Indonesia: How the polls are performing. *New Mandala*.

Spellman, B., Gilbert, E. A., & Corker, K. S. (2017). *Open Science: What, Why, and How*

(Preprint). PsyArXiv. <https://doi.org/10.31234/osf.io/ak6jr>

Stagge, J. H., Rosenberg, D. E., Abdallah, A. M., Akbar, H., Attallah, N. A., & James, R. (2019).

Assessing data availability and research reproducibility in hydrology and water resources.

Scientific Data, 6(1), 1–12. <https://doi.org/10.1038/sdata.2019.30>

Stein, M. M., Smith, E. M., & Holmes, N. G. (2018). Confirming what we know: Understanding questionable research practices in intro physics labs. *arXiv:1807.04716 [Physics]*.

Retrieved from <http://arxiv.org/abs/1807.04716>

Stone, S., Johnson, K. M., Beall, E., Meindl, P., Smith, B., & Graham, J. (2014). Political psychology. *Wiley Interdisciplinary Reviews: Cognitive Science*, 5(4), 373–385.

<https://doi.org/10.1002/wcs.1293>

Symonds, J. E., & Gorard, S. (2010). Death of mixed methods? Or the rebirth of research as a craft. *Evaluation & Research in Education*, 23(2), 121–136.

<https://doi.org/10.1080/09500790.2010.483514>

- Tijdink, J. K., Verbeke, R., & Smulders, Y. M. (2014). Publication pressure and scientific misconduct in medical scientists. *Journal of Empirical Research on Human Research Ethics*, 9(5), 64–71. <https://doi.org/10.1177/1556264614552421>
- van Aert, R. C. M. (2019). Meta-analysis and publication bias. Rotterdam, Netherlands.
- Vankov, I., Bowers, J., & Munafò, M. R. (2014). On the persistence of low power in psychological science. *The Quarterly Journal of Experimental Psychology*, 67(5), 1037–1040. <https://doi.org/10.1080/17470218.2014.885986>
- Veldkamp, C. L. S., Bakker, M., van Assen, M. A. L. M., Cromptvoets, E. A. V., Ong, H. H., Nosek, B. A., ... Wicherts, J. M. (2018). *Ensuring the quality and specificity of preregistrations* (Preprint). PsyArXiv. <https://doi.org/10.31234/osf.io/cdgyh>
- Wampold, B. E., Ahn, H., & Kim, D. (2000). Meta-analysis in the social sciences: *Asia Pacific Education Review*, 1(1), 67–74. <https://doi.org/10.1007/BF03026147>
- Wilkinson, M. D., Dumontier, M., Aalbersberg, I. J., Appleton, G., Axton, M., Baak, A., ... Mons, B. (2016). The FAIR Guiding Principles for scientific data management and stewardship. *Scientific Data*, 3, 160018. <https://doi.org/10.1038/sdata.2016.18>
- Wynd, C. A., Schmidt, B., & Schaefer, M. A. (2003). Two Quantitative Approaches for Estimating Content Validity. *Western Journal of Nursing Research*, 25(5), 508–518. <https://doi.org/10.1177/0193945903252998>
- Yong, E. (2018). Psychology's Replication Crisis Is Running Out of Excuses. *The Atlantic*. <https://www.theatlantic.com/science/archive/2018/11/psychologys-replication-crisis-real/576223/>.

