

Desenho de pesquisa, inferência e causalidade em Ciência Política

Research design, inference and causality in Political Science

Renan Holanda Montenegro¹

Resumo: O objetivo deste artigo é apresentar uma breve contribuição sobre três tópicos importantes para a consecução de uma pesquisa bem embasada em Ciência Política: desenho de pesquisa, inferência e causalidade. Estudantes na fase inicial de treinamento em metodologia de pesquisa aplicada à Ciência Política são o público-alvo do texto. O que é e como desenvolver um desenho de pesquisa adequado? Como realizar inferências válidas? É possível identificar causalidade entre variáveis nas investigações sociais e políticas? Por meio de uma descrição da importância de cada um desses componentes dentro da pesquisa em Ciência Política, discutimos as principais contribuições que a literatura sobre o tema tem levantado.

Palavras-chave: Metodologia; Inferência; Causalidade; Ciência Política.

Abstract: The aim of this paper is to present a contribution on three important topics for achieving a well-grounded research in Political Science: research design, inference and causality. Students in initial phase of training in research methodology applied to Political Science are the target audience of the text. What it is and how to develop an appropriate research design? How to draw valid inferences? Is it possible to identify causality between variables in social and political investigations? Through a description of the importance of each of these components within the research in Political Science, we discuss the main contributions raised by the literature on the subject.

Keywords: Methodology; Inference; Causality; Political Science.

¹ Mestre em Relações Internacionais (UERJ) e doutorando em Ciência Política (UFPE). E-mail: renanholanda@bol.com.br.

1. Introdução

Quais os elementos constitutivos de uma teoria? Existe um passo a passo que garanta a formulação de teorias robustas? Como desenvolver um desenho de pesquisa eficiente? Quais métodos são mais adequados para os fins de uma pesquisa? Como realizar inferências causais? Perguntas desse tipo têm dominado as discussões metodológicas no campo da Ciência Política há algumas décadas. No Brasil, entretanto, tal debate ainda se mostra incipiente. Há lacunas importantes na formação metodológica dos pesquisadores nacionais, tanto na tradição quantitativa quanto na qualitativa. O quadro tem mudado ao longo dos últimos anos, mas ainda há muito a ser feito. O objetivo deste trabalho é, assim, apresentar uma contribuição no sentido de preencher esses espaços.

Em conhecido artigo sobre o assunto, Soares (2005) nota que os cientistas políticos brasileiros não se ancoram em nenhuma das tradições quali ou quanti, mas simplesmente desprezam o método. A grande parte dos trabalhos publicados nas revistas nacionais, explica o autor, não é quantitativa, não é qualitativa: são ensaios. Seguindo a mesma linha, Valle Silva (1999), ao realizar análise minuciosa sobre o teor dos artigos publicados na Revista Brasileira de Ciências Sociais, constatou que apenas oito deles apresentavam alguma análise quantitativa. Com relação aos autores destes artigos, sete tinham alguma formação realizada nos Estados Unidos, local onde o desenvolvimento da área de métodos se mostra mais pujante.

Dado esse cenário, o presente artigo busca apresentar uma breve contribuição sobre três componentes de reconhecida importância para a consecução de uma pesquisa com algum embasamento científico na área de Ciência Política: desenho de pesquisa, inferência e causalidade. O que é e como desenvolver um desenho de pesquisa adequado? Como realizar inferências válidas? É possível identificar causalidade entre variáveis?

Nas próximas seções, descrevemos a importância de cada um desses componentes dentro da pesquisa em Ciência Política e apresentamos as

principais contribuições que a literatura sobre o tema tem levantado. Por fim, tecemos algumas considerações finais. Nossa abordagem metodológica é essencialmente descritiva, ancorada em uma revisão bibliográfica sobre o assunto, reunindo as recomendações mais frequentes fornecidas pelos especialistas. O público-alvo são os estudantes em fase inicial de treinamento na área de metodologia de pesquisa aplicada à Ciência Política.

2. Desenho de pesquisa

Após a publicação do seminal trabalho *Designing Social Inquiry*, em 1994, os autores King, Keohane e Verba (comumente mencionados como KKV) participaram de um seminário realizado exclusivamente para debater as contribuições do livro. Para responderem as questões levantadas na ocasião, o trio publicou um texto ressaltando a importância do desenho de pesquisa na Ciência Política (King, Keohane & Verba, 1995). De acordo com eles, o desenho de pesquisa deve ser uma prioridade para a disciplina.

Essa afirmação é particularmente relevante para a Ciência Política devido a um problema central: a relativa impossibilidade de realizar estudos experimentais na área². Guardadas algumas exceções, a literatura sobre metodologia política e estatística aplicada trata os dados e os problemas deles derivados como questões dadas. Ao focar apenas na realização de inferências, essa literatura ignora a importância do desenho de pesquisa para os estudos observacionais. Questões relacionadas à realização de inferências, contudo, serão abordadas mais à frente.

O que diferencia um estudo experimental de um estudo observacional? Para fins de esclarecimento, um estudo experimental (ou experimento) é aquele no qual o pesquisador pode manipular as variáveis diretamente. Geralmente, mas não exclusivamente, acontecem em laboratórios. Eis um exemplo comum

² Para uma discussão mais aprofundada sobre desenhos de pesquisa experimentais em Ciência Política, ver Morton e Williams (2008).

de experimento: um cientista que testa a eficácia de alguma substância manipulando grupos (de animais, de plantas, etc.), realizando uma divisão entre os que receberam a substância, o chamado grupo de tratamento, e os que não receberam, o grupo de controle.

Nas Ciências Sociais, esse tipo de condução de pesquisa é relativamente mais difícil de se perseguir, seja por questões éticas ou por impossibilidade material. Não é plausível pensar que se pode testar a eficácia de uma política pública atribuindo arbitrariamente grupos que serão ou não beneficiados³. Sendo assim, a grande maioria das pesquisas sociais é constituída por estudos observacionais, pois não há manipulação direta das variáveis. O investigador se limita a observar os dados e, a partir deles, construir modelos para realizar inferências e previsões.

