



RESENHA

O LIVRO DO PORQUÊ: A NOVA CIÊNCIA DE CAUSA E EFEITO

PEARL, JUDEA; MACKENZIE, DANA. *THE BOOK OF WHY: THE NEW SCIENCE OF CAUSE AND EFFECT*. BASIC BOOKS, 2018.

*Leonardo Rodrigues Ferreira¹ **

Introdução

O Livro de Judea Pearl e Dana Mackenzie, sob o título de “O livro do Porquê” - A nova ciência de causa e efeito é vencedor do prêmio Turing, publicado pela Editora Basic Books da cidade de New York em 2018. O texto inicial do livro apresenta uma nova forma de se olhar a ciência.

A introdução traz algumas reflexões sobre como a ciência mudou a maneira da humanidade de distinguir os fatos da ficção, o uso da ciência trouxe uma maior qualidade de vida para os habitantes do planeta terra, pois as pessoas obtiveram remédios para suas doenças, houve uma melhoria da educação com as novas tecnologias, o meio ambiente e a agricultura resolveram diversos problemas com a utilização da ciência.

A nova ciência denomina-se “inferência causal” que essencialmente parte do pressuposto da observação do homem que “certas coisas causam outras coisas”, através dessa descoberta surgiram às sociedades organizadas e em seguida toda a tecnologia que nós temos hoje. Tudo isso, em consequência, de uma simples pergunta: porquê? A inferência causal busca explicar o porquê das coisas, através da mente humana que é a ferramenta capaz de decifrar causas e efeitos.

¹ Doutor em Ciência Política pela Universidade Federal de Pernambuco (UFPE); mestre em Administração e Desenvolvimento Rural pela Universidade Federal Rural de Pernambuco (UFRPE). E-mail: lrferreira.adm@gmail.com.

Várias pesquisas atestam que o cérebro humano, é capaz de armazenar uma grande quantidade de conhecimento e que, adicionado por dados, pode-se responder a algumas das questões mais necessárias da atualidade. Quando, compreendemos o sentido no entorno do pensamento causal, podemos transferir a ideia para os programas computacionais e criar um "cientista artificial".

Este robô teria o propósito de descobrir fenômenos ainda não desvendados e buscar explicações para problemas sociais, arquitetando novos experimentos para produzir mais conhecimento causal do ambiente. Problemas envolvendo questões de causa e efeito faz parte do estudo da inferência causal, podemos citar temática de diversos tipos como: política, saúde, educação, meio ambiente, ou seja, tudo que está relacionado ao ser vivo e todo o seu entorno é propósito do referido estudo.

Desenvolvimento

De acordo com o livro, a maior contribuição da inferência causal para a raça humana foi à transformação da negligência científica em referência ativa. A nova ciência modificou nossos hábitos. A maneira de apresentar as informações em formato matemático proporcionou um cabedal de métodos poderosos e com funcionalidades para associar o conhecimento humano aos dados.

As pesquisadoras em estatísticas, Francis Galton e Karl Pearson, desvendaram que os dados populacionais ajudam a responder sobre questões científicas. Por ironia do destino, a teoria da causalidade surgiu no mesmo período em que as estatísticas emergiram. De fato, as estatísticas modernas nasceram das questões causais que Galton e Pearson fizeram sobre a hereditariedade e suas várias tentativas de compreendê-las utilizando dados de gerações.

Mesmo com os esforços de Sewall Wright (1889-1988) o período entre 1880 e 1930 foram críticos para a história da ciência, que teve oportunidade de construir sobre as questões causais utilizando uma própria linguagem, mas não prosperaram, nos anos seguintes, essas indagações foram anunciadas como não científicas e ficaram na clandestinidade, o elemento causal ficou no ostracismo por aproximadamente meio século.

Por razão da proibição, os instrumentos matemáticos passaram a conduzir sobre as questões causais de forma secundária, e as estatísticas se centralizaram apenas em como resumir dados, não em como interpretá-los. A Revolução Causal não aconteceu no vazio, surgiu de um procedimento matemático, que pode ser apresentado como um cálculo de causalidade, que dá resposta a vários problemas sobre causa e efeito.

O cálculo da causalidade se compõe em duas linguagens: diagramas causais, para designar o que sabemos, e uma linguagem simbólica, equivalente à álgebra, para expor o que queremos saber. Uma ação máxima da Revolução Causal foi entender a previsão dos efeitos de uma intervenção sem decretá-la. Não seria possível se não tivéssemos, determinado o que faz um operador, para que possa realizar a pergunta correta e, em seguida, criar uma forma de emulá-la de maneira não invasiva.

No momento em que a questão científica de interesse, relaciona-se ao pensamento retrospectivo, buscamos outro formato do raciocínio causal que é o contrafactual. Entretanto, a tradicional estatística se resume os dados, consequentemente, não proporciona um meio para fazer essa pergunta.

Já a inferência causal permite uma notação e, por isso, possibilita uma solução. O pensamento contrafactual, que tem o raciocínio do "e se", pode aparentar não científico para alguns leitores. Porém, a observação empírica não pode comprovar ou negar as explicações a tais questões. Os contrafatuais são as estruturas de edificação da conduta moral, tal qual do pensamento científico.

A reflexão sobre as atuações e a habilidade de prospectar cenários diferentes é o pilar do livre arbítrio e da responsabilidade social. O procedimento de inferência é um instrumento que aceita três tipos diversos de entradas - suposições, consultas e dados - e produz três tipos de saídas.

A primeira das saídas é uma decisão Sim/Não sobre se a consulta dada pode, em teoria, pode ser respondida conforme o modelo causal existente, considerando os dados perfeitos e ilimitados. É fundamental entender que, contrariando o pressuposto tradicional da estatística, algumas consultas não são respondidas pelo atual modelo causal, mesmo depois da coleta de qualquer quantidade de dados.

Nesse caso específico, é perder tempo a coleta de dados. Ao invés disso, necessitamos nos voltar para a refinação do modelo, seja complementando com novos conhecimentos científicos, que nos permite estimar Z ou fazendo suposições reduzidas. Entretanto o mundo científico atual reproduz uma provocação para um pensamento consolidado sobre causas e efeitos.

Apesar da convicção, que o modelo causal cresceu com várias dificuldades, entre as ciências, vários estudiosos em inteligência artificial desejam de pular a árdua fase de criar ou adquirir um modelo causal e acreditar unicamente nos dados para todas as atividades cognitivas.

No primeiro capítulo do livro, o autor inicia sua fala sobre seu processo de descoberta entre 6 e 7 anos com a leitura do Jardim do Éden, relata como foi sua interpretação sobre Adão e Eva no paraíso, e que com o passar dos anos a sua interpretação sobre a história vai modificando. Em outros pontos do capítulo 1, o autor, cita alguns exemplos de evolução dos seres vivos com o passar dos anos, as águias e corujas desenvolveram uma visão incrível.

Os humanos realizaram uma verdadeira revolução no planeta terra em poucos séculos. O autor se reporta a esse fenômeno como "aceleração superevolucionária". O processo de evolução nos proporciona adquirir a competência de planejar nossas vidas, e a pergunta, mais uma vez, é "Por quê?" Que diferencial os humanos tem em relação aos outros animais? Não é só pensar a questão vai mais além. Várias teorias foram apresentadas, mas uma em especial é adequada à ideia de causalidade. No livro dele Sapiens, o historiador Yuval Harari persevera que a competência de nossos antepassados de idealizar objetos inexistentes era o caminho para tudo, pois possibilitava a comunicação entre eles.

Anteriormente a essa mudança, eles só confiavam em pessoas de sua família ou tribo. Logo após a imaginação, sua confiança aumentou e se expandiu para comunidades maiores, relacionadas pelas mesmas fantasias, ou seja, a crença em divindades invisíveis, mas imagináveis, na vida após a morte e na divindade do líder.

O autor relata que passa a impressão de que a competência da organização do nosso conhecimento do mundo em causas e efeitos era homogeneia e rígida obtida de uma só vez. Segundo o mesmo, de acordo com sua pesquisa sobre aprendizado de máquina cada aluno causal deve entender pelo menos três níveis diferentes de habilidade cognitiva: ver, fazer e imaginar.

Nessa relação os dois primeiros, ver ou observar, abrange a descoberta de regras em nosso ambiente e é utilizado por muitos animais, como foi com os primeiros humanos antes da Revolução Cognitiva. Na sequência, o fazer, envolve a previsão de efeitos de modificações estabelecidas no ambiente e na escolha entre essas mudanças para produção do resultado almejado.