- Zhou, S., Page-Gould, E., Aron, A., Moyer, A., & Hewstone, M. (2019). The Extended Contact Hypothesis: A Meta-Analysis on 20 Years of Research. *Personality and Social Psychology Review*, 23(2), 132–160. <https://doi.org/10.1177/1088868318762647>
- Zlowodzki, M., Poolman, R. W., Kerkhoffs, G. M., Tornetta, P., & Bhandari, M. (2007). How to interpret a meta-analysis and judge its value as a guide for clinical practice. *Acta Orthopaedica*, 78(5), 598–609. <https://doi.org/10.1080/17453670710014284>
- Alderson, P. (2004). Absence of evidence is not evidence of absence. *BMJ : British Medical Journal*, 328(7438), 476–477.
- Appelbaum, M., Cooper, H., Kline, R. B., Mayo-Wilson, E., Nezu, A. M., & Rao, S. M. (2018). Journal article reporting standards for quantitative research in psychology: The APA Publications and Communications Board task force report. *American Psychologist*, 73(1), 3–25. <https://doi.org/10.1037/amp0000191>
- Barnett, A., Fraser, H., Parker, T. H., Nakagawa, S., & Fidler, F. (2018). Questionable Research Practices (QRPs) in Ecology and Evolution. *PLoS ONE*, 13(7), e0200303. <https://doi.org/10.1371/journal.pone.0200303>
- Bethlehem, J. (2010). Selection Bias in Web Surveys: Selection Bias in Web Surveys. *International Statistical Review*, 78(2), 161–188. <https://doi.org/10.1111/j.1751-5823.2010.00112.x>
- Biemer, P. P. (2010). Total Survey Error: Design, Implementation, and Evaluation. *Public Opinion Quarterly*, 74(5), 817–848. <https://doi.org/10.1093/poq/nfq058>
- Borenstein, M., Hedges, L. V., Higgins, J. P. T., & Rothstein, H. R. (2009). Meta-Regression.

- Bornstein, R. F. (2011). Toward a process-focused model of test score validity: Improving psychological assessment in science and practice. *Psychological Assessment, 23*(2), 532–544. <https://doi.org/10.1037/a0022402>
- Camerer, C. F., Dreber, A., Forsell, E., Ho, T.-H., Huber, J., Johannesson, M., ... Wu, H. (2016). Evaluating replicability of laboratory experiments in economics. *Science, 351*(6280), 1433–1436. <https://doi.org/10.1126/science.aaf0918>
- Chan, M.-p. S., Jones, C. R., Hall Jamieson, K., & Albarracín, D. (2017). Debunking: A Meta-Analysis of the Psychological Efficacy of Messages Countering Misinformation. *Psychological Science, 28*(11), 1531–1546. <https://doi.org/10.1177/0956797617714579>
- Cho, E. (2016). Making Reliability Reliable: A Systematic Approach to Reliability Coefficients. *Organizational Research Methods, 19*(4), 651–682. <https://doi.org/10.1177/1094428116656239>
- Cohen, J. (1988). *Statistical Power Analysis for the Behavioral Sciences* (2nd ed.). Hillsdale, NJ: Lawrence Erlbaum Associates, Inc.
- Cohen, J. (1992). A Power Primer. *Psychological Bulletin, 112*(1), 155. <https://doi.org/10.1038/141613a0>
- Cohen, J. (1994). The earth is round ($p < 0.05$). *American Psychologist, 49*(12), 997–1003. <https://doi.org/10.1037/0003-066X.50.12.1103>
- Committee on Reproducibility and Replicability in Science, Board on Behavioral, Cognitive, and Sensory Sciences, Committee on National Statistics, Division of Behavioral and Social Sciences and Education, Nuclear and Radiation Studies Board, Division on Earth and Life