Ainda há uma terceira categoria de desenho de pesquisa: os estudos quase-experimentais. São aqueles em que não há atribuição aleatória, caso dos estudos experimentais. Isso significa que a amostra utilizada não foi selecionada de maneira randomizada. Com isso, a inferência de relações causais fica mais difícil e, conseqüentemente, a generalização das conclusões é facilmente contestada. Os estudos quase-experimentais, todavia, costumam apresentar mais informações. Em geral, são realizadas várias medições ao longo do tempo. Nesse tipo de estudo, o pesquisador observa um ou mais casos antes ou depois do que se pensa como um “tratamento”, por meio de alguma mudança na variável explicativa em um determinado momento do tempo. Como exemplo, podemos imaginar um analista político interessado em avaliar uma determinada política pública – Bolsa Família, por exemplo – antes e depois da

³ Acontecimentos da vida real, contudo, podem fornecer os elementos necessários para que um pesquisador possa manipular as variáveis da pesquisa com praticamente o mesmo rigor de um experimento. Um exemplo aconteceu no estado do Oregon, nos Estados Unidos. O governo local ofereceu planos de saúde aleatoriamente aos moradores, numa espécie de loteria. Assim, pesquisadores puderam medir o efeito dos planos na saúde dos que foram sorteados (tratamento) e dos que não foram (controle). Para mais detalhes, ver Angrist e Pischke (2015).

sua execução. Nesse caso, um evento criado por lei ou por força da natureza “cria” um grupo de tratamento.

Przeworski e Teune (1970) notam que estudos que comparam países, por exemplo, frequentemente adotam essa forma quase-experimental. Já King, Keohane e Verba (1994) rejeitam o conceito de quase-experimento. Para eles, um desenho de pesquisa só pode ser de dois tipos: ou o investigador tem controle sobre as observações e os valores das variáveis causais (pesquisa experimental) ou não tem (pesquisa não-experimental). Cada um desses tipos de pesquisa tem suas vantagens e limitações, e nenhum é melhor que o outro.

Como se vê, o desenho de pesquisa exerce papel fundamental na elaboração de um conhecimento científico rigoroso nas Ciências Sociais. O objetivo das Ciências Sociais (a Ciência Política, inclusive), segundo Przeworski e Teune, é explicar o fenômeno social. Mas como generalizar a explicação de fenômenos? Observações históricas específicas podem gerar teorias gerais? A resposta oferecida pela literatura é que sim, é possível desenvolver teorias gerais a partir de contextos específicos. O campo dos estudos comparados (a política comparada) oferece a ponte para unir esses extremos (Przeworski & Teune, 1970; King, Keohane & Verba, 1994).

Lijphart define a disciplina de política comparada (*comparative politics*) como sendo essencialmente preocupada com questões relativas ao “método” na ciência política. Collier define o método comparativo na ciência política como sendo um ramo da área de metodologia caracterizado pela produção sistemática de análise qualitativa, a partir da utilização de uma quantidade reduzida de casos (*small-n*). O traço distintivo do método comparativo, em diferenciação aos modelos experimentais e a análise estatística, seria, portanto, a combinação entre *small-n* e a utilização de análise qualitativa (não exclusivamente). A ciência política comparada mais recente tem estimulado a produção de trabalhos que se valem de múltiplas metodologias, especialmente integrando trabalhos quantitativos e qualitativos, análise estatística e estudos de caso e outras possibilidades disponíveis aos cientistas políticos. (Rezende, 2011. p. 297)

Uma das ferramentas metodológicas mais utilizadas nos desenhos de pesquisa com poucos casos (*small-n*) e, mais especificamente, nos estudos de caso é o process-tracing. Por definição, trata-se de uma ferramenta analítica para traçar inferências causais e descritivas a partir de pedaços de evidências inseridas em uma sequência temporal de eventos (Collier, 2011). As tais evidências essenciais para a consecução do método são chamadas de *causal-process observations* (Brady, Collier & Seawright, 2010).

A acumulação do conhecimento produzido pelos estudos de caso, nesse sentido, consiste em um processo maior de gradual confirmação e modificação de teorias que constituem um esquema explanatório amplo. Em um estágio mais avançado de acumulação de conhecimento científico, é natural que mais de uma teoria possa explicar a mesma classe de eventos. Então, o que devemos ter em mente na hora de avaliar uma teoria? Como testar sua validade?

Przeworski e Teune (1970) explicam que uma teoria deve ser avaliada de acordo com quatro pontos: acurácia, generalidade, parcimônia e causalidade. Em primeiro lugar, espera-se que uma teoria seja acurada porque ele deve explicar o máximo possível de variação. Isso nos leva à sua generalidade: o alcance de fenômenos sociais ao qual a teoria se aplica. Quanto ao terceiro ponto, quanto menor for o número de fatores utilizados para explicar uma dada classe de eventos, mais parcimoniosa é a teoria – ou seja, precisa de pouco para explicar muito. Por fim, a causalidade apresenta-se enquanto propriedade de um sistema de variáveis (uma variável dependente e um conjunto de variáveis explicativas).

Um bom desenho de pesquisa desempenha papel decisivo na produção de inferências válidas sobre fenômenos sociais e políticos. Em linguagem causal: um bom desenho de pesquisa (x) afeta positivamente a produção de inferências/formulação de teorias (y). Uma boa pesquisa é aquela que, antes de tudo, apresenta criteriosa metodologia científica. Sendo assim, uma boa pesquisa pode ter o estilo quantitativo ou qualitativo, mas o desenho da

pesquisa segue uma lógica própria e tem quatro características: 1) o objetivo é realizar inferências; 2) os procedimentos são públicos; 3) as conclusões são incertas; e 4) o conteúdo é o método (King, Keohane & Verba, 1994). O quadro abaixo sumariza essas informações.