Contudo somente um grupo pequeno de espécies revelou componentes dessa habilidade. A utilização de instrumentos artesanais, mesmo que sem intenção, apenas não acidental ou replicado dos antepassados, pode ser visto como uma maneira de chegar nesse segundo nível. Entretanto, mesmo os usuários de desses utensílios, estes não tem necessariamente uma “teoria” de seu ferramental que lhes responda o funcionamento e o que se pode fazer quando não funciona. Para esse fim, você deve ter atingido um grau de compreensão que proporcione imaginar. Os estatísticos realizaram muitos métodos construídos para diminuir um grande corpo de dados e identificar relações entre variáveis. “Correlação” ou “regressão”, uma forma específica de associação frequentemente exposta neste livro, compreende regular uma linha a uma coleção de pontos de dados e calcular a disposição dessa linha. Certas relações podem ter interpretações causais óbvias; outros não. Portanto as estatísticas por si só não podem definir qual é a causa e qual é o efeito. A classificação de uma intervenção é mais alta do que a associação, porque abrange não apenas ver, mas também mudar o que é. Ver fumaça, não é necessariamente um incêndio. Ou seja, não se podem dar respostas a perguntas sobre intervenções com dados coletados de forma fragmentada, não importando a dimensão do conjunto de dados ou a profundidade da rede neural. Uma modo muito direto de prever o resultado de uma intervenção é experimentá-la sob condições cautelosamente controladas. Todos nós fazemos intervenções a todo o tempo em nossas vidas diariamente, contudo normalmente não utilizamos esse termo tão sofisticado. Ainda que, pensar sobre intervenções seja um passo significativo na escada causal, ainda não atende a todas as questões de interesse. Os contrafatuais têm uma ligação essencialmente problemática com os dados porque são, por definição, os fatos. Eles não nos dizem o que acontecerá em um mundo contrafactual ou imaginário, onde os determinados fatos examinados são negados sem pretexto. Porém, a mente do homem faz tais inferências em buscando explicações de forma confiável e repetitiva. São vários os ganhos em ter um modelo causal, que possa responder perguntas contrafatuais. O fundamental aprendizado para um pesquisador de causalidade é que um modelo causal abrange muito mais do que os desenhos das letras e flechas. Tem um infinito além das setas, que são as

probabilidades. Quando ilustramos uma flecha de X para Y, estamos subentendendo que determinada regra ou função de probabilidade como Y mudaria se X deviam mudar. Para sabermos qual é a regra; necessariamente, teremos que estimá-lo a partir dos dados. Tem como atributos meios enigmáticos como a “Revolução Causal”, contudo, em muitos contextos esses pontos matemáticos não são de fácil especificação. Reconhecer que a causalidade não é redutível a probabilidades foi uma conquista através de muita pesquisa, que levou anos de estudos dos filósofos e cientistas como um todo. Entender o sentido de “causa” tem sido o objetivo de vários filósofos, principalmente porque esse conceito é estabelecido pela intuição. O que explica a estabilidade da dotação genética da população? Galton pesquisou durante oito anos para decifrar esse enigma, onde relata os achados na no seu livro *Gênio hereditário* em 1869. De acordo com o livro, o real interesse de Galton não eram as projeções sobre os jogos de carnaval ou a estatura dos homens, mas a inteligência humana. Proveniente de uma família com vários gênios, Galton buscou uma científica que a genialidade está nas famílias. Em seu livro, reuniu 605 pessoas com características geniais dos quatro últimos séculos. Os achados revelaram que os filhos e pais desses gênios eram poucos notáveis e que os avós e os netos não tinha nada geniais.

Portanto, qual é o conceito de eminência? É difícil descrever que pessoas notáveis sejam bem-sucedidas, pois irá depender de algumas variáveis. Galton buscou essa explicação genética diuturnamente. Mesmo assim, ele estava certo e as respostas vieram quando nas características físicas como altura, que são mais acessíveis para mensurar e estão diretamente associadas à hereditariedade do que a “eminência”. Em 1877, Galton procurava uma explicação causal e julgava que a regressão era um processo causal, como uma lei da física. Mero engano, contudo esse erro ainda é bastante cometido. Em 1889, Galton descobriu que precisava separar as estatísticas das causas, foi também o nascimento da disciplina estatística. Assim ele começou a reunir uma variedade de “antropométricas”: altura, comprimento da cabeça, largura. Ele observou que quando alinhou a altura em relação ao comprimento do antebraço, aconteceu o fenômeno de regressão à média. De acordo com a lei da regressão a utilização da relação de duas distintas quantidades, como altura e QI e você colocar uma quantidade contra a outra em um gráfico de dispersão e calcular os dois eixos devidamente, a inclinação da linha de melhor ajuste geralmente terá as mesmas propriedades. É igual a 1 apenas quando uma quantidade pode prever a outra com precisão; é 0 sempre que a previsão não for melhor do que uma estimativa aleatória. Uma maneira de apresentar a regressão é através do gráfico de dispersão, onde há a representação por pontos com as coordenadas X e Y. A disposição da regressão proporciona a previsão do valor de uma variável desde que você saiba o valor da outra. O aprendiz de Galton, chamado Karl Pearson, mais tarde decifrou uma fórmula para a inclinação da linha de regressão e a nomeou de “coeficiente de correlação”. Parece piada a história de Galton, que começou buscando a causalidade e acabou descobrindo a correlação. A primeira descoberta de Galton, referente à correlação foi a elaboração de um mecanismo capaz de explicar a estabilidade da dotação genética da população. Quando se trata em esclarecer a eliminação da causalidade das estatísticas, vejamos a visão do historiador Whig, que afirma não haver outra forma de

compreender a estatística como uma estrutura de redução de dados cegos para modelos, exceto colocando nossas lentes causais e recontando as histórias de Galton e Pearson com o foco na ciência de causa e efeito. Pearson, discípulo de Galton, tentou completar a tarefa de eliminar da estatística a causalidade, porém não conseguiu. Para Pearson, Galton expandiu o vocabulário da ciência, mas reduziu a causalidade a um caso de correlação, ou seja, o coeficiente 1 ou -1 e a relação determinista entre x e y . Pearson era muito cético a questão da causalidade, ele combatia os fundamentos filosóficos da física. Pearson, através dos ensinamentos de Galton, encontrou o foco para suas paixões, pois ele acreditava que poderia transformar o mundo da ciência. No seu primeiro artigo sobre estatística publicado em 1893, apenas quatro anos após a descoberta da correlação de Galton. Ele fundou o jornal *Biometrika*, que continua sendo uma revista de referência científica. Em 1911, tornou-se professor titular do departamento de Biometria na University College London. E logo o Laboratório de Biometria da Pearson foi o ponto central da estatística mundial. Posteriormente Pearson ocupou uma posição de poder e seu fanatismo ficou evidente, ele exigia fidelidade e obrigações de seus membros, o que ocasionou muitas dissidências. Uma parceria de Pearson foi Yule, juntos realizaram várias compleições de exemplos de correlações espúrias. Nem todos os alunos de Pearson tinha sincronia com ele. Yule rompeu com Pearson por outros motivos. Yule manteve-se na linha sustentando as correlações, mas teve que mudar de ideia quando teve que explicar as condições de pobreza em Londres. Com Pearson e seus discípulos contrários a causalidade, mas medrosos em afrontar seu líder, e vários dissidentes, um novo cientista encontrou um cenário ideal para apresentar sua teoria, que evitava a causalidade. Trata-se de Sewall Wright que logo quando terminou seu doutorado em 1915, recebeu uma oferta para trabalhar no Departamento de Agricultura dos Estados Unidos, estudando cobaias. Em 1925, tornou-se professor na Universidade de Chicago e continuou a estudar genética, contribuindo para a teoria da evolução que influenciou Charles Darwin. As descobertas de Wright acabaram sendo revolucionária porque foi a prova de que de que “correlação não implica causalidade” e devem dar lugar para a lógica “algumas correlações implicam causação”. Finalmente, Wright comprou que os fatores de desenvolvimento hipotéticos eram mais importantes do que a hereditariedade. O entendimento dos coeficientes de caminho, em referencia a quantidade de variação esclarecida por uma variável, esse era o conceito da época. No entanto a interpretação causal moderna é distinta, eles definem que os coeficientes de caminho são os resultados de uma intervenção hipotética na variável de origem. Muitas vezes os cientistas desconhecem a cadeia de relações entre suas variáveis. Portanto, alegou Wright, o diagrama pode ser aplicado no formato exploratório; Pode-se pressupor algumas relações causais e calcular as correlações previstas entre as variáveis. Se por esse motivo contrariar os dados, neste caso, evidencia-se que as relações que presumimos eram falsas. A forma criada por Wright, de utilizar diagramas de caminho, foi utilizada em 1953 por Herbert Simon, inspirando várias pesquisas em ciências sociais. As descobertas de Wright foram excepcionais para a ciência, pois trouxeram vários resultados, que consistiam em duas linguagens matemáticas diferentes e quase incompatíveis: a linguagem dos diagramas e a linguagem dos dados. Mas o que aliviava Wright, e era a certeza de que ele estava

na direção correta, se deve a seu entendimento de que ele respondia a perguntas que não podiam ser respondidas de outra maneira. Caracterizar a importância relativa de vários fatores era uma dessas questões. Em 1972, o economista Arthur Goldberger reclamou sobre a "negligência escandalosa" do trabalho de Wright durante aquele determinado período e constatou, com euforia de um convertido, que "a abordagem [de Wright]... estabeleceu uma recente corrida a modelagem causal na sociologia". Fisher era um papa da estatística, na qual existia uma rivalidade entre Fisher-Wright que não era a análise do caminho, mas a biologia evolutiva. Fisher discordou da teoria de Wright qualificada como "genética deriva" na qual uma espécie pode evoluir rapidamente quando passa por um gargalo populacional.