- Studies, ... National Academies of Sciences, Engineering, and Medicine. (2019). *Reproducibility and Replicability in Science*. Washington, D.C.: National Academies Press. <https://doi.org/10.17226/25303>
- Cooper, M. M. (2018). The Replication Crisis and Chemistry Education Research. *Journal of Chemical Education*, 95(1), 1–2. <https://doi.org/10.1021/acs.jchemed.7b00907>
- Cronbach, L. J., & Meehl, P. E. (1955). Construct Validity in Psychological Test. *Psychological Bulletin*, 52(4), 281–302.
- Dalton, D. R., Aguinis, H., Dalton, C. M., Bosco, F. A., & Pierce, C. A. (2012). REVISITING THE FILE DRAWER PROBLEM IN META-ANALYSIS: AN ASSESSMENT OF PUBLISHED AND NONPUBLISHED CORRELATION MATRICES: PERSONNEL PSYCHOLOGY. *Personnel Psychology*, 65(2), 221–249. <https://doi.org/10.1111/j.1744-6570.2012.01243.x>
- Darley, J. M., & Latané, B. (1968). Bystander intervention in emergencies: Diffusion of responsibility. *Journal of Personality and Social Psychology*, 8(4), 377–383. <https://doi.org/10.1037/h0025589>
- Davis, N. (2017). The Goldwater rule: Why commenting on mental health from a distance is unhelpful. *The Guardian*.
- Davis, R. J. (2014). Reproducibility Project: Cancer Biology. *eLife*. <https://elifesciences.org/collections/9b1e83d1/reproducibility-project-cancer-biology>.
- Deming, W. E. (1944). On Errors in Surveys. *American Sociological Review*, 9(4), 359–369.
- Dienes, Z. (2008). *Understanding psychology as a science*. London: Palgrave Macmillan.

- Donsbach, W. (2015). Public Opinion Polls. In G. Mazzoleni (Ed.), *The International Encyclopedia of Political Communication*. New York: Wiley-Blackwell.
- Dorey, F. J. (2011). In Brief: Statistics in Brief: Statistical Power: What Is It and When Should It Be Used? *Clinical Orthopaedics and Related Research*, 469(2), 619–620.
<https://doi.org/10.1007/s11999-010-1435-0>
- Duckitt, J. (2001). A dual-process cognitive-motivational theory of ideology and prejudice. In *Advances in experimental social psychology* (Vol. 33, pp. 41–113).
[https://doi.org/10.1016/S0065-2601\(01\)80004-6](https://doi.org/10.1016/S0065-2601(01)80004-6)
- Dumenci, L. (2000). Multitrait-Multimethod Analysis. In H. E. A. Tinsley & S. D. Brown (Eds.), *Handbook of Applied Multivariate Statistics and Mathematical Modeling* (pp. 583–611). San Diego: Elsevier. <https://doi.org/10.1016/B978-0-12-691360-6.X5000-9>
- Dunn, T. J., Baguley, T., & Brunnsden, V. (2014). From alpha to omega: A practical solution to the pervasive problem of internal consistency estimation. *British Journal of Psychology*, 105(3), 399–412. <https://doi.org/10.1111/bjop.12046>
- Erişen, C., Erişen, E., & Özkeçeci-Taner, B. (2013). Research Methods in Political Psychology. *Turkish Studies*, 14(1), 13–33. <https://doi.org/10.1080/14683849.2013.766979>
- Errington, T. (2019). Reproducibility Project: Cancer Biology - Barriers to Replicability in the Process of Research. Stanford University.
- Fanelli, D. (2012). Negative results are disappearing from most disciplines and countries. *Scientometrics*, 90(3), 891–904. <https://doi.org/10.1007/s11192-011-0494-7>

Fanelli, D. (2018). Opinion: Is science really facing a reproducibility crisis, and do we need it to?

Proceedings of the National Academy of Sciences, 115(11), 2628–2631.

<https://doi.org/10.1073/pnas.1708272114>

Fealy, G. (2014). Resurgent political Islam, or astute Islamic parties? *New Mandala*.

Fowler, F. J. (2014). *Survey research methods* (Fifth edition). Los Angeles: SAGE.

Fried, E. I., & Flake, J. K. (2018). Measurement Matters. *APS Observer*, 31(3).