Quadro 1. Características de um desenho de pesquisa

Objetivo → Inferência	A pesquisa científica é desenhada para que se faça inferências descritivas ou explanatórias de acordo com as informações empíricas sobre o mundo. Descrições são frequentemente indispensáveis, mas a acumulação de fatos <i>per se</i> não é suficiente
Procedimentos → Públicos	A pesquisa científica utiliza métodos públicos, codificados e explícitos para gerar e analisar dados cuja confiabilidade possa ser avaliada. Se os métodos não são esclarecidos, a comunidade científica não tem meios para julgar a validade do que foi feito.
Conclusões → Incertas	Inferência é um processo imperfeito por definição. Assim sendo, a incerteza é um aspecto central de toda e qualquer pesquisa e conhecimento produzido sobre o mundo.
Conteúdo → Método	A pesquisa científica se assenta em um conjunto de regras de inferência na qual sua validade repousa. O conteúdo da ciência é, primariamente, seus métodos e regras, e não o objeto. Isso porque com métodos rigorosos é possível estudar praticamente qualquer coisa.

Fonte: Elaboração do autor com base em KKV (1994)

Tendo isso em vista, é bom ter em mente que o desenho de pesquisa não é um mero modelo utilizado de forma mecânica para coletar e avaliar dados. Não funciona dessa forma. Cada tipo de pergunta de pesquisa demanda uma intervenção diferente no âmbito do desenho da pesquisa. Não existe um desenho-padrão, adequado para qualquer situação. Sendo assim, os interessados em conectar a teoria com os dados devem estar atentos a algumas

questões. Um desenho de pesquisa indeterminado pode apresentar vários problemas, entre os quais podemos citar: ter mais inferências que observações, variáveis explicativas correlacionadas (multicolinearidade) e viés de seleção⁴.

Além de enumerar as características de um desenho de pesquisa, King, Keohane e Verba (1994) também listam os componentes de um. A saber, são eles: 1) questão de pesquisa; 2) teoria; 3) dados; 4) uso dos dados. Não há uma ordem lógica estabelecida que deve ser seguida, assim como esses componentes não costumam ser desenvolvidos separadamente. Pesquisadores qualitativos, por exemplo, costumam realizar trabalhos de campo antes mesmo de terem uma questão de pesquisa precisa.

Na Ciência Política, um desenho de pesquisa muito comum é aquele que reúne um número limitado de casos, os chamados *small-n*. Não só a quantidade de casos é problemática, mas o próprio critério de seleção desses casos, na maioria das vezes não-aleatório. Por esses e outros fatores, os estudos de caso costumam ser apontados como desenhos de pesquisa problemáticos no que diz respeito à inferência causal. No entanto, muitas contribuições recentes apontam que os estudos de caso podem ser uma espécie de “salvação”. Esse tipo de debate conecta, de forma clara, questões sobre desenho de pesquisa e os tipos de explicação buscados pela comunidade científica em Ciência Política (Rezende, 2011). Rezende (2002), por exemplo, propõe uma explicação para a falha das reformas administrativas por meio de um aprofundado estudo de caso do MARE (Ministério da Administração Federal e Reforma do Estado), criado em 1995 e extinto em 1998.

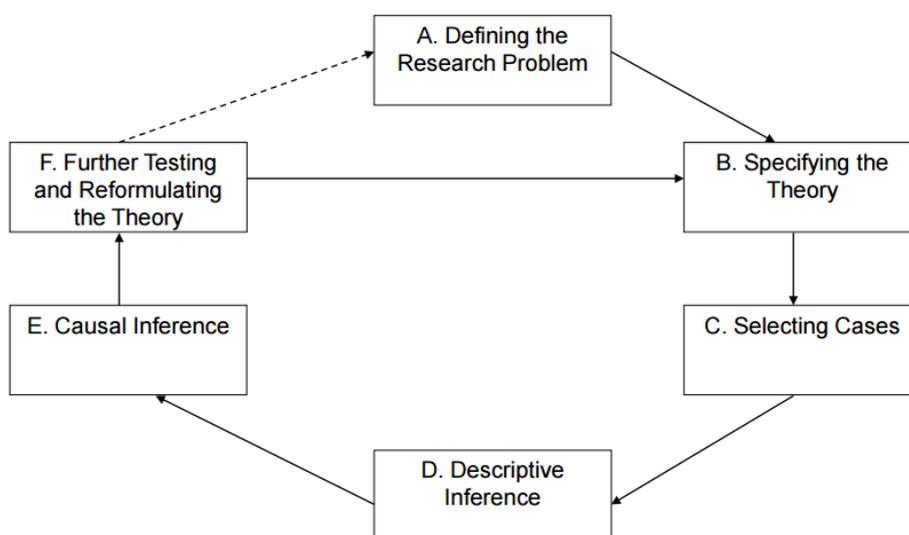
Para atingir um padrão superior de qualidade, os desenhos de pesquisa (inclusive os estudos de caso) devem acessar de forma cuidadosa todos os componentes listados por King, Keohane e Verba. Todavia, como propor e operacionalizar uma boa questão de pesquisa? Alias, o que é uma boa questão

4 Por questões de espaço, este artigo não abordará os problemas mais recorrentes dentro da pesquisa em Ciência Política.

de pesquisa? Como melhorar a teoria? Qual a melhor forma de utilizar os dados? Como utilizá-los de maneira eficiente?

Na figura abaixo – extraída de Collier, Seawright e Munck (2004) – é possível identificar os passos envolvidos em um “ciclo de pesquisa”. Trata-se de um fluxograma que resume as ideias propostas por KKV.

Figura 1. As etapas do ciclo de investigação



Fonte: Brady & Collier (2004)

Note que se trata de um ciclo que nunca se fecha: definir o problema de pesquisa, especificar a teoria, selecionar casos e observações, realizar inferências e, por fim, testar a reformular a teoria existente. Todo o empreendimento científico, coletivo por natureza, repousa sobre essa estrutura. Na figura, as setas mais sólidas (a única exceção é a seta que liga o “teste e reformulação de teorias” à “definição do problema de pesquisa”) mostram os *links* entre as etapas do ciclo. As decisões feitas em qualquer um desses passos podem afetar os passos seguintes.