Os destinos da análise do caminho nas áreas da sociologia e na economia trilharam percursos distintos, cada um se divergindo das idéias de Wright. Os sociólogos modificaram a análise de caminho como modelagem de equações estruturais, sem utilizar os diagramas até 1970, foi quando um programa computacional denominado LISREL mecanizou alguns cálculos dos coeficientes de caminho. Outro crítico as teorias de Wright foi Karlin que fez a seguinte citação: "pensamos da forma mais proveitosa, pode-se adotar uma abordagem essencialmente livre de modelos, buscando entender os dados de forma interativa usando uma bateria de exposições, índices, e contrastes". Um razão da refutação de Wright que foi motivo de resistência dos estatísticos à causalidade. Foi o fato de não querer, que a análise do caminho se tornasse "estereotipada". Conforme Wright, "a abordagem não estereotipada da análise de caminho difere profundamente dos modos estereotipados de descrição projetados para evitar qualquer desvio da objetividade completa". Lamentavelmente, a aceitação da subjetividade bayesiana nas estatísticas convencionais não colaborou em nada para o entendimento da subjetividade causal, que era necessária para especificar um diagrama de caminho. O diagrama causal significa dizer que faz parte da rede bayesiana onde cada seta significa uma relação causal direta, ou seja, é ao menos uma possibilidade, na direção daquela seta. Porém nem todas as redes bayesianas são causais e, em algumas ações, isso não tem significado. Entretanto, para fazer uma consulta de segundo ou terceiro degrau sobre sua rede bayesiana, deve buscar com cautela à causalidade. Bayes e o problema de inverso de probabilidade: Thomas Bayes, não imaginava que uma fórmula que ele derivou na década de 1750 seria utilizada para identificar vítimas de desastres. Na verdade, sua preocupação era apenas com as probabilidades de dois eventos, a hipótese e a evidência. Contudo, a causalidade sempre estava em sua mente. Na realidade, as aspirações causais tornaram seu estímulo na sua análise da "probabilidade inversa". Para Bayes que foi ministro presbiteriano, uma frase ocasionou um problema natural: Quanta evidência seria necessária para nos convencer de que algo que consideramos improvável realmente aconteceu? Neste caso uma hipótese ultrapassou a linha da impossibilidade à improbabilidade e até mesmo à probabilidade ou certeza virtual? Apesar da questão tenha sido elaborada na linguagem da probabilidade, as consequências foram direcionadas a área da teologia, provavelmente pela formação religiosa de Bayes. Segundo ele, o propósito é descobrir a razão para a crença sobre a criação de todas as coisas, para ele, é por conta das leis fixas, que as coisas acontecem, por

consequente, o formato do mundo deve ser a consequência da sabedoria e do poder de uma causa inteligente; é nesse sentido, que confirma a lógica extraída das causas finais para a existência divina. Um artigo de Bayes é citado e debatido cerca de 250 anos depois, não com um propósito teológico, mas pelo fato de apresentar a dedução da probabilidade de uma causa a partir de um efeito. Para ele, se sabemos a causa, é fácil estimar a probabilidade do efeito, que é uma probabilidade direta. A regra de Bayes é apresentada pela equação: $P(S|T) = P(T|S)P(S)$. Se verificarmos com atenção no que ela representa, encontraremos uma resposta para o problema da probabilidade inversa. Se começemos a probabilidade de S dado T, $P(S|T)$, somos capazes de entender a probabilidade de T dado S, $P(T|S)$, considerando, que sabemos $P(T)$ e $P(S)$. É uma maneira de explicar a nossa crença baseada em uma hipótese particular. É muito importante compreender, porque parte da credence humana sobre acontecimentos futuros apresenta-se na repetição com que eles acontecem ou ações semelhantes que ocorreram no passado. Matematicamente, isso é o princípio de Bayes. Apresenta-se de forma trivial. Configura-se em uma básica definição de probabilidade condicional, com uma dose da velha lógica grega. E como um artifício tão simplório pode tornar Bayes tão importante para a ciência e por que os pesquisadores têm debatido sobre essa lógica há pelo menos 250 anos. Por fim, acredita-se que os argumentos matemáticos resolvam os problemas, e não os gerem. Como se pode observar a regra de Bayes é um resultado básico de sua teoria da probabilidade condicional. Epistemologicamente, está distante de ser simples. Opera, efetivamente, como um princípio normativo para inovar as crenças em resposta às evidências. Em vários contextos, a regra de Bayes é uma consequência do método científico aplicado. A discriminação do formato científico no livro didático é aproximadamente da seguinte maneira: (1) formular uma hipótese, (2) deduzir uma consequência testável da hipótese, (3) realizar um experimento e coletar evidências e (4) atualizar sua crença na hipótese. Da regra de Bayes às redes bayesianas: Apesar de Bayes não saber, sua norma para probabilidade inversa significa a rede bayesiana no formato mais simples. A disseminação de crenças atua sempre da mesma forma, sejam as flechas não causais ou causais. Entretanto, pode se ter o sentimento intuitivo de que foi realizado algo mais importante no último caso do que no primeiro. Isso acontece porque nossos cérebros são providos com um mecanismo excepcional para entender as relações de causa e efeito (como câncer e mamografias). Diferente para as triviais associações (como chá e scones). As redes bayesianas cujo, o diagrama e suas setas que direcionam da causa para o efeito. De fato, o diagrama funciona como uma mola impulsora da rede bayesiana. Porém, precisa de um combustível, que é a tabela de probabilidade condicional. Para converter o diagrama causal em uma rede bayesiana, precisamos indicar as tabelas de probabilidade condicional. A função das redes Bayesianas é a resolução de problemas de probabilidade inversa: se x minutos se passaram e ainda não peguei minha bolsa, qual é a probabilidade de ela estar no avião? A regra de Bayes resolve essa cifra e indica um critério relevante. Resposta: Após um minuto, há ainda 47 por cento de possibilidade de que estivesse no avião. Logo depois de cinco minutos, a probabilidade cai para 33 por cento. Em seguida aos dez minutos, ele cai para zero. As redes bayesianas se transformaram em uma grande teia da tecnologia, onde através do software a sua

lógica é utilizada por várias empresas, que também empregam os sistemas embutidos em vários outros aparelhos “inteligentes”. A visibilidade das redes bayesianas se diferencia das outras interpretações de aprendizado de máquina, que tem uma inclinação a gerar “caixas pretas” impenetráveis. Para entender uma rede Bayesiana, é necessário seguir todas as etapas e compreender como e por que cada indicador modificou as crenças da rede. As diferenças elementares entre as redes bayesianas e os diagramas causais estão na elaboração e utilização. Uma rede bayesiana é textualmente uma reprodução compacta de uma grande tabela de probabilidade. As setas indicam unicamente que as probabilidades dos nós filhos estão relacionadas aos valores dos nós pais por uma fórmula (as tabelas de probabilidade condicional) e que essa relação é suficiente. Traduzindo, conhecer antepassados adicionais da criança não modificará a fórmula. Igualmente, uma seta perdida entre quaisquer dois nós revela que eles são independentes, uma vez que conhecemos os valores de seus pais. Uma forma adequada de pensar sobre o modelo causal é no formato de experimentos hipotéticos. Onde cada seta pode ser vista como uma declaração sobre o resultado de um experimento hipotético. O raciocínio causal que constitui a elaboração da rede causal somente é viável, somente se, no tipo de perguntas que a rede pode responder. No entanto uma rede bayesiana pode apenas responder a probabilidade de um evento, e os diagramas causais explicam as questões de intervenção e contrafactuais. Possivelmente, o mais importante impacto, das redes bayesianas é a inferência causal. As descobertas entre o arranjo gráfico do diagrama e os dados que ele simboliza agora nos autorizam emular a agitação sem fazer isso fisicamente. Exclusivamente, a utilização de uma série inteligente de procedimentos de condicionamento nos concede prever o efeito das ações ou intervenções sem necessariamente realizar um experimento. Sobre os experimentos causais: Constitua dois grupos de indivíduos, similares em todos os aspectos importantes. Atribua a um grupo um novo tratamento (uma dieta, um medicamento, etc.), em oposição monte outro grupo (chamado de grupo de controle) recebe o tratamento antigo ou nenhum tratamento especial. Após, um tempo adequado, se possa visualizar uma alteração verificável entre os dois grupos aparentemente semelhantes de pessoas, então o novo tratamento deve ser o motivo da diferença. Na atualidade, denominamos isso de experimento controlado. No experimento temos alguns propósitos a considerar: Exemplificando, o viés de confusão que ocorre quando uma variável influencia tanto quem é selecionado para o tratamento e o resultado do experimento. Raramente, os fatores de confusão são reconhecidos; ocasionalmente, são apenas suspeitos e agem como uma “terceira variável à espreita”. Entretanto, em um diagrama causal, os fatores de confusão são extremamente fáceis de identificar. Todavia, o inverso também é verdadeiro. Com as medidas da terceira variável, é muito simples desconstruir os efeitos verdadeiros e espúrios. Portanto, se a variável de confusão é a idade, confrontamos os grupos de tratamento e controle em cada parcela etária isoladamente. Feito isso, se consegue, alcançar uma média dos efeitos, analisando cada faixa etária conforme a sua porcentagem do público-alvo. Objetivamente, a Revolução Causal foi ainda mais longe. Em determinados casos, é possível controlar a confusão, da mesma forma, quando não se tem os dados em um conjunto adequado. Nesses casos específicos, utilizamos fórmulas de ajuste diferentes - não a convencional, que só é pertinente