Gaines, B. J., Kuklinski, J. H., & Quirk, P. J. (2007). The Logic of the Survey Experiment

Reexamined. *Political Analysis*, 15(1), 1–20. <https://doi.org/10.1093/pan/mpi008>

Garrison, K. E., Tang, D., & Schmeichel, B. J. (2016). Embodying Power: A Preregistered

Replication and Extension of the Power Pose Effect. *Social Psychological and Personality*

Science, 7(7), 623–630. <https://doi.org/10.1177/1948550616652209>

Gawronski, B., Galdi, S., & Arcuri, L. (2015). What Can Political Psychology Learn from

Implicit Measures? Empirical Evidence and New Directions: Implicit Measures in

Political Psychology. *Political Psychology*, 36(1), 1–17.

<https://doi.org/10.1111/pops.12094>

Giorgi, A. (2012). The descriptive phenomenological psychological method. *Journal of*

Phenomenological Psychology, 43(1), 3–12. <https://doi.org/10.1163/156916212X632934>

Goodman, S. N., Fanelli, D., & Ioannidis, J. P. A. (2016). What does research reproducibility mean? *Science Translational Medicine*, 8(341), 341ps12–341ps12.

<https://doi.org/10.1126/scitranslmed.aaf5027>

Greenland, S., Senn, S. J., Rothman, K. J., Carlin, J. B., Poole, C., Goodman, S. N., & Altman, D.

G. (2016). Statistical tests, P values, confidence intervals, and power: A guide to misinterpretations. *European Journal of Epidemiology*, *31*(4), 337–350.

<https://doi.org/10.1007/s10654-016-0149-3>

Groves, R. M., & Lyberg, L. (2010). Total Survey Error: Past, Present, and Future. *Public*

Opinion Quarterly, *74*(5), 849–879. <https://doi.org/10.1093/poq/nfq065>

Hagger, M. S., Chatzisarantis, N. L. D., Alberts, H., Anggono, C. O., Batailler, C., Birt, A. R., ...

Zwienenberg, M. (2016). A Multilab Preregistered Replication of the Ego-Depletion Effect. *Perspectives on Psychological Science*, *11*(4), 546–573.

<https://doi.org/10.1177/1745691616652873>

Hammack, P. L., & Pilecki, A. (2014). Methodological approaches in political psychology:

Discourse and narrative. In *The Palgrave Handbook of Global Political Psychology* (pp. 72–89). London: Palgrave Macmillan.

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.

<https://doi.org/10.1371/journal.pbio.1002106>

Hendry, L. B., Mayer, P., & Kloep, M. (2007). Belonging or Opposing? A Grounded Theory

Approach to Young People's Cultural Identity in a Majority/Minority Societal Context.

Identity, *7*(3), 181–204. <https://doi.org/10.1080/15283480709336930>

- Hidayat, R. (2018). Rawan Kepentingan: Campur Aduk Lembaga Survei & Jasa Konsultan. *tirto.id*. <https://tirto.id/rawan-kepentingan-campur-aduk-lembaga-survei-jasa-konsultan-cJkL>.
- HIMPSI. (2010). *Kode Etik Psikologi Indonesia* (Pertama (Kongres XI HIMPSI 2010)). Jakarta: Pengurus Pusat Himpunan Psikologi Indonesia (HIMPSI).
- Hollenbeck, J. R., & Wright, P. M. (2017). Harking, Sharking, and Tharking: Making the Case for Post Hoc Analysis of Scientific Data. *Journal of Management*, *43*(1), 5–18. <https://doi.org/10.1177/0149206316679487>
- Hunsley, J., & Meyer, G. J. (2003). The Incremental Validity of Psychological Testing and Assessment: Conceptual, Methodological, and Statistical Issues. *Psychological Assessment*, *15*(4), 446–455. <https://doi.org/10.1037/1040-3590.15.4.446>
- Intan, G. (2019). Dituduh Tukang Bohong, Lembaga Survei Ungkap Data dan Metodologi Quick Count. *VOA Indonesia*. <https://www.voaindonesia.com/a/dituduh-tukang-bohong-lembaga-survei-ungkap-data-dan-metodologi-quick-count/4885243.html>.
- Ioannidis, J. P. A. (2018). Meta-research: Why research on research matters. *PLOS Biology*, *16*(3), e2005468. <https://doi.org/10.1371/journal.pbio.2005468>
- Isani, M., & Silverman, D. (2016). Foreign Policy Attitudes toward Islamic Actors: An Experimental Approach. *Political Research Quarterly*, *69*(3), 571–582. <https://doi.org/10.1177/1065912916654988>

Israel, H., & Richter, R. R. (2011). A Guide to Understanding Meta-analysis. *Journal of Orthopaedic & Sports Physical Therapy*, *41*(7), 496–504.