O quadro abaixo descreve com detalhes as recomendações de King, Keohane e Verba (1994) para se extrair o melhor de todos os quatro

componentes de um desenho de pesquisa. Para uma discussão mais aprofundada sobre cada um desses itens, é extremamente recomendável a leitura completa e atenta da seção 1.2 do *Designing Social Inquiry*.

Quadro 2. O que fazer com os componentes de um desenho de pesquisa

Questão de Pesquisa	A pesquisa deve propor uma pergunta que é importante para o mundo real, que tenha implicações práticas e identificáveis para a vida política social ou econômica. Além disso, a pesquisa deve fazer uma contribuição específica para a literatura sobre o assunto.
Teoria	Escolha teorias que possam estar erradas. Mais que isso, escolha teorias que possam ser falsificáveis, que são aquelas capazes de gerar quantas observações forem necessárias. Seja o mais concreto possível.
Dados	Registre e reporte o processo pelo qual os dados foram gerados. Colete o máximo possível de observações. Maximize a validade das mensurações. Garanta que os métodos são confiáveis. Os dados devem ser replicáveis.
Uso dos dados	Utilize os dados para gerar inferências corretas em média, ou seja, não enviesadas. Maximize a quantidade de informação utilizada para a realização de inferências: faça com que os dados sejam eficientes.

Fonte: Elaboração do autor com base em KKV (1994)

Seguindo a mesma linha, outra fonte interessante de consulta para os interessados em desenvolver um desenho de pesquisa mais robusto é o artigo de Paranhos *et al* (2012). Nele, os autores apresentam dez procedimentos que podem ajudar o pesquisador a melhorar a qualidade do seu desenho de pesquisa – e do empreendimento científico como um todo. Os procedimentos foram extraídos da literatura sobre o assunto e também da experiência de ensino e pesquisa compartilhada pelos autores. As recomendações são divididas em dois grupos: substantivas e procedimentais. Cada grupo agrega cinco recomendações.

As sugestões substantivas são: 1) explicitar e justificar a questão de pesquisa; 2) descrever os métodos e as técnicas; 3) simplificar a hipótese de trabalho; 4) produzir inferências causais falsificáveis; e 5) apresentar as limitações do desenho de pesquisa. E as recomendações procedimentais: 6) minimizar a complexidade da linguagem; 7) compartilhar a base de dados; 8) evitar gráficos nebulosos e tabelas poluídas e incompletas; 9) ser criticado antes de publicar; e 10) escolher adequadamente os meios de divulgação. (Paranhos et al., 2012).

3. Inferência

A pesquisa nas Ciências Sociais, não importa se qualitativa ou quantitativa, tem o objetivo duplo de descrever e explicar. Nem sempre, é verdade, esses polos andam juntos. Há pesquisadores interessados em descrever um fenômeno, outros em explicar. A despeito disso, tanto a explicação quanto a descrição são mecanismos que operam sob as regras da inferência científica (King, Keohane & Verba, 1994). Mas, afinal, o que é inferência? Quais as diferenças entre uma inferência descritiva e uma inferência causal? Como as Ciências Sociais em geral, e a Ciência Política em particular, dialogam com essa questão?

Na definição extraída (e traduzida) do glossário presente em Brady e Collier (2004), inferência é o “processo de usar dados para traçar conclusões mais amplas a respeito de conceitos e hipóteses que estão no foco da pesquisa”. Ou seja, inferência é o processo pelo qual utilizamos informações conhecidas para aprender sobre informações não-conhecidas. Cabe ressaltar, contudo, que essa definição é específica para a discussão sobre pesquisas empíricas nas Ciências Sociais. Em outros contextos, como na Matemática por exemplo, os analistas preocupam-se mais com inferências lógicas do que propriamente inferências a partir de dados. Em miúdos, entretanto, podemos dizer que a

inferência permite ao pesquisador traçar conclusões sobre a população a partir de dados de uma amostra dela.

As fundações lógicas e estatísticas da inferência causal, inclusive, apontam um certo ceticismo sobre a produção de inferências desse tipo com base em estudos observacionais. Isso é especialmente importante, pois uma grande parte das inferências realizadas na área de Ciência Política são extraídas por meio da análise de regressão (especificamente o modelo de mínimos quadrados ordinários – MQO), técnica importada da estatística e da econometria. Um estudo que levantou 1.756 artigos publicados em três dos principais periódicos da área – *American Political Science Review*, *American Journal of Political Science* e *Journal of Politics* – constatou que 1/3 deles utilizaram a regressão de mínimos quadrados ordinários (Krueger & Lewis-Beck, 2008).

No clássico *Designing Social Inquiry*, a análise de regressão é apontada como a ferramenta básica para se produzir inferências causais a partir de dados empíricos. A estimação dos parâmetros e os testes de significância, amplamente utilizados na técnica da regressão, oferecem a maior parte da base estatística utilizada por King, Keohane e Verba em suas discussões sobre inferência (Brady & Collier, 2004).

Particularmente na econometria, disciplina que tem influenciado muito a condução das pesquisas quantitativas mais recentes na Ciência Política, a inferência é uma ferramenta utilizada por meio do teste de hipóteses dos parâmetros do modelo da regressão populacional. O que isso significa? Em linhas gerais, a inferência feita a partir de uma amostra só pode ser estendida à população após alguns testes. Em um modelo de regressão linear, os coeficientes β são características desconhecidas da população e nunca serão conhecidos com 100% de segurança. No entanto, é possível fazer hipóteses sobre o valor desse coeficiente e utilizar a inferência estatística para testar a hipótese (Wooldridge, 2013).

Ora, se é preciso ter uma amostra “boa” para poder realizar inferências confiáveis, então como ficam os trabalhos qualitativos, cujo foco de análise costuma estar detido a um ou poucos casos? Numa Ciência Política que vem tendo sua produção fortemente marcada pela utilização de modelos quantitativos formais, o espaço que se tem dado às pesquisas de *small-n* e as discussões em torno destas merecem atenção especial. Essa discussão é apresentada em detalhes e de forma mais aprofundada por Rezende (2011).