para utilização com o critério da porta dos fundos, e eliminar todos os fatores de confusão. É integralmente a arte e prática da experimentação científica, e se compreende no hábil interrogatório da Natureza. A análise proporciona ao cientista uma imagem da natureza em determinado aspecto, que tem todas as imperfeições de uma declaração voluntária. Onde se deseja aferir as interpretações, fazendo perguntas essenciais direcionadas a estabelecer as relações causais. Em meados de 1923/1924, Fisher entendeu que apenas um projeto experimental que a genialidade não poderia vencer era um aleatório. Conceba fazer o mesmo experimento mais de cem vezes em uma área com uma distribuição de fertilidade desconhecida. Em um tempo em que os estudos clínicos randomizados são o padrão ouro, tudo isso pode parecer evidente. Porém, na época, a concepção de um experimento ilustrado aleatoriamente apavorou os colegas estatísticos de Fisher. A razão de Fisher entender de um baralho de cartas para atribuir subtramas a cada fertilizante pode ter ajudado para essa descoberta. A ciência está compelida aos desejos do acaso? No entanto, Fisher compreendeu que uma resposta incerta para a pergunta certa é muito melhor do que uma resposta altamente certa para a pergunta errada. Por conseguinte, a randomização verdadeiramente traz duas vantagens. Primeiro, elimina o preconceito do fator de confusão (faz a pergunta certa à Natureza). Em segundo lugar, proporciona ao pesquisador quantificar sua incerteza. Por sorte, o faz-operador (modelo de experimento) nos proporciona várias formas cientificamente consolidadas, de aferir os efeitos causais de estudos não experimentais, que suscitam a soberania convencional, dos ensaios clínicos randomizados. Ainda que, o fator de confusão seja extensivamente aceito, como um das questões fundamentais na pesquisa, um levantamento das referências literárias indicará escassa regularidade entre os conceitos de fator de confusão ou fator de confusão. Na ausência de um entendimento sobre os princípios de confusão, os pesquisadores não podiam afirmar nada importante nos estudos observacionais em que o controle físico sobre os tratamentos é inviável. O motivo do problema é que confundir não é uma noção estatística. Retrata a divergência entre o que queremos avaliar (o efeito causal) e o que realmente avaliamos utilizando as técnicas estatísticas. Um trabalho de 1996 do norueguês Sven Hernberg diz que “Formalmente, pode-se comparar o risco relativo bruto e o risco relativo resultante após o ajuste para o potencial fator de confusão”. Ou seja, uma distinção configura uma confusão e, nesse caso, recomenda-se utilizar a estimativa de risco ajustada. Robins e a Groenlândia iniciaram o seu entendimento de confusão no formato de resultados potenciais. Eles separaram a população em quatro tipos de indivíduos: condenados, causadores, preventivos e imunes. Esses achados foi uma grande descoberta, pois possibilitou dar exemplos explícitos que apresentam que os conceitos anteriores de confusão eram descabidos. Compreender o método da porta dos fundos contribui para se ter uma base de intuição de como a informação resulta em um diagrama causal. Raras são às vezes em uma trajetória acadêmica, que saímos vitoriosos, quando se tem um problema que intrigou e perturbou gerações de pesquisadores e pode ser resolvido através de um jogo ou algoritmo simples. A resposta completa da questão do “confuso” foi um dos principais problemas da revolução causal, porque finalizou um tempo de conflitos que certamente decorreu em muitas decisões erradas no passado. Tratou-se de uma revolução, que ocorreu

essencialmente nos laboratórios de pesquisa e reuniões científicas. O compromisso da ciência é deixar o achismo a parte e se direcionar para os fatos. Em 1948, Doll e Austin Bradford Hill se juntaram para pesquisar sobre as razões da epidemia de câncer. Hill foi um renome da estatística, publicou neste mesmo ano, um artigo clínico randomizado e controlado, provando que a estreptomicina um dos primeiros antibióticos, era capaz de combater a tuberculose. A investigação, uma grande realização na história da medicina, pois, não só anunciou aos médicos as “drogas maravilhosas”, mas também estruturou a imagem das pesquisas clínicas randomizadas, que tornaram uma referencia para os estudos clínicos em epidemiologia. O formato da pesquisa conduzido por Doll e Hill foi denominado de estudo de caso-controle porque relaciona “casos” (pessoas com uma doença) a controles. É evidentemente um avanço em relação aos dados de série temporal, pois os cientistas podem controlar fatores de confusão como idade, sexo e exposição ao espaço poluído. Os epidemiologistas em 1950 passaram pela crítica que seus achados eram “apenas estatísticas”. Não existia qualquer “prova de laboratório”. Porém, olhando para a história, percebe-se que essa alegação era ilusória. Se o modelo de “prova laboratorial” fosse atribuído ao escorbuto, os marinheiros permaneciam sucumbindo até a década de 1930, porque até a criação da vitamina C não existia “prova laboratorial” de que as frutas cítricas previassem o escorbuto. Ademais, na década de 1950, surgiram várias espécies de prova laboratorial dos efeitos do tabagismo surgiram em revistas médicas. Os ratos pintados com alcatrão de cigarro desenvolveram câncer. Foi confirmado que a fumaça do cigarro é carcinógeno. Esses experimentos potencializaram a razoabilidade da hipótese de que fumar pode causar câncer. Como os cientistas não tinham um conceito objetivo da palavra “causa” e nenhum jeito de definir um efeito causal exceto com um ensaio clínico randomizado, eles eram despreparados para uma discussão sobre se fumar causava câncer. Eles foram obrigados seguir em direção do processo que durou entre 1950 e 1964. Em meados de 1965, Austin Bradford Hill, tentou simplificar os argumentos causais em um formato que pudesse ser utilizada em outros tipos de problemas de saúde pública. Observado sobre o sentido da saúde pública, o relatório do comitê consultivo foi um entendeu que o cigarro causa o câncer. Em seguida, o congresso obrigou que os fabricantes inserissem recomendações de saúde em todos os maços de cigarros. Em 1971, a publicidade de cigarros foi extinta do rádio e da televisão. A porcentagem de adultos americanos fumantes reduziu de seu máximo histórico de 45% em 1965 para 19,3% em 2010. Diversas pesquisas já haviam revelado que os bebês de mães fumantes pesavam menos ao nascer, em média, do que os bebês de não fumantes, e era normal imaginar que isso se revertia em uma menor sobrevivência. Estatísticos e epidemiologistas persistiam em investigar o paradoxo em termos probabilísticos e vê-lo como uma anomalia peculiar ao peso ao nascer.

Em 1946, Joseph Berkson, um bioestatístico da Clínica Mayo, exibiu uma particularidade nas pesquisas observacionais geridas em um meio hospitalar: diante de duas doenças que não possuam relação entre si na população em geral, elas parecem estar relacionadas entre os pacientes em um hospital. Em 1979, quando David Sackett, da Universidade McMaster, um especialista em várias tipologias de vieses estatístico, conferiu evidências de que o paradoxo de Berkson é real. Em um exemplo, ele investigou dois grupos de doenças: respiratórias e ósseas.

Aproximadamente 7,5 por cento das pessoas na população em geral têm alguma doença óssea, e esse percentual é independente de elas terem doenças respiratórias. Porém para pessoas já hospitalizadas com doenças respiratórias, a regularidade de doenças ósseas amplia para 25%! Sackett denominou esse fenômeno de “viés da taxa de admissão” ou “viés de Berkson”. No livro “A direção do tempo”, publicado em 1956, o filósofo Hans Reichenbach realizou uma prognóstico ousado denominada de “princípio de causa comum”. Contestando o pensamento “Correlação não implica causalidade”, Reichenbach impetrou com a ideia: “Nenhuma correlação sem causação.” Ele disse que uma correlação entre duas variáveis, X e Y, não pode ocorrer por acidente. Qualquer uma das variáveis causa a outra, ou uma terceira variável, digamos Z, precede e causa os dois. Por vários anos, não houve o convencimento da comunidade científica de que a confusão sobre o paradoxo de Simpson é consequência da utilização errada dos princípios causais a proporções estatísticas. Se utilizarmos a notação causal e diagramas, somos capazes de decidir no formato claro e evidente se o D previne ou causa ataques cardíacos. Basicamente, o paradoxo de Simpson é uma parábola sobre confusão e consegue ser resolvida pelos mesmos modos que temos para solucionar outros mistérios. Na visão dos estatísticos profissionais que utilizam os números todos os dias de suas vidas, existe menos motivo para pensar a reversão de Simpson um paradoxo. Há grande contradição no entendimento da teoria de Simpson, e muitos estatísticos tomam o cuidado de evitá-lo. Frequentemente, essas técnicas evitam o problema, a reversão de Simpson, sem realizar nada sobre a doença, é o que causa a confusão. Ao invés de eliminar os sintomas, temos que dá atenção a eles. O paradoxo de Simpson nos chama atenção para os casos em que uma das propensões estatísticas não representa os efeitos causais. Há, evidentemente, outros sinais de alerta de confusão. É de fácil compreensão o trabalho com diversas variáveis. Se o conjunto de variáveis Z deve ocorrer para atender a condição de porta dos fundos, então o coeficiente de X na equação de regressão, uma, será o efeito causal médio de X em Y. Por esse motivo, gerações de estudiosos passaram a crer que os coeficientes de regressão ajustados (ou parciais) são de alguma maneira, compostos de informações causais que faltam aos coeficientes de regressão não ajustados. Estando longe da verdade. Os coeficientes de regressão, ajustados ou não, são somente tendências estatísticas, sem disseminar nenhuma informação causal entre elas. O formato $r_{YX.Z}$ identifica o efeito causal de X em Y, enquanto r_{YX} não, tão somente, porque temos um diagrama apresentando Z como um confundidor de X e Y. Em resumo, muitas vezes um coeficiente de regressão simboliza um efeito causal, e às vezes não, e não podemos acreditar somente nos dados, para lhe apresentar as diferenças. Dois elementos adicionais são fundamentais para dotar $r_{YX.Z}$ com legitimidade causal. Primeiramente, o diagrama de caminho deve representar uma aceitável identificação da realidade e, em segundo lugar, as variáveis ajustadas Z devem atender o critério da porta dos fundos. É por essa razão que era tão significativa para que Sewall Wright identificasse os coeficientes de caminho (que retratam efeitos causais) de coeficientes de regressão (que constituem tendências de pontos de dados). Os coeficientes de caminho são essencialmente diferentes dos coeficientes de regressão, contudo muitas vezes podem ser calculados a partir do último. Analisando o processo decisório se o exercício físico é benéfico ou