<https://doi.org/10.2519/jospt.2011.3333>

John, L. K., Loewenstein, G., & Prelec, D. (2012). Measuring the Prevalence of Questionable Research Practices With Incentives for Truth Telling. *Psychological Science*, *23*(5), 524–532. <https://doi.org/10.1177/0956797611430953>

Jost, J. T. (2019). The IAT Is Dead, Long Live the IAT: Context-Sensitive Measures of Implicit Attitudes Are Indispensable to Social and Political Psychology. *Current Directions in Psychological Science*, *28*(1), 10–19. <https://doi.org/10.1177/0963721418797309>

Kaarbo, J., & Beasley, R. K. (1999). A Practical Guide to the Comparative Case Study Method in Political Psychology. *Political Psychology*, *20*(2), 369–391. <https://doi.org/10.1111/0162-895X.00149>

Kelley, K., & Preacher, K. J. (2012). On effect size. *Psychological Methods*, *17*(2), 137–152. <https://doi.org/10.1037/a0028086>

Khan, K. S. (2003). Five Steps to Conducting a Systematic Review, *96*, 4.

Klein, R. A., Cook, C. L., Ebersole, C. R., Vitiello, C. A., Nosek, B. A., Chartier, C. R., ... Ratliff, K. A. (2019). *Many Labs 4: Failure to Replicate Mortality Salience Effect With and Without Original Author Involvement* (Preprint). PsyArXiv.

<https://doi.org/10.31234/osf.io/vef2c>

- Lilienfeld, S. O., Miller, J. D., & Lynam, D. R. (2018). The Goldwater Rule: Perspectives From, and Implications for, Psychological Science. *Perspectives on Psychological Science*, *13*(1), 3–27. <https://doi.org/10.1177/1745691617727864>
- Lupia, A., & Elman, C. (2014). Openness in Political Science: Data Access and Research Transparency. *PS: Political Science & Politics*, *47*(01), 19–42. <https://doi.org/10.1017/S1049096513001716>
- Mair, P. (2018). *Modern Psychometrics with R*. Cham: Springer International Publishing. <https://doi.org/10.1007/978-3-319-93177-7>
- Maris, E. (1995). Psychometric latent response models. *Psychometrika*, *60*(4), 523–547.
- Mayr, S., Buchner, A., Erdfelder, E., & Faul, F. (2007). A short tutorial of GPower. *Tutorials in Quantitative Methods for Psychology*, *3*(2), 51–59. <https://doi.org/10.1037/0096-1523.32.4.932>
- McAdams, D. P., Albaugh, M., Farber, E., Daniels, J., Logan, R. L., & Olson, B. (2008). Family metaphors and moral intuitions: How conservatives and liberals narrate their lives. *Journal of Personality and Social Psychology*, *95*(4), 978–990. <https://doi.org/10.1037/a0012650>
- McNally, R. J. (2018). Diagnosing at a Distance: Is the Goldwater Rule Still Relevant Today? *Perspectives on Psychological Science*, *13*(1), 28–30. <https://doi.org/10.1177/1745691617731636>
- McNeish, D. (2018). Thanks coefficient alpha, we'll take it from here. *Psychological Methods*, *23*(3), 412–433. <https://doi.org/10.1037/met0000144>