De acordo com Gil (1999), a maioria das pesquisas realizadas no âmbito das Ciências Sociais não tem o objetivo de verificar ou estabelecer hipóteses causais. Na Ciência Política em particular, é possível que essa afirmação não faça tanto sentido. Paranhos et al (2012), por exemplo, defende que os desenhos de pesquisa em Ciência Política devem ser formatados com o objetivo de gerar inferências causais.

Para a realização de inferência causais, o pesquisador precisa estar atento a três pressupostos essenciais: 1) X e Y variam em conjunto, de acordo com a hipótese específica prevista pela teoria; 2) Y não precede X no tempo; e 3) outros fatores não determinam Y (Selltiz et al., 1967). Para efeito de rápido esclarecimento, em linguagem metodológica, Y corresponde à variável dependente (o que se quer explicar) e X à variável independente ou explicativa (o que explica Y). Um desenho de pesquisa pode ter uma variável explicativa ou um conjunto delas.

Em estudo sobre golpes de Estado na Argentina, Mainwaring e Pérez-Liñán (2013) constroem um modelo explicativo para a ocorrência de quebras democráticas (Y) segundo três variáveis independentes: se a maioria dos atores políticos durante o período tinha um comprometimento normativo com a democracia (X1); se a maioria dos atores políticos do período adotava posicionamentos radicais (X2); se o contexto internacional era favorável à democratização (X3). Além do process-tracing, a principal metodologia empregada pelos autores foi o Qualitative Comparative Analysis (QCA), voltada

para descortinar configurações causais necessárias e suficientes para a ocorrência do fenômeno de interesse.

O grande dilema envolvendo inferências causais diz respeito ao risco inerente das pesquisas não experimentais. Nos experimentos controlados, é possível elaborar com segurança provas estatísticas para todos os aspectos envolvendo as variáveis do trabalho. O mesmo não acontece em um estudo observacional. Essa incerteza frequente e impossível de se eliminar dos desenhos de pesquisa observacionais é chamada de “problema fundamental da inferência causal”. Em termos técnicos, o problema é consequência do fato de ser impossível se observar ao mesmo tempo o valor do tratamento e do não-tratamento. Ou seja, o pesquisador não tem acesso a um contrafactual.

Especificamente falando em linguagem das Ciências Sociais: o pesquisador não pode saber como um fenômeno se comportaria na ausência daquelas variáveis utilizadas para se realizar uma inferência causal. Se X não existisse, Y aconteceria? Para saber isso com certeza, a única maneira é realizando o mesmo experimento com e sem a presença de X. Em se tratando de fenômenos sociais, isso é impraticável.

No matter how perfect the research design, no matter how much data we collect, no matter how perceptive the observers, no matter how diligent the research assistants, and no matter how much experimental control we have, we will never know a causal inference for certain. Indeed, (...) most of our suggestions constitute partial attempts to avoid it. (King, Keohane & Verba, 1994, p. 79. grifo nosso.)

À disposição, o pesquisador tem algumas ferramentas que podem auxiliá-lo na produção de inferências causais válidas. No *Designing Social Inquiry*, como já mencionamos, a análise de regressão é a ferramenta mais utilizada para se realizar inferências a partir de dados empíricos. Entretanto, cabe ressaltar que a regressão não é única maneira de se identificar e explicar relações causais.

Outros métodos existem e eles funcionam da seguinte forma: uma vez que a estratégia de identificação é selecionada e o desenho da pesquisa está completo, o próximo passo do analista é estimar os efeitos causais. E alguns métodos foram desenvolvidos exatamente com esse propósito: estimar efeitos causais. Keele (2015) menciona pelo menos três deles: 1) gráficos acíclicos dirigidos; 2) métodos de estimação (regressão, *matching* e *weighting*); e 3) métodos inferenciais. Angrist e Pischke (2015) apresentam cinco ferramentas econométricas, chamadas de *Furious Five*, largamente utilizadas na identificação de causas e efeitos: 1) atribuição aleatória (*random assignment*); 2) regressão; 3) variáveis instrumentais; 4) regressão descontínua; e 5) diferenças em diferenças (*diff-in-diff*).

Ainda dentro desse contexto da inferência causal, uma condição extremamente importante que deve ser observada ao longo do processo são os já mencionados contrafactuais. A condição contrafactual é a essência por trás da definição de causalidade. Trata-se de uma tentativa do pesquisador em responder a pergunta “e se”?

Uma forma de deixar claro o que é o contrafactual é explicitar o que está sendo deixado constante enquanto o valor da variável de tratamento é alterado. Alguns alvos de inferência são factuais, ou seja, eles existem mesmo que nós não saibamos. Outros são contrafactuais: não existem, ao menos por enquanto. Os Estados Unidos teriam invadido o Iraque se não ocorresse o ataque às Torres Gêmeas em 11 de setembro de 2001? Desenvolver questões contrafactuais devem ser uma rotina, parte obrigatória do relatório estatístico de qualquer um interessado em fazer previsões ou estimar efeitos causais (King & Zeng, 2007). No quadro abaixo, resumimos algumas das principais informações acima relatadas sobre a inferência causal.

Quadro 3. Aspectos da inferência causal

Pressupostos	1) X e Y variam em conjunto 2) Y não precede X no tempo 3) Outros fatores não determinam Y
Problema fundamental	Se 'X' não existisse, 'Y' aconteceria? O contrafactual nem sempre pode ser acessado.
Métodos utilizados	1) Gráficos acíclicos dirigidos 2) Métodos de estimação 3) Métodos inferenciais

Fonte: Elaboração do próprio autor com base em fontes diversas

A inferência causal, vale ressaltar, não é a única a existir: há também a inferência descritiva. Descrição e inferência descritiva são coisas diferentes. Descrição nada mais é do que a simples coleta de fatos. Descrever cuidadosamente um evento ajuda o pesquisador a fazer as perguntas certas e a traçar os procedimentos necessários para que as conclusões estejam alicerçadas em bases sólidas. No entanto, é por meio da inferência que o pesquisador se habilita a avaliar hipóteses e ver se elas estão corretas. Afinal, inferência e teste de hipóteses andam sempre de mãos dadas (King, Keohane & Verba, 1994).