prejudicial, normalmente, necessitamos refletir sobre história por trás dos dados. Os dados exibem que os idosos em nossa população praticam mais exercícios. É mais provável que a idade traga o exercício, e como a idade pode ter um efeito causal sobre o colesterol, deduzimos que a idade pode ser um fator de confusão entre exercício e colesterol. Consequentemente, devemos controlar por idade. Em outros termos, devemos ter um olhar para os dados segregados por idade e inferir que o exercício é benéfico, independentemente da idade. Sobre os pontos mais delicados do paradoxo de Simpson e do princípio da coisa certa, é que o princípio da coisa certa atua exclusivamente nos casos em que a parte referente a cada subpopulação não modifica de grupo para grupo. Nesse contexto, no caso de Lord, o “tratamento” (gênero) atinge intensamente o percentual de alunos em cada classe de peso. Para muitos estudiosos, a técnica mais comum de conjecturar o efeito de uma intervenção é “controlar” os fatores de confusão utilizando a fórmula de ajuste. É o melhor formato a ser utilizado, tendo certeza de que possui os dados necessários do conjunto de variáveis, para bloquear todos os caminhos alternativos entre a intervenção e o resultado. Para essa realização, mensuramos o efeito causal médio de uma intervenção estimando primeiro seu efeito em cada “nível” ou estrato do desconfundidor. Seguindo, calculamos uma média ponderada desses estratos, onde cada um é ponderado de acordo com sua prevalência na população. Em várias situações, as variáveis X, Y, ou Z pegue valores numéricos - por exemplo, renda ou altura ou peso ao nascer. Esse é um exemplo visual do paradoxo de Simpson. Como a variável pode assumir (pelo menos, para todos os fins práticos) valores infinitos possíveis. Uma resposta rápida é separar os valores numéricos em um número finito e gerenciável de categorias. Porém, não existe nada de errado com essa opção, mas a escolha das categorias é um pouco fortuita. Ruim, é se tivermos muitas variáveis ajustadas, obteremos uma explosão exponencial no número de categorias. Dessa forma tornará a sistemática computacionalmente proibitiva; ainda pior, muitos dos estratos ficarão desprovidos de amostras e, por seguinte, ineficientes de fornecer quaisquer estimativas de probabilidade. A função de suavização mais largamente utilizada é, claramente, uma aproximação linear, que foi o carro-chefe da maioria dos trabalhos quantitativos nas ciências sociais e comportamentais no século XX. Vejamos como Sewall Wright colocou seus diagramas de caminho na conjuntura de equações lineares e notasse uma vantagem computacional dessa colocação: todo efeito causal pode ser representado por um único número (o coeficiente de caminho). Outra e tão quanto importante vantagem das aproximações lineares é a admirável simplicidade de calcular a fórmula de ajuste. É fácil a compreensão, que existe o meio para lidar com várias variáveis também. Que se o conjunto de variáveis Z deve ocorrer para satisfazer a condição de porta dos fundos, então o coeficiente de X na equação de regressão, uma, será nada menos que o efeito causal médio de X em Y. O grande desafio de Sewall Wright era distinguir entre os coeficientes de caminho e os coeficientes de regressão. Os coeficientes de caminho são essencialmente distintos dos coeficientes de regressão, contudo em várias possibilidades possam ser calculados a partir do último. Wright errou em perceber, porém, como todos os pesquisadores de caminhos e econometristas após ele, que seus cálculos eram demasiadamente complexos. Ele poderia ter alcançado os coeficientes de caminho por meio dos coeficientes de correlação parcial, se tivesse

conhecimento que o conjunto adequado de variáveis de ajuste pode ser conhecido, por inspeção, por meio do próprio diagrama de caminho. Pode-se avaliar cada um dos Faz-probabilidades, debatidas a partir dos dados. Ou melhor, somos capazes de escrever matematicamente em expressão de probabilidades que não incluem o Faz-operador. Assim sendo, a matemática faz por nós o que em uma década de debate e depoimentos no congresso não conseguiram: quantificar o efeito causal do tabagismo sobre o câncer. Freedman também acreditou ser incerto que o fumo cause o câncer somente por meio do alcatrão. Provavelmente, outros meios poderiam ser subentendidos; possivelmente fumar provoque uma inflamação crônica que leva ao câncer. Por fim, disse ele, os resíduos de alcatrão nos pulmões de uma pessoa viva não são capazes de ser medido com exatidão - consequentemente, um estudo observacional como o que propus não pode ser realizado no mundo real. Ainda bem, que as vantagens do ajuste na porta da frente não foram integralmente desprezadas. Em 2014, Adam Glynn e Konstantin Kashin, todos cientistas políticos de Harvard, publicaram um artigo que foi premiado e deveria ser leitura obrigatória para todos os cientistas sociais quantitativos. Eles utilizaram o novo método a um grupo de dados conferidos por cientistas sociais, chamado Job Training Partnership Act (JTPA) Study, conduzido de 1987 a 1989. Como consequência do JTPA de 1982, o Departamento de Trabalho instituiu um plano de treinamento profissional que, entre várias atividades, proporcionou aos participantes habilidades ocupacionais, habilidades de busca de emprego e experiência de trabalho. Nas circunstâncias da pesquisa, os serviços sempre estiveram à disposição, entretanto quando Glynn e Kashin testaram o critério da porta da frente de qualquer maneira, associamos esse momento como um teste de sensibilidade. Se entendermos que a seta do meio é fraca, a probabilidade inicial por tratá-la como ausente pode ser muito pequena. Realizando suposições aceitáveis, Glynn e Kashin derivaram desigualdades anunciando se o ajuste provavelmente seria muito alto ou muito baixo e em quanto. Enfim, eles associaram as previsões da porta da frente e as previsões da porta dos fundos com as respostas do experimento controlado aleatório que foi executado ao mesmo tempo. Os resultados foram surpreendentes. Em contrapartida, as estimativas preliminares removeram quase todo o efeito Motivação. Para os homens, as deduções iniciais estavam dentro do erro experimental do ensaio controlado randomizado, com o pequeno viés positivo que Glynn e Kashin já presumiam. Para as mulheres, os desfechos foram ainda melhores: as estimativas iniciais equiparam-se ao benchmark experimental quase perfeitamente, sem viés visível. A possibilidade de fazer determinações, através do formato exclusivamente matemático deve encantar qualquer indivíduo que compreenda o valor e o sacrifício de efetuar ensaios clínicos randomizados, até quando eles são fisicamente viáveis e formalmente permitidos. No raciocínio da matemática, conhecido como o "problema de decisão". Várias concepções lógicas são afetadas por problemas de decisão complexas. Por exemplo, dada uma pilha de dominós de vários tamanhos, não temos a melhor maneira de escolher se podemos organizá-los para completar um quadrado de um determinado tamanho. Em meados de 2005, Wermuth e Cox se interessam por uma questão intitulada "decisões sequenciais" ou "tratamentos que variam no tempo", sociais, por exemplo, o tratamento da AIDS. Naturalmente os cuidados são gerenciados ao longo de um tempo e, a cada período, os médicos avaliam a

evolução e a dosagem do tratamento conforme as condições do paciente. Porém, com a interpretação de Spirtes sobre a exclusão de equações para o mundo dos diagramas causais provocou uma enxurrada de novos insights e novos resultados. A metodologia da porta dos fundos foi uma das primeiras favorecidas com a tradução, em contrapartida o Faz-cálculo vem em seguida. A sucessão de ideias, ainda não terminou. Progressos em campos como contrafactuais, generalizabilidade, dados ausentes e aprendizado de máquina ainda estão acontecendo. As estatísticas de mortalidade corroboram com a hipótese assustadora de Snow. As províncias assistidas pela Southwark and Vauxhall Company foram essencialmente contaminados pelo cólera e obtiveram uma taxa de mortalidade oito vezes maior. Contudo, os indícios eram meramente circunstanciais. Um proponente da teoria do miasma deveria alegar que o miasma era mais potencial nesses distritos e não haveria como contestá-lo. Não observamos o fator de confusão Miasma (ou outros fatores de confusão como Pobreza), então não podemos controlá-lo usando o ajuste da porta dos fundos. Apesar da teoria do miasma já tenha sido desprestigiada, a pobreza foi, um fator de confusão, bem como a localização. Porém mesmo sem medi-los, ainda se podem utilizar variáveis instrumentais para determinar quantas vidas teriam sido salvas purificando o fornecimento de água. Variáveis instrumentais já eram familiares antes da Revolução Causal, mas os diagramas causais apresentaram uma nova clareza a sua utilização. De fato, Snow estava utilizando uma variável instrumental oculta, apesar de não tiver uma fórmula quantitativa. Sewall Wright seguramente compreendeu o uso de caminhos através de diagramas; a fórmula $b = r_{ZY} / r_{ZX}$ pode ser derivada diretamente de seu método de coeficientes de caminho. A primeira droga transformadora do colesterol exposta a um ensaio clínico randomizado foi a colestiramina. O Coronary Primary Prevention Trial, iniciado em 1973 e concluído em 1984, apresentou uma redução de 12,6% no colesterol entre os homens que receberam a droga colestiramina e uma redução de 19% no risco de ataque cardíaco. Os métodos de variáveis instrumentais permaneceram em desenvolvimento desde 1984, e um modelo se tornou popular: a randomização Mendeliana. Por exemplo: ainda que o efeito do LDL, ou colesterol “ruim” esteja solucionado, ainda existe uma incerteza sobre a lipoproteína de alta densidade (HDL), ou colesterol “bom”. Os estudos iniciais, como o Framingham Heart Study no final da década de 1970, sugeriram que o HDL tinha a finalidade contra ataques cardíacos. Considerando a análise causal, temos o seguinte ensinamento: em qualquer estudo de intervenções, necessitamos perguntar se a variável que estamos de fato manipulando é a mesma que julgamos estar manipulando. Faz parte do “interrogatório habilidoso da natureza”. A análise contrafactual sugere que os pesquisadores do clima realizem declarações muito mais determinísticas e categóricas do que antes. Exige, entretanto, uma adição ao nosso dicionário habitual. Será importante diferenciar três tipos distintos de causalidade: necessário causalidade, suficiente causalidade, e necessário e suficiente causalidade. De acordo com o conceito do contrafactual que faz parte do sistema mental, que nos identifica como humanos, não causa surpresa que possamos descobrir opiniões contrafactuais tão remotas na história da humanidade. Para achar um filósofo que colocou os contrafactuais no centro da causalidade, temos de buscar David Hume, o filósofo recusou a estrutura de Aristóteles e persistiu em um