- Messick, S. (1995). Validity of Psychological Assessment. *American Psychologist*, 9.
- Mietzner, M. (2009). Political opinion polling in post-authoritarian Indonesia: Catalyst or obstacle to democratic consolidation? *Bijdragen Tot de Taal-, Land- En Volkenkunde / Journal of the Humanities and Social Sciences of Southeast Asia*, 165(1), 95–126.
<https://doi.org/10.1163/22134379-90003644>
- Moher, D., Shamseer, L., Clarke, M., Ghersi, D., Liberati, A., Petticrew, M., ... PRISMA-P Group. (2015). Preferred reporting items for systematic review and meta-analysis protocols (PRISMA-P) 2015 statement. *Systematic Reviews*, 4(1), 1.
<https://doi.org/10.1186/2046-4053-4-1>
- Morling, B. (2018). *Research Methods in Psychology: Evaluating a World of Information* (3rd ed.). New York, NY: W. W. Norton & Company, Inc.
- Mullinix, K. J., Leeper, T. J., Druckman, J. N., & Freese, J. (2015). The Generalizability of Survey Experiments. *Journal of Experimental Political Science*, 2(2), 109–138.
<https://doi.org/10.1017/XPS.2015.19>
- Nosek, B. A., Ebersole, C. R., DeHaven, A. C., & Mellor, D. T. (2018). The preregistration revolution. *Proceedings of the National Academy of Sciences*, 2017(15), 201708274.
<https://doi.org/10.1073/pnas.1708274114>
- Open Science Collaboration. (2015). Estimating the reproducibility of psychological science. *Science*, 349(6251), aac4716–aac4716. <https://doi.org/10.1126/science.aac4716>

- Panagiotakos, D. B. (2008). The Value of p-Value in Biomedical Research. *The Open Cardiovascular Medicine Journal*, 2(1), 97–99.
<https://doi.org/10.2174/1874192400802010097>
- Parackal, M., Mather, D., & Holdsworth, D. (2018). Value-based prediction of election results using natural language processing: A case of the New Zealand General Election. *International Journal of Market Research*, 60(2), 156–168.
<https://doi.org/10.1177/1470785318762234>
- Perezgonzalez, J. D. (2015). Fisher, Neyman-Pearson or NHST? A tutorial for teaching data testing. *Frontiers in Psychology*, 6(MAR), 1–11.
<https://doi.org/10.3389/fpsyg.2015.00223>
- Peters, G. J. Y. (2018). *The alpha and the omega of scale reliability and validity: Why and how to abandon Cronbach's alpha and the route towards more comprehensive assessment of scale quality* (Preprint). PsyArXiv. <https://doi.org/10.31234/osf.io/h47fv>
- Peters, J. L., Sutton, A. J., Jones, D. R., Abrams, K. R., & Rushton, L. (2008). Contour-enhanced meta-analysis funnel plots help distinguish publication bias from other causes of asymmetry. *Journal of Clinical Epidemiology*, 61(10), 991–996.
<https://doi.org/10.1016/j.jclinepi.2007.11.010>
- Price, P. C., Jhangiani, R. S., Chiang, I.-C. A., Leighton, D. C., & Cuttler, C. (2017). *Research Methods in Psychology* (3rd ed.). Pullman: Washington State University.