Nesse sentido, inferência descritiva é o processo de compreensão de um fenômeno não-observado através de um conjunto de observações coletadas. A ideia é sumarizar informações e alcançar conclusões descritivas sobre um fenômeno com base em um conjunto de dados observado. Um dos fundamentais objetivos da inferência, de acordo com o *Designing Social Inquiry*, é distinguir os componentes sistemáticos e os componentes não-sistemáticos do fenômeno de estudo. Nenhum é mais importante que o outro e o pesquisador deve estar atento a ambos.

Por exemplo, imagine que as eleições em um determinado município brasileiro tenham tido um alto índice de abstenções. O pesquisador pode inferir que se trata de um protesto? Os eleitores estão insatisfeitos com os candidatos?

Essas são perguntas relativas a componentes sistemáticos do fenômeno estudado. No entanto, se os eleitores simplesmente não foram às urnas porque choveu muito no dia do pleito, então estamos diante de um componente não-sistemático que está influenciando diretamente o fenômeno observado.

Os fatores sistemáticos são persistentes e oferecem consequências consistentes quando esses fatores assumem determinados valores. Componentes não-sistemáticos, por outro lado, são transitórios e impossíveis de se prever. Uma inferência descritiva, então, está preocupada em alcançar conclusões descritivas com base na observação de um dado conjunto de informações.

A inferência descritiva diz respeito a sumarizar um conjunto de dados através de números ou gráficos. As estatísticas descritivas de um conjunto de variáveis, por exemplo, informam o pesquisador sobre a média, pontos de mínimo e máximo, desvios-padrão. A inferência causal diz respeito a alcançar conclusões sobre uma população a partir de observações extraídas de uma amostra (Brady & Collier, 2004).

Na visão de King, Keohane e Verba (1994), há três critérios que devem ser utilizados no momento de se avaliar os métodos utilizados na produção de inferências descritivas: 1) imparcialidade (não-enviesamento); 2) eficiência; e 3) consistência. Uma versão simples de uma inferência envolve a estimação de parâmetros, inclusive o valor esperado ou a variância de uma variável randômica para a inferência descritiva.

Em primeiro lugar, uma estimação imparcial (não enviesada) ocorre quando a variação observada na medida em que os dados são replicados em sequência é não-sistemática e move as estimativas uma vez para um lado, outra vez para o outro. O viés acontece quando há um erro sistemático na mensuração. Quando os dados são replicados e o pesquisador encontra resultados diferentes que pendem sempre para a mesma direção, é muito provável que ele esteja diante de uma estimativa enviesada, que possivelmente

causará uma inferência enviesada. Cabe ressaltar que o viés depende muito da teoria que está sendo investigada e nem sempre ele existe apenas nos dados.

Além de estar atento ao critério da imparcialidade, também faz-se necessário ter especial cuidado com a eficiência das inferências. A eficiência é um conceito relativo que é mensurado quando se calcula a variância das estimações ao longo das replicações. Quanto menor a variação, melhor os estimadores. O conselho mais sugerido pelo *Designing Social Inquiry* para aumentar a eficiência das estimativas, bem como solucionar outros problemas que surgem no curso da investigação científica, é crescer o número de observações. Trata-se de um mantra.

O critério da consistência está diretamente ligado com o da eficiência. Observa-se a consistência de uma inferência quando a variabilidade dos estimadores decresce a zero ao passo em que o número de observações aumenta, fazendo com que as estimativas traçadas igualem os parâmetros que se tenta estimar (King, Keohane & Verba, 1994). Para fins didáticos de facilitar a absorção dos conceitos, e como forma de concluir esta seção, resumimos abaixo as definições dos principais conceitos aqui trabalhados.

Quadro 4. Definições Dos Conceitos De Inferência

Conceito	Definição
Inferência	Processo no qual utilizamos informações conhecidas (e disponíveis) para aprender sobre informações não-conhecidas (e indisponíveis).
Inferência causal	Processo de traçar conclusões sobre causalidade (X causa Y) com base em um conjunto de dados observados.
Inferência descritiva	Processo de traçar conclusões descritivas com base em um conjunto de dados observados.

Fonte: Elaboração do próprio autor com base em fontes diversas

4. Causalidade

Questões envolvendo causalidade são de relevância incontestável em todas as áreas do conhecimento, e com a Ciência Política não é diferente. Uma grande parte das produções recentes na disciplina tem o objetivo velado de realizar inferências causais, algo que está diretamente ligado ao conceito de causalidade. A definição do conceito, pelo menos em suas aplicações nas Ciências Sociais, é oriunda da Estatística. No livro de King, Keohane e Verba, por exemplo, a abordagem utilizada sobre causalidade vem do trabalho de dois estatísticos: Donald Rubin e Paul Holland.

De acordo com Brady (2004), a abordagem proposta no *Designing Social Inquiry* com relação à causalidade envolve dois eixos principais: 1) descrição cuidadosa da condição contrafactual (ou o que teria acontecido se a causa estivesse ausente); e 2) comparação entre o que aconteceu com o que teria acontecido se a causa não existisse. Se o pesquisador descobriu na sua investigação que X é a causa de Y, então ele deve estimar o que aconteceria na ausência de X e comparar com o modelo explicativo encontrado.

Uma forma didática de pensar essa situação é imaginar uma pesquisa na qual o analista descobre que uma política de transferência de renda foi a causa da redução da pobreza em uma determinada localidade (pode ser um município, estado, país, bairro, etc.). A grande questão é: a redução da pobreza teria acontecido se não houvesse a política pública de transferência de renda? Novamente, nos deparamos com o problema fundamental envolvendo causalidade. Nunca será possível responder a tais questionamentos com toda certeza.

Dentro desse contexto, a noção de *ceteris paribus* – termo em latim que significa “outros fatores permanecendo iguais” – é central para que se possa realizar uma análise causal. Em muitas pesquisas empíricas, o objetivo do investigador é inferir que uma variável tem um efeito causal sobre outra. Claro, encontrar padrões de associação entre variáveis já indica algo, mas o

estabelecimento de causalidade é o que norteia uma pesquisa. Para encontrar causalidade de uma forma em que a incerteza não seja tão alta, manter fixos outros fatores da análise é crucial (Wooldridge, 2013). No mundo real, uma série de fatores podem influenciar uma variável dependente. Um exemplo bem ilustrativo é a violência: uma série de fatores incide sobre ela, tais como educação, iluminação e policiamento.