significado de causalidade. Porém ele entendeu que esse conceito muito impreciso. Posteriormente, essa compreensão se transformaria em convicções incompatíveis, que ironicamente poderiam referenciar David Hume como sua fonte! É importante refletir sobre o pensamento de Hume por conceituar as causas referentes aos contrafactuais, e não o contrário. As ideias têm como propósito diminuir um conceito mais complexo para um mais simples. Hume pressupõe que seus leitores compreenderão a afirmativa “se o primeiro objeto não tivesse sido, o segundo nunca existiu” com menos dúvida do que “o primeiro objeto causou o segundo”. Ele está certo. A última assertiva coloca todos os tipos de conjectura metafísica inútil sobre qual qualidade ou poder pertencente ao primeiro objeto gera o segundo. Contestando os métodos com a perspectiva do modelo causal, e examinando o que há de errado com a imputação cega do modelo. Particularmente, explicamos por que Bert e Caroline, que fazem uma combinação perfeita em conhecimento, são incomparáveis se tratando de confrontar seus resultados potenciais. O ponto-chave a identificar é que a experiência certamente provém da educação. Afinal de contas, os empregados que conseguiram um diploma educacional passaram quatro anos de suas vidas para essa realização. Desse modo, caso Caroline tivesse unicamente um título acadêmico (como Bert), ela seria capaz de utilizar esse tempo para obter mais experiência comparando com o que ela tem agora. Essa forma daria a ela equivalente educação e mais capacidade do que Bert. O modelo SCM que é para determinar os contrafactuais, não é o mesmo que Rubin utilizaria. Um dos itens fundamentais de distinção é a utilização de diagramas causais. São eles que permitem que os cientistas apresentem estimativas causais para que possam entender e, então, examinar todos os contrafactuais como propriedades derivadas de seu modelo de mundo. A informação funcional normalmente não estará disponível na prática. Geralmente, denominamos um modelo de “completamente especificado” se as funções por trás das setas são reconhecidas e “parcialmente especificadas” de outra maneira. Exemplificando, como nas redes bayesianas, conseguimos identificar apenas relações probabilísticas no gráfico. Se o molde for indicado com precisão pelo menos parcialmente, podemos não ser capazes de estimar com exatidão; Ao invés disso, podemos ter que fazer uma declaração de intervalo de probabilidade, mas mesmo com essas respostas probabilísticas, teremos o suficiente para muitas aplicações. A referência causal de Rubin trabalha os contrafactuais como objetos matemáticos que são operacionalizados por equipamentos algébricos. Outra estimativa do modelo de Rubin, também benéfica, é denominada de “consistência”. Ele propõe que o indivíduo que toma aspirina e se recupera também se recuperaria se ingerir aspirina por meio de um projeto experimental. Desprovido de uma interação gráfica, o operador do modelo causal de Rubin é frequentemente solicitado a consentir três suposições. A primeira, chamada “suposição de valor de tratamento de unidade estável”, ou SUTVA, é razoavelmente transparente. Anuncia que cada elemento ou unidade terá o mesmo efeito de tratamento, independentemente do tratamento que os outros elementos recebam. Em vários casos, excluindo epidemias e outras interações coletivas, isso faz muito sentido. A segunda suposição no modelo de Rubin, também benigna, é chamada de “consistência”. Estreitamente ligada à transparência está à noção de testabilidade. Um modelo projetado como um diagrama causal pode ser naturalmente testado para

compatibilidade com os dados, ao passo que um modelo entregue em linguagem de resultado potencial necessita desse recurso. O teste é seguindo esse formato: sempre que todos os caminhos entre X e Y no diagrama são fechados por um conjunto de nós Z, então nos dados X e Y deve ser independente, condicionado a Z. Essa postulação, que é uma teoria na constituição do SCM, afirma que o experimento está livre de efeitos placebo e outras imperfeições. A suspeita fundamental é que os operadores de resultados potenciais são inegavelmente obrigados a fazer a denominada "ignorabilidade". É mais técnico, mas é a parte crucial da transação, pois é, na prática, a mesma coisa que a condição de permutabilidade de Jamie Robins e Sander Greenland. Essa presunção, é uma teoria no arranjo do SCM, afirma que o experimento está isento de efeitos placebo e outros defeitos. Por infelicidade, Rubin não acredita em diagramas causais para "auxiliar no desenho de inferências causais". Consequentemente, os cientistas que acompanharem suas teorias ficarão ausentes desse teste de ignorabilidade e terão que fazer uma reengenharia mental perfeita para se satisfazer de que o prognóstico é válido ou simplesmente acatar o pressuposto como uma "caixa preta". Moderadamente, não existia nada de revolucionário em equações. Economistas e sociólogos utilizavam esses modelos desde os anos 1950 e 1960 e denominando-as de modelos de equações estruturais (SEMs). Mas essa nomenclatura apresentou conflito sobre a interpretação causal das equações. Com o passar do tempo, os economistas esqueceram os precursores desses modelos, Trygve Haavelmo na economia e Otis Dudley Duncan na sociologia, onde desejavam que representassem relações causais. Eles confundiam as equações estruturais com linhas de regressão, retirando assim a substância da forma. Uma distinção significativa entre SEMs e SCMs é que a relação entre causas e efeitos em um SCM não é absolutamente linear. Os métodos que surgem do estudo SCM são válidas tanto para funções não lineares como lineares, tanto variáveis discretas como contínuas. No começo, os contrafactuais devem ter fácil operacionalização no tribunal. Digo "em princípio" porque o trabalho jurídico é bastante conservador e levando tempo para acatar novos modelos matemáticos. Porém utilizar contrafactuais como uma maneira de exposição é, contudo, conhecida na área jurídica como "mas para causa". Os advogados compreendem uma lógica matemática que é uma referencia de prova muito alta. Nos casos criminais nos Estados Unidos, a Suprema Corte em 1880 determinou que a culpa deve ser provada "com exclusão de todas as dúvidas razoáveis". O tribunal disse não "além de todas as dúvidas" ou "além de uma sombra de dúvida", mas além de alguma dúvida razoável. Em 2003, os pesquisadores do clima não especulavam sobre complexos assuntos climáticos. Contudo a sabedoria popular era mais ou menos assim: "Embora esse seja o tipo de fenômeno que o aquecimento global pode tornar mais frequente, é impossível atribuir esse evento específico às emissões passadas de gases de efeito estufa." Myles Allen, da Universidade de Oxford e autor da citação acima, recomendou uma forma melhor de se calcular o clima: utilizar uma medida denominada fração de risco atribuível (FAR) para dimensionar as consequências da mudança do clima. O FAR significa somente os dados, ele não possui qualquer sentido causal. Ocorre, no entanto, sob dois pressupostos causais moderados, é equivalente a probabilidade de necessidade. Primeiramente, precisamos admitir que o tratamento (gases de efeito estufa) e o resultado (ondas de calor) são diferentes:

não há uma causa comum para cada um. Hannart vai mais adiante do que Allen e Stott e utiliza fórmulas incrementais para medir a probabilidade de suficiência (PS) e por necessidade (PN). Em se tratando da onda de calor europeia de 2003, ele desvendou que PS foi muito baixo, sobre 0,0072, o que reflete que não teria como determinar que esse evento ocorresse neste ano. Surge uma questão natural: o quanto podemos acreditar nas simulações de computador? A resposta tem divisões políticas, particularmente nos Estados Unidos. Entretanto, segue uma explicação imparcial. A função de argumentação é muito mais segura do que os modelos lineares que temos com frequência nas ciências naturais e sociais. Os modelos lineares são escolhidos sem qualquer razão além da conveniência. Comparando, os modelos climáticos representam mais de um século de pesquisas por físicos, meteorologistas e cientistas do clima. Eles constituem os melhores empenhos de um grupo de cientistas para entender os processos que governam nosso tempo e clima. Entender que os contrafactuais são um fragmento fundamental de como os humanos descobrem sobre o mundo e como nossas ações o impactam. Porém, não podemos andar nos dois caminhos, ambos divergem em vários casos, mas podemos entender, com alguma confiança, o que existe em cada lugar. Certamente, a diversidade e a abundância de consultas causais que se apresenta ao “mecanismo de inferência” são potencializadas quando podemos introduzir contrafactuais na mistura. A procura por procedimento é necessária para a ciência, bem como para a vida habitual, porque diferentes instrumentos exigem diversificadas atitudes quando as situações modificam. Considere que nossas laranjas sejam extintas. Identificando o procedimento pelo qual as laranjas atuam, ainda podemos prevenir as doenças que carecem da referida vitamina. Apenas, temos que substituir a substância por outro fortificante. Caso, se não soubermos o mecanismo, nada teríamos para substituir. Em síntese, nas últimas décadas, a Revolução Causal desvendou diversas formas para avaliar quanto um efeito é direto e quanto é indireto. Modificou a relação de uma definição mal entendida com aceitação duvidosa em um instrumento comum e largamente utilizado para a análise científica. Um dos principais modelos de experimento controlado foi à pesquisa do capitão do mar James Lind sobre o escorbuto, publicado em 1747. No tempo de Lind, o escorbuto era uma enfermidade apavorante, que deve ter matado aproximadamente 2 milhões de marinheiros entre 1500 e 1800. Lind sugeriu uma dieta de frutas cítricas, e com isso, interrompeu que os marinheiros desenvolvesse essa triste doença. Já nos anos de 1800, o escorbuto virou um problema do passado para a marinha inglesa, pois todos os seus navios saíam para o mar com uma provisão suficiente de frutas cítricas. Este episódio é lembrado nos livros de história, em comemoração uma grande vitória do método científico. O primeiro indivíduo a simbolizar categoricamente um mediador com um diagrama foi uma estudante de graduação de Stanford chamada Barbara Burks, em meados de 1926. Essa desbravadora feminina é uma das verdadeiras heroínas da história da ciência. Existem vários motivos para crer que ela verdadeiramente criou os diagramas de caminhos independentemente de Sewall Wright. Em se tratando da mediação, ela estava à frente de Wright e décadas a diante de seu tempo. É admirável idealizar o que Burks poderia ter se transformado, caso, ela não tivesse sido uma vítima de seu tempo. Após obter o doutorado, ela nunca alcançou um trabalho como professora em uma universidade, a qual estava extremamente