- Prinz, F., Schlange, T., & Asadullah, K. (2011). Believe it or not: How much can we rely on published data on potential drug targets? *Nature Reviews Drug Discovery*, *10*(9), 712–712. <https://doi.org/10.1038/nrd3439-c1>
- Quintana, D. (2019). Synthetic datasets: A non-technical primer for the behavioural sciences to promote reproducibility and hypothesis-generation. <https://doi.org/10.31234/osf.io/dmfb3>
- Revelle, W., & Zinbarg, R. E. (2008). Coefficients Alpha, Beta, Omega, and the glb: Comments on Sijtsma. *Psychometrika*, *74*(1), 145. <https://doi.org/10.1007/s11336-008-9102-z>
- Rheault, L., Beelen, K., Cochrane, C., & Hirst, G. (2016). Measuring Emotion in Parliamentary Debates with Automated Textual Analysis. *PLOS ONE*, *11*(12). <https://doi.org/10.1371/journal.pone.0168843>
- Ritchie, S. J., Wiseman, R., & French, C. C. (2012). Failing the Future: Three Unsuccessful Attempts to Replicate Bem’s “Retroactive Facilitation of Recall” Effect. *PLOS ONE*, *7*(3), e33423. <https://doi.org/10.1371/journal.pone.0033423>
- Rodgers, M. A., & Pustejovsky, J. E. (2019). *Evaluating Meta-Analytic Methods to Detect Selective Reporting in the Presence of Dependent Effect Sizes* (Preprint). MetaArXiv. <https://doi.org/10.31222/osf.io/vqp8u>
- Rothstein, H., Sutton, A. J., & Borenstein, M. (Eds.). (2005). *Publication bias in meta-analysis: Prevention, assessment and adjustments*. Chichester, England ; Hoboken, NJ: Wiley.
- Rubio, D. M., Berg-Weger, M., Tebb, S. S., Lee, E. S., & Rauch, S. (2003). Objectifying content validity: Conducting a content validity study in social work research. *Social Work Research*, *27*(2), 94–104. <https://doi.org/10.1093/swr/27.2.94>

- Ruel, E. E., Wagner, W. E., & Gillespie, B. J. (2016). *The practice of survey research: Theory and applications*. Thousand Oaks, CA: Sage Publications, Inc.
- Sandve, G. K., Nekrutenko, A., Taylor, J., & Hovig, E. (2013). Ten Simple Rules for Reproducible Computational Research. *PLOS Computational Biology*, 9(10), e1003285. <https://doi.org/10.1371/journal.pcbi.1003285>
- Schafer, M. (2000). Issues in Assessing Psychological Characteristics at a Distance: An Introduction to the Symposium. *Political Psychology*, 21(3), 511–527. <https://doi.org/10.1111/0162-895X.00201>
- Schoonvelde, M., Schumacher, G., & Bakker, B. N. (2019). Friends With Text as Data Benefits: Assessing and Extending the Use of Automated Text Analysis in Political Science and Political Psychology. *Journal of Social and Political Psychology*, 7(1), 124–143–143. <https://doi.org/10.5964/jspp.v7i1.964>
- Shaughnessy, J. J., Zechmeister, E. B., & Zechmeister, J. S. (2012). *Research methods in psychology* (9th ed). New York, NY: McGraw-Hill.
- Sijtsma, K. (2008). On the Use, the Misuse, and the Very Limited Usefulness of Cronbach's Alpha. *Psychometrika*, 74(1), 107. <https://doi.org/10.1007/s11336-008-9101-0>
- Silberzahn, R., Uhlmann, E. L., Martin, D. P., Anselmi, P., Aust, F., Awtrey, E., ... Nosek, B. A. (2018). Many Analysts, One Data Set: Making Transparent How Variations in Analytic Choices Affect Results: *Advances in Methods and Practices in Psychological Science*. <https://doi.org/10.1177/2515245917747646>

- 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. <https://doi.org/10.1177/0956797611417632>
- Simonsohn, U., Nelson, L. D., & Simmons, J. P. (2014). P-Curve and Effect Size: Correcting for Publication Bias Using Only Significant Results. *Perspectives on Psychological Science*, 9(6), 666–681. <https://doi.org/10.1177/1745691614553988>
- Singh, S. (2018). Understanding the Bias-Variance Tradeoff. *Medium*.
<https://towardsdatascience.com/understanding-the-bias-variance-tradeoff-165e6942b229>.
- Skrondal, A., & Rabe-Hesketh, S. (2007). Latent Variable Modelling: A Survey. *Scandinavian Journal of Statistics*, 34(4), 712–745. <https://doi.org/10.1111/j.1467-9469.2007.00573.x>
- Soderborg, S. (2019). Indonesia: How the polls are performing. *New Mandala*.
- Spellman, B., Gilbert, E. A., & Corker, K. S. (2017). *Open Science: What, Why, and How* (Preprint). PsyArXiv. <https://doi.org/10.31234/osf.io/ak6jr>
- Stagge, J. H., Rosenberg, D. E., Abdallah, A. M., Akbar, H., Attallah, N. A., & James, R. (2019). Assessing data availability and research reproducibility in hydrology and water resources. *Scientific Data*, 6(1), 1–12. <https://doi.org/10.1038/sdata.2019.30>
- Stein, M. M., Smith, E. M., & Holmes, N. G. (2018). Confirming what we know: Understanding questionable research practices in intro physics labs. *arXiv:1807.04716 [Physics]*.
Retrieved from <http://arxiv.org/abs/1807.04716>