King, Keohane e Verba definem causalidade como um conceito teórico independente dos dados utilizados. A causalidade é a diferença entre os valores assumidos pela variável dependente a partir da variação dos valores da variável independente. Quem está ligada diretamente aos dados é a inferência causal. O que os pesquisadores do tema argumentam é que a ideia central de causalidade envolve os mecanismos causais supostamente existentes entre a causa e o efeito. Qualquer informação sobre causalidade precisa ser especificada em termos de como os efeitos são exercidos. A definição de causalidade, reforçamos, diz respeito à identificação dos mecanismos causais.

Identificar mecanismos causais é uma forma popular de se realizar análises empíricas. Estudos de caso, *process tracing* e análises históricas são algumas ferramentas de pesquisa que têm o objetivo de identificar mecanismos causais. Em linhas gerais: o pesquisador pode definir um efeito causal sem entender completamente todos os mecanismos causais envolvidos, mas não pode identificar mecanismos causais sem definir o conceito de efeito causal (King, Keohane & Verba, 1994).

No entanto, as Ciências Sociais estão povoadas de fenômenos que possuem causalidade múltipla. Isso acontece quando o pesquisador se depara com um problema que apresenta uma pluralidade de causas. Nessas condições, onde diferentes variáveis independentes podem interferir no resultado do modelo, alguns métodos podem ser vilões e apontar que se deve rejeitar a hipótese que informa o status causal dessas variáveis. Determinados métodos e até mesmo desenhos de pesquisa podem não informar diretamente o

pesquisador sobre a existência da causalidade múltipla, mas é certo que alguns modelos estatísticos podem ajudar a lidar com situações desse tipo (Ragin, 1987).

Como, então, o pesquisador pode evitar todos esses problemas envolvendo causalidade? Ao menos com relação ao problema fundamental da inferência causal, duas premissas podem auxiliar o pesquisador: homogeneidade das unidades e independência condicional. Com relação ao primeiro item, pode-se dizer que duas unidades são homogêneas quando os valores esperados da variável dependente são os mesmos quando a variável independente assume determinados valores. Trocando em miúdos: como o pesquisador não pode observar a ausência e a presença de uma variável ao mesmo tempo, a saída é rodar seu modelo em duas unidades distintas, mas homogêneas. Przeworski e Teune (1970) estabelecem esse debate em termos de “equivalência” entre as unidades.

A independência condicional, por sua vez, é a premissa de que os valores são atribuídos às variáveis explicativas independentemente dos valores tomados pela variável dependente. Em um experimento, a independência é alcançada quando a atribuição de casos para os grupos de tratamento e controle não tem nenhuma relação estatística com outras características destes casos que podem influenciar a variável dependente. A maneira mais confiável de se atingir a independência condicional é por meio de uma análise de *large-n* que envolva procedimentos de aleatoriedade da seleção e da atribuição de valores (King, Keohane & Verba, 1994).

Brady (2004) critica a abordagem de causalidade proposta no *Designing Social Inquiry* na medida em que ela não dialoga com questões como a relação entre mecanismos causais, teoria e explicação. Na visão do autor, KKV pegam emprestado dos estudos experimentais sua definição de causalidade e isso é desvantajoso. A literatura estatística define causalidade sem discutir explicação porque os estatísticos estão muito mais preocupados em realizar inferências a

partir dos dados e do desenho da pesquisa, e não a partir de questões substanciais. A abordagem que KKV lança mão, emprestada de Rubin e Holland, não traz recomendações sobre o que seria uma boa explicação ou uma boa inferência causal (Brady, 2004). Rezende (2011) resume bem essa questão:

As explicações causais nas ciências sociais (e na ciência política) se enquadram nas leis de validade geral (*covering laws*), nas explicações estatísticas, e nas explicações por mecanismos. Nestas, a lógica de explicação não reside na covariância entre duas categorias de análise, mas sim na identificação dos mecanismos (da agência) que torna plausível a conexão entre as variáveis independentes (causas consideradas relevantes) e a variável dependente (efeitos observados), a partir de uma teoria. A considerável força deste argumento reside no fato de que as concepções mecanicistas da causalidade são um dos principais consensos nos debates sobre a filosofia da ciência social. Importantes trabalhos na tradição da teoria social e da sociologia analítica (...) lançam os fundamentos da lógica analítica dos mecanismos causais como um dos principais “consensos” acerca da explicação em ciências sociais. Explicações devem envolver mecanismos e mostrar claramente como as variáveis se articulam num dado modelo causal. (Rezende, 2011, p. 325)

O que o pesquisador precisa ter em mente, nesse sentido, é que a simples correlação entre variáveis não indica qualquer relação de causalidade entre elas. Vale salientar que, grosso modo, toda causalidade pressupõe correlação, mas o inverso não é verdade. Esse debate é especialmente importante para o cientista político que tem um desenho de pesquisa voltado para desvendar alguma relação causal. As explicações causais só podem ser referendadas com base em análises substanciais dos processos de interação entre os mecanismos causais, do contexto em que elas ocorrem e, claro, da teoria existente sobre o assunto. Como sabemos, os fenômenos políticos são fortemente influenciados pelo seu contexto e qualquer análise de causalidade que exclua as particularidades dos mecanismos envolvidos está fadada ao fracasso.

Em termos filosóficos, a definição precisa de causalidade e a lógica que envolve a identificação dessa propriedade entre variáveis é uma questão ainda não consensual. Nem os próprios filósofos da ciência têm tanta certeza se o

único tipo possível de explicação envolve causalidade. No entanto, sabe-se que não é possível captar causalidade em fenômenos sociais sem levar em conta as relações materiais envolvidas. Na estatística pura, cujo objeto são apenas números e suas relações lógicas, a causalidade pode ter fundamentos meramente lógicos. Certamente não é o caso nas Ciências Sociais (e na Ciência Política). O contexto importa.