qualificada. Ela teve que se satisfazer com cargos de pesquisa menos visíveis, na Carnegie Institution. Em 1942, ela ficou noiva, o que se poderia esperar que representasse uma melhora em sua fortuna; em vez disso, ela entrou em profunda depressão. Em 1973, Eugene Hammel, reitor associado da Universidade da Califórnia, reconheceu uma propensão muito preocupante os percentuais de admissão de homens e mulheres na universidade. Os dados apresentam que 44% dos homens que se inscreveram para a pós-graduação em Berkeley foram aceitos, comparando com apenas 35% das mulheres. O preconceito de gênero estava atraindo a atenção do público, e Hammel não queria aguardar por problemas. Então ele resolveu averiguar os motivos da discrepância. Verdadeiramente, Bickel e Hammel descobriram uma história causal que os deixou inteiramente satisfeitos. Eles publicaram um artigo, na revista *Ciência* em 1975, expondo uma simples explicação: as mulheres eram desclassificadas em maior número porque se procuravam os cursos mais concorridos dos departamentos que eram mais difíceis de entrar. Em Carson v. Bethlehem Steel Corp. (1996), o Tribunal do Sétimo Circuito escreveu: “A questão central em qualquer caso de discriminação no emprego é se o empregador teria tomado a mesma ação se o empregado fosse de uma raça diferente (idade, sexo, religião, nacionalidade, etc.) e tudo o mais tinha sido o mesmo”. Essa descrição expressa nitidamente a ideia de que devemos eliminar ou “congelar” todos os canais causais que direcionam o gênero à admissão por meio de qualquer outra variável. Melhor dizendo, a discriminação é igual ao efeito direto do gênero no resultado da admissão. Em sua carta a Bickel, Kruskal indicou que a relação entre o Departamento e o Resultado poderia ter um elemento de confusão não mensurado, como o Estado de Residência. Ele descreveu um modelo numérico para uma universidade hipotética com dois departamentos que tem discriminação de sexo que constituem precisamente os mesmos dados do modelo de Bickel. Ele fez isso considerando que os departamentos recebem todos os homens e mulheres de fora do estado e recusam todos os homens e mulheres de fora e que essa é sua única forma de decisão. Obviamente, essa dinâmica de entrada é um exemplo evidente de discriminação. Mas como o número total de postulantes de cada gênero aceitos e rejeitados era precisamente o mesmo que no exemplo de Bickel. Em estudos Burks e Kruskal foram inusitados em admitir a falácia da mediação como um erro grosseiro, apesar não ter apresentado uma solução. RA Fisher sofreu do mesmo erro em 1936 e, oitenta anos depois, os estatísticos ainda batalham com o problema. Por sorte, ocorreram grandes avanços desde a época de Fisher. Os epidemiologistas sabem que é necessário estar vigilante para os confundidores entre mediador e resultado. Entretanto, os que fogem da linguagem dos diagramas reconhecem que é muito difícil explicar os resultados. Ainda bem, que uma possibilidade reduz os problemas do experimento supercontrolado. Orientamos os candidatos a informar um gênero aleatório, porém a se inscrever no departamento de preferência. Denominamos essa ação de efeito direto natural (EQM), onde cada candidato termina em um departamento de sua escolha. A expressão “teria” é uma dica de que a descrição integral da EQM requer contrafactuais. O efeito direto natural simboliza uma dificuldade maior, porque não pode ser determinado em um Faz-expressão. Necessita da linguagem dos contrafactuais e, conseqüentemente, não pode ser estimado utilizando o Faz-cálculo. Quando se utiliza a fórmula da EQM se atinge a

todos os seus subscritos contrafactuais, com os resultados, e a fórmula de mediação, torna a EQM um instrumento prático porque pode estimar a partir de dados observacionais. Os estatísticos realizaram estudos durante muito tempo para estabelecer os efeitos indiretos, se um único contrafactual já era considerado enigmático, então os contrafactuais com aninhamento duplo estavam completamente fora do contexto. Em 1986, Reuben Baron e David Kenny promoveram uma relação de conceitos para detectar e avaliar a intervenção em um sistema de equações. Os fundamentos são, primeiro, que as variáveis estão todas associadas por equações lineares, que são estimadas ajustando-as aos dados. Em segundo lugar, os efeitos diretos e indiretos são calculados ajustando duas equações aos dados: uma com o mediador incluído e outra com o mediador excluído. Uma modificação relevante nos coeficientes quando o mediador é introduzido é denominada evidência de mediação. Como especialista em saúde e segurança ocupacional, Robins fora convocado a testemunhar no tribunal sobre a possibilidade de exposição a produtos químicos no local de trabalho ter ocasionado à morte de um empregado. Ele ficou triste ao entender que estatísticos e epidemiologistas não tinham instrumentos para responder a essas perguntas. Nesta época a linguagem causal era tida como muito complexa para os estatísticos. É comum as pessoas acharem difíceis as fórmulas matemáticas, olhando de uma forma oculta, as formulas não revelam informações para os leigos. Diferentemente, de um matemático, ou de um individuo que é treinado na maneira matemática de raciocinar, certamente o inverso acontece. Uma fórmula revela tudo: não deixa dúvidas ou divergências. Uma fórmula serve a duas finalidades, uma prática e outra social. Na perspectiva prática, os indivíduos podem ler como fariam em uma receita. A receita pode ser simples ou complexa, mas no final do dia ela promete que, se você seguir os caminhos, conhecerá os efeitos diretos e indiretos naturais - desde que, seu modelo causal considere com precisão o mundo real. Já a segunda finalidade de uma fórmula. É um contrato social. Ela estrutura-se na ideia e que diz: “Isso é algo que acredito ser importante. Isso é algo que merece ser compartilhado”. “Álgebra para todos”: um programa e seus efeitos colaterais. Existem vários sistemas de escolas públicas em grandes cidades, as Escolas Públicas de Chicago possuem problemas que muitas vezes aparentam ser irreparáveis: grande índice de pobreza, baixos orçamentos e falhas de desempenho entre alunos negros, latinos, brancos e asiáticos. Em 1988 nos Estados Unidos, o secretário de educação, William Bennett, categorizou as escolas públicas de Chicago como as piores do país. Contudo, na década de 1990, sob uma nova administração, as Escolas Públicas de Chicago tiveram uma série de transformações e passaram da "pior da nação" a "inovadoras para a nação". Vários dos gestores autores dessas mudanças ganharam visibilidade nacional, como Arne Duncan, que foi secretário de Educação do presidente Barack Obama. Duncan utilizou uma política, excluindo os cursos de recuperação no ensino médio e exigindo que todos os alunos do nono ano realizassem cursos preparatórios para a faculdade, como Inglês I e Álgebra I. A parte matemática desta política era chamada de “Álgebra para Todos”. Em 2003, as Escolas Públicas de Chicago (comandas por Duncan) idealizaram uma nova reforma denominada “Álgebra de Dose Dupla”. Essa reformulação ainda determinava que todos os alunos fizessem álgebra, porém os discentes com pontuação abaixo da

mediana nacional na oitava série teriam duas aulas de álgebra por dia, ao invés de uma. Dessa forma resolveu o efeito colateral contrário da reforma anterior. Atualmente, pelo menos uma vez ao dia, os estudantes com baixo desempenho têm um ambiente de sala de aula melhor do que antes da reforma “Álgebra para Todos”. A reformulação para “Álgebra de Dose Dupla” foi reconhecida como um sucesso e continua até hoje. Os estudiosos da genômica reconheceram em 2008 que Fisher estava certo: existe um “gene do fumo” que atua da maneira que ele disse. Esta evidência veio por meio de uma nova técnica de análise genômica denominada estudo de associação de todo o genoma (GWAS) Este é um instrumento de “big-data” que proporciona aos estudiosos investigar todo o genoma estatisticamente, pesquisando genes que surgem com mais regularidade em indivíduos com uma alguma patologia, como diabetes, esquizofrenia ou câncer de pulmão. O achado do gene do fumo não vai modificar a opinião de ninguém sobre o fator causal mais importante do câncer de pulmão, que é o fumo. É sabido que fumar está relacionado a um aumento de mais de dez vezes a possibilidade de contrair câncer de pulmão. Os torniquetes normalmente são feitos de improvisos, com tiras ou materiais que sejam úteis, de forma que sua eficácia é um esforço de acertar ou errar, logo após a Segunda Guerra Mundial, eles eram vistos como um tratamento de último recurso e seu uso foi oficialmente descartado. As guerras do Iraque e do Afeganistão reformaram essa política. Duas coisas ocorreram: mais ferimentos graves necessitaram do uso de torniquete. Em 2005, o cirurgião geral do Exército dos EUA sugeriu que torniquetes pré-fabricados fossem distribuídos a todos os soldados. Em 2006, como Kragh constatou que os soldados feridos chegavam ao hospital com um torniquete no braço ou na perna diariamente - uma ocorrência sem precedentes na história médica. De 2002 a 2012, os torniquetes salvaram 2.000 vidas de militares. Em concordância com o cirurgião do Exército dos EUA David Welling, “As tropas de combate estão saindo em missões de patrulha perigosas com torniquetes já colocados nas extremidades, pois desejam estar totalmente prontos para responder ao sangramento de extremidades, se e quando a mina ou os dispositivos explosivos improvisados (IED) deve disparar”. Após um estudo com análise dos dados sobre a mortalidade dos militares e os torniquetes. Os resultados do estudo, publicado em 2015, não foram o que Kragh aguardava. Conforme os dados, os enfermos que usaram torniquete antes de chegar ao hospital não sobreviveram em maior proporção do que aqueles com lesões semelhantes que não fizeram uso de torniquete. No raciocínio de Kragh, aqueles com torniquetes provavelmente tinham ferimentos mais graves para começar. Mas quando ele controlou esse fator confrontando casos de igual gravidade, os torniquetes não apresentaram melhoras nos índices de sobrevivência. Com as redes bayesianas, instruímos as máquinas a operacionalizar o que nós previamente determinamos, e esse foi um caminho importante no direcionamento ao pensamento humano. Mas não podíamos ensinar as máquinas a entender as causas e efeitos. Não explicamos a um computador por que girar o mostrador de um barômetro não causaria chuva. Nem conseguiríamos prepara-lo para quando um dos fuzileiros de um grupo de fuzilamento muda de pensamento e opta por não atirar. Sem a competência de refletir sobre realidades eletivas e comprovar com a real existência, um equipamento não pode passar no teste de mini-Turing; não responde a uma questão