- Stone, S., Johnson, K. M., Beall, E., Meindl, P., Smith, B., & Graham, J. (2014). Political psychology. *Wiley Interdisciplinary Reviews: Cognitive Science*, 5(4), 373–385.
<https://doi.org/10.1002/wcs.1293>
- Symonds, J. E., & Gorard, S. (2010). Death of mixed methods? Or the rebirth of research as a craft. *Evaluation & Research in Education*, 23(2), 121–136.
<https://doi.org/10.1080/09500790.2010.483514>
- Tijdink, J. K., Verbeke, R., & Smulders, Y. M. (2014). Publication pressure and scientific misconduct in medical scientists. *Journal of Empirical Research on Human Research Ethics*, 9(5), 64–71. <https://doi.org/10.1177/1556264614552421>
- van Aert, R. C. M. (2019). Meta-analysis and publication bias. Rotterdam, Netherlands.
- Vankov, I., Bowers, J., & Munafò, M. R. (2014). On the persistence of low power in psychological science. *The Quarterly Journal of Experimental Psychology*, 67(5), 1037–1040. <https://doi.org/10.1080/17470218.2014.885986>
- Veldkamp, C. L. S., Bakker, M., van Assen, M. A. L. M., Cromptoets, E. A. V., Ong, H. H., Nosek, B. A., ... Wicherts, J. M. (2018). *Ensuring the quality and specificity of preregistrations* (Preprint). PsyArXiv. <https://doi.org/10.31234/osf.io/cdgyh>
- Wampold, B. E., Ahn, H., & Kim, D. (2000). Meta-analysis in the social sciences: *Asia Pacific Education Review*, 1(1), 67–74. <https://doi.org/10.1007/BF03026147>
- Wilkinson, M. D., Dumontier, M., Aalbersberg, I. J., Appleton, G., Axton, M., Baak, A., ... Mons, B. (2016). The FAIR Guiding Principles for scientific data management and stewardship. *Scientific Data*, 3, 160018. <https://doi.org/10.1038/sdata.2016.18>

- Wynd, C. A., Schmidt, B., & Schaefer, M. A. (2003). Two Quantitative Approaches for Estimating Content Validity. *Western Journal of Nursing Research*, 25(5), 508–518. <https://doi.org/10.1177/0193945903252998>
- Yong, E. (2018). Psychology's Replication Crisis Is Running Out of Excuses. *The Atlantic*. <https://www.theatlantic.com/science/archive/2018/11/psychologys-replication-crisis-real/576223/>.
- Zhou, S., Page-Gould, E., Aron, A., Moyer, A., & Hewstone, M. (2019). The Extended Contact Hypothesis: A Meta-Analysis on 20 Years of Research. *Personality and Social Psychology Review*, 23(2), 132–160. <https://doi.org/10.1177/1088868318762647>
- Zlowodzki, M., Poolman, R. W., Kerkhoffs, G. M., Tornetta, P., & Bhandari, M. (2007). How to interpret a meta-analysis and judge its value as a guide for clinical practice. *Acta Orthopaedica*, 78(5), 598–609. <https://doi.org/10.1080/17453670710014284>