5. Considerações finais

Não existe uma fórmula mágica que nos diga com toda certeza como construir e conduzir uma pesquisa perfeita. Os caminhos percorridos durante uma pesquisa científica são inerentemente cobertos por obstáculos. É raro, ou impossível, encontrar um pesquisador que nunca se deparou com um percalço ao longo de algum trabalho. Dificuldade em coletar dados e desorganização no momento de escrever (a famosa pergunta: “Por onde eu começo?”) são apenas alguns exemplos que podemos dar para ilustrar nosso argumento.

Percalços surgem naturalmente no curso de uma pesquisa e são imprevisíveis. O que o pesquisador pode fazer, no entanto, é se resguardar. Como? Por meio de uma rigorosa estruturação da pesquisa. O primeiro passo nesse sentido é, de cara, definir uma boa questão de pesquisa. Duas indagações podem nortear o trabalho do analista nesse momento: 1) Qual pergunta quero responder?; e 2) Uma vez escolhida a pergunta, como posso respondê-la?

Estruturar um desenho de pesquisa adequado para os propósitos da investigação é algo elementar, que está na base da construção do saber científico. Reforçamos: a pesquisa precisa ser desenhada de acordo com a pergunta que se propõe a responder. Não é a pergunta que precisa se encaixar em um desenho de pesquisa, mas o inverso. Um desenho de pesquisa mal feito prejudica a realização de inferências, causais ou descritivas, o que por sua vez põe dúvidas quanto à plausibilidade dos resultados encontrados.

O objetivo deste trabalho foi abordar alguns norteamentos que a literatura oferece com relação à consecução de uma boa pesquisa científica. É claro que o domínio de métodos específicos de pesquisa, sejam quali ou quanti, também exerce grande influência nos resultados de um trabalho. Ter conhecimento de técnicas como regressão, análise fatorial, QCA ou *process tracing* auxilia e muito o pesquisador na hora em que ele precisa manipular dados e realizar inferências a partir deles. No entanto, os métodos sozinhos não fazem verão. Uma boa pesquisa, antes de tudo, é aquela estruturada segundo rigorosos padrões científicos. E se queremos fazer ciência de qualidade, é bom estarmos preparados para seguir esses padrões.

Referências

ANGRIST, J. D; PISCHKE, J. **Mastering 'Metrics: The Path from Cause to Effect**. Princeton: Princeton University Press, 2015;

BRADY, H. E. Doing good and doing better: how far the quantitative template get us? In: BRADY, H. & COLLIER, D. (eds.) **Rethinking social inquiry: diverse tools, shared standards**. New York: Rowman & Littlefield Publishers, pp. 53-67, 2004.

BRADY, H. E; COLLIER, D. **Rethinking social inquiry: diverse tools, shared standards**. New York: Rowman & Littlefield Publishers, 2004.

COLLIER, D; SEAWRIGHT, J; MUNCK, G. L. The quest for standards: King, Keohane, and Verba's Designing Social Inquiry. In BRADY, H; COLLIER, D. (eds.). **Rethinking social inquiry: diverse tools, shared standards**. New York: Rowman & Littlefield Publishers, pp. 21-50, 2004.

GIL, A. C. **Métodos e técnicas de pesquisa social**. São Paulo: Atlas, 1999.

KEELE, L. The statistics of causal inference: a view from political methodology. **Political Analysis**. v. 23: 313-335, 2015.

KING, G; KEOHANE, R. O; VERBA, S. **Designing social inquiry: scientific inference in qualitative research**. Princeton: Princeton University Press, 1994.

KING, G; KEOHANE, R. O; VERBA, S. The importance of research design in Political Science. *The American Political Science Review*, v. 89, n. 2: 475-481, 1995.

KING, G; ZENG, L. When can history be our guide? The pitfalls of counterfactual inference. **International Studies Quarterly**, v. 51: 183-210, 2007.

KRUEGER, J; LEWIS-BECK, M. Is OLS dead? **The Political Methodologist**, v. 15, n. 2: 2-4, 2008.

MAINWARING, S; PÉREZ-LIÑÁN, A. S. **Democracies and Dictatorships in Latin America: Emergence, Survival, and Fall**. Cambridge: Cambridge University Press, 2013.

MORTON, R. B; WILLIAMS, K. C. Experimentation in Political Science. In. BOX-STEFFENSMEIER, J; COLLIER, D; BRADY, H; (eds.). **Oxford Handbook of Political Methodology**. Oxford: Oxford University Press, 2008.

PARANHOS, R. et al. Levando Gary King a sério: desenhos de pesquisa em Ciência Política. **Revista Eletrônica de Ciência Política**, v. 3, Curitiba: 86-117, 2012.

PRZEWORSKI, A; TEUNE, H. **The logic of comparative social inquiry**. New York: Wiley Interscience, 1970.

RAGIN, C. **The comparative method: moving beyond qualitative and quantitative strategies**. Berkeley: University of California Press, 1987.

REZENDE, F. C. Por que reformas administrativas falham? **Revista Brasileira de Ciências Sociais**, nº 50, vol. 17: 123-142, 2002.

REZENDE, F. C. Razões emergentes para a validade dos estudos de caso em ciência política comparada. **Revista Brasileira de Ciência Política**, nº 06, Brasília: 297-337, 2011.

SELLTIZ, Claire et al. **Métodos de pesquisa nas relações sociais**. São Paulo: Herder, 1976.

SOARES, G. O Calcanhar Metodológico da Ciência Política no Brasil. *Sociologia, Problemas e Práticas*, n. 48: 27-52, 2005.

VALLE SILVA, N.. Relatório de consultoria sobre melhoria do treinamento em ciência social quantitativa e aplicada no Brasil. **Laboratório Nacional de Computação Científica**. Rio de Janeiro: 22 págs, 1999.

WOOLDRIDGE, J. M. **Introdução à Econometria: uma abordagem moderna**. São Paulo: Cengage Learning, 2013.

Recebido em: 19/04/2016
Aprovado em: 03/07/2016