básica que nos torna humanos: “Por quê?” isso parece com uma deformidade porque não prevê que perguntas simples e intuitivas existissem fora da obtenção dos sistemas de raciocínio mais avançados do tempo. Na ciência, nos negócios, no governo e até nos esportes, o montante de dados brutos que temos sobre o mundo aumentou a números impressionantes nos últimos anos. A transformação é mais concreta para aqueles que utilizam a Internet e as redes sociais. Como retiramos significado de todos esses números, bits e pixels? Os dados podem ser numerosos, mas as indagações que fazemos são básicas. Existe um gene que causa câncer de pulmão? Que tipo de sistema solar provavelmente abrigará planetas semelhantes à Terra? Que fatores estão causando a diminuição da população de nossos peixes favoritos, e o que podemos fazer a respeito? Não significa dizer que o garimpo de dados seja desnecessário. Esse pode ser um caminho necessário para pesquisar modelos importantes de relação e aplicar problemas interpretativos mais precisos. Ao invés de questionar: “Existem genes causadores de câncer de pulmão?” Agora podemos escanear o genoma a procura de genes com alta associação com câncer de pulmão. Então, podemos nos indagar: “Esse gene causa câncer de pulmão? (E como?)” “Nunca poderíamos ter perguntado sobre o “Sr. Grande” gene se não tivéssemos o garimpo de dados. Para progredir com as pesquisas, precisamos aperfeiçoar um modelo causal descrevendo (por exemplo) quais variáveis que o gene afeta, quais fatores de confusão podem existir e quais outras vias causais podem gerar o resultado. A interpretação dos dados quer dizer formular hipóteses sobre como as coisas funcionam na realidade. Uma função do Big Data em questões de inferência causal habita na última fase do motor de inferência, que nos mostra iniciando na estimativa e concluindo também na estimativa. A parte da estimativa estatística não é simples quando o número de variáveis é muito grande, e somente o big-data e os métodos modernos de processo de máquina ajudam a solucionar a dimensionalidade. Da mesma maneira, Big Data e inferência causal caminham juntos desempenhando uma participação fundamental na área da medicina personalizada. É mérito do Big Data, poder acessar um gigantesco número de elementos em qualquer pesquisa, como também podemos alcançar um imenso número de estudos, em distintos locais e de diversas formas. Regularmente, combinamos os resultados dessas pesquisas e interpretamos de várias formas para a população. Elias Bareinboim logrou êxito ao resolver o problema da transportabilidade da mesma forma que Ilya Shpitser fez para o problema das intervenções. Ele elaborou um algoritmo que pode gerar instantaneamente se o efeito é transportável, utilizando somente parâmetros gráficos. Resumindo, pode afirmar se a separação necessária de Faz-operadores pode ser feitas ou não. Na atualidade, a cultura da “validade externa” está muito direcionada em levantar e categorizar as ameaças à validade, ao invés de combatê-las. Na realidade, está tão estático por ameaças que ver com ceticismo e desconfiança a ideia de que as ameaças podem ser anuladas. Os especialistas, que são iniciantes em modelos gráficos, entendem que é mais simples ajustar ameaças aditivas do que tentar mitigar qualquer uma delas. Os estudiosos de aprendizagem profunda desconhecem limitações básicas. Por exemplo, os economistas que utilizam o aprendizado de máquina constataram que suas técnicas não correspondem os principais problemas de interesse, como estimar o impacto de políticas e ações não testadas. As técnicas descritas para estruturar uma máquina

com uma linguagem adequada para o seu ambiente e o potencial de imaginar uma perturbação hipotética desse ambiente podem ser expandidos para inclusão do equipamento como parte integrante do ambiente. A máquina não pode processar uma cópia completa de seu próprio software, porém pode ter uma síntese do projeto de seus fundamentais componentes de software. A busca pelo “Por quê?” associamos a uma anomalia, pois não, podemos prever os acontecimentos, nos colocou em convívio com indivíduos de uma diversidade de áreas, como Clark Glymour e seu grupo (Richard Scheines e Peter Spirtes) da filosofia, Joseph Halpern da ciência da computação, Jamie Robins e Sander Greenland da epidemiologia, Chris Winship da sociologia e Don Rubin e Philip Dawid das estatísticas, que pensavam sobre o mesmo problema. Unidos, produzimos milhares de revoluções causais, que se expandem em cadeia entre várias disciplinas: epidemiologia, psicologia, genética, ecologia, geologia, ciência do clima e assim por diante. Um comportamento desenvolveu-se conforme a existência dos problemas se basear em suposições, o mais importante é que torne os argumentos transparentes para que outras pessoas possam avaliar o quanto são admissíveis ou quão são frágeis. A Revolução Causal possivelmente não trouxe nenhum instrumento para mudar nossas vidas, mas criou uma transformação de atitudes que obrigatoriamente encaminhará a uma ciência mais benéfica. Na ciência, nos negócios, no governo e nos esportes, a dimensão de dados brutos que geremos sobre o mundo aumenta a valores significativos a cada ano. As modificações são mais visíveis para aqueles que utilizam a Internet e as redes sociais. Em 2014, o Facebook estava armazenando 300 petabytes de dados sobre seus 2 bilhões de usuários ativos, ou 150 megabytes de dados por usuário. Os softwares de jogos, os produtos diversos, os nomes de todos os amigos do Facebook e, todos os vídeos, estão todos em um gigantesco oceano de uns e zeros. É compreensível por que alguns indivíduos enxergam a mineração de dados como o fim, e não como um meio. Espera-se a solução, e não o caminho. Existe uma expectativa que para qualquer problema a solução é fazer uso da tecnologia. Essas indagações são para refletir, sobre o futuro das máquinas, o trabalho de ter que permitir e articular suposições substantivas sobre o funcionamento do mundo. Em várias áreas do conhecimento, podemos estar em um estado rudimentar, sobre o qual não temos ideia de como começar a desenhar um protótipo do mundo. Porém o Big Data não resolverá esse problema. A importância da resposta é a reflexão que deve vir de um modelo, seja esboçado por nós ou concentrado e alinhado por máquinas. O procedimento de interpretação dos resultados de uma pesquisa de um lugar para outro é necessário para a ciência. Verdadeiramente, o desenvolvimento científico seria parado se não fosse pela competência em desenvolver resultados de experimentos de laboratório para o mundo real - exemplificando, de tubos de ensaio a animais e humanos. Porém, até há pouco tempo, cada ciência tinha que criar seus próprios critérios para separar generalizações válidas de inválidas, e não havia métodos sistemáticos para abordar a “transportabilidade” em geral. A igual anomalia estava contaminando mais do que apenas o campo da inteligência artificial (IA). Os mesmos indivíduos que deveriam se preocupar mais com “Por quê?” As perguntas - a saber, os pesquisadores - trabalhavam sob uma cultura estatística que lhes impedia o direito de fazer esses questionamentos. É evidente que eles as indagaram de qualquer maneira,

informalmente, mas eles necessitaram que joga-las como questões associativas sempre que queriam submetê-las à análise matemática. De modo técnico, os meios de aprendizado de máquina nos fornecem uma forma eficiente de ir de suposições de amostra finita para distribuições de probabilidade, e ainda precisamos ir de distribuições para relações de causa-efeito. Em síntese, o pacote de software pode dar a uma máquina vários benefícios que consiste em pelo menos três partes: um modelo causal do mundo; um modelo causal de seu próprio software (superficial); e uma memória que registra como os propósitos em sua mente constituem as ações do mundo real. Os pesquisadores começaram a se afastar do factível a partir da conferência Asilomar em 1975 que tratava sobre recombinação de DNA, e uma tecnologia reconhecida pela mídia como visionários. Os estudiosos que atuam na área alcançaram um entendimento sobre as técnicas de segurança, esse achado, continuou estável, durante as quatro décadas seguintes. O DNA recombinante é agora uma tecnologia simples e confiável. Existe uma enorme distinção entre o espírito e a abordagem causal para elaborar o robô moral e uma conduta que tem sido pesquisada e reparada na ficção científica desde os anos 1950: as leis da robótica de Asimov. Isaac Asimov indicou três leis absolutas, começando com “Um robô não pode ferir um ser humano ou, por inação, permitir que um ser humano sofra algum dano”. Portanto, como a ficção científica tem demonstrado constantemente, as leis de Asimov sempre direcionam a contradições.



Recebido em 27 de Março de 2025

Aceito para publicação em 18 de Junho de 2025