



Capturando a complexidade causal: Uma abordagem qualitativa formal para pesquisas explicativas

Resumo: Este artigo discute a importância da pesquisa explicativa para compreender eventos complexos na área de Administração. A Teoria da Causação por Regularidade é apresentada como uma forma de fornecer critérios precisos para estabelecer relações causais com base em regularidades observadas na ocorrência de fatos/eventos. Além disso, os Métodos Configuracionais Comparativos são discutidos como uma maneira de identificar padrões complexos de relações causais entre valores de variáveis categóricas, levando em consideração a interação entre elas. O artigo destaca a relevância da Coincidence Analysis (CNA) - Análise de Coincidências, em comparação à Comparative Qualitative Analysis (QCA) - Análise Qualitativa Comparativa, como uma ferramenta metodológica mais robusta para explorar estruturas de causa comum e cadeias causais de maneira configuracional, utilizando-se de um algoritmo próprio do pacote CNA, integrado ao software livre R. As propriedades de conjuntividade, disjuntividade e sequencialidade inerentes à técnica CNA permitem uma compreensão mais aprofundada das complexas relações causais em contextos organizacionais. Estudos realizados com a CNA são descritos para demonstrar a sua aplicabilidade em pesquisas explicativas nacionais e internacionais da Administração. A literatura sobre a metodologia CNA e biblioteca Zotero com informações bibliográficas que envolvem a metodologia CNA são disponibilizadas.

Esdras Antunes do Nascimento^{1A}, Jonathan Simões Freitas

1 - Universidade Federal de Minas Gerais
A - contato principal : eanascimento@ufmg.br

Introdução

A pesquisa científica é um processo fundamental que impulsiona o avanço da sociedade moderna, possibilitando a descoberta de novas ideias, a formulação de teorias e a solução de desafios complexos. Para garantir que os resultados obtidos sejam confiáveis e valiosos, é preciso conduzir a pesquisa com rigor, assegurando sua relevância e impacto científico.

A pesquisa acadêmica e científica pode ser bastante complexa, especialmente em áreas como as ciências sociais e a administração. Isso porque os fenômenos estudados nesses campos são frequentemente influenciados por múltiplos fatores, o que pode tornar difícil identificar quais são as causas reais de um determinado evento ou comportamento e levar a considerações de relações causais espúrias (HAESEBROUCK; THOMANN, 2022).

A compreensão da complexidade causal pode ser alcançada por meio da abordagem de pesquisa explicativa, que tem como objetivo ultrapassar a mera descrição de um evento e buscar compreender as razões pelas quais ele ocorre, mesmo quando as informações disponíveis são limitadas. Além de identificar o como e o porquê de um determinado fenômeno, a pesquisa explicativa permite a possibilidade de previsão de ocorrências futuras (CRESWELL, 2014; GIL, 2018).

Os eventos futuros podem ser causados pela regularidade de sua ocorrência em determinadas condições. De acordo com a teoria da causação por regularidade, um evento B pode ser a causa de um evento A. No entanto, para que a relação de causa e efeito seja estabelecida de forma fiável, é necessário considerar outras condições além da regularidade observada na ocorrência dos eventos, como a precedência temporal e a ausência de outras causas INUS (sigla em inglês para “parte insuficiente, mas não redundante, de uma condição desnecessária, mas suficiente”). Somente quando essas condições são atendidas é possível inferir que uma determinada condição é a causa de um resultado específico, com base em

regularidades observadas na natureza (BAUMGARTNER; FALK, 2019).

Os métodos configuracionais comparativos podem ser úteis ao utilizar a teoria da causalidade por regularidade para analisar eventos e suas causas em um contexto mais abrangente. Tais métodos visam identificar padrões complexos de relações causais entre variáveis, levando em conta sua interação em vez de analisá-las de forma isolada. Dessa forma, a abordagem configuracional possibilita uma compreensão mais profunda e precisa da causalidade em um determinado evento (BAUMGARTNER; AMBÜHL, 2018).

Por exemplo, ao analisar a relação entre dois eventos A e B, pode-se utilizar métodos configuracionais comparativos para identificar outros fatores que podem estar contribuindo para a ocorrência de A. Esses fatores podem incluir condições específicas em que A e B ocorrem, bem como outras variáveis que podem influenciar a relação entre eles (estrutura causal e/ou cadeias causais).

Entre os métodos configuracionais comparativos, a *Coincidence Analysis* (CNA) - Análise de Coincidências tem se destacado por sua capacidade de lidar com maior complexidade causal e ambiguidades nos modelos. Através da CNA, é possível investigar as causas que tendem a acontecer em conjunto, e não isoladamente (conjuntividade); a existência de caminhos alternativos ou mais de uma causa (disjuntividade); e as cadeias causais, ou seja, uma causa que leva a outra (sequencialidade). Essas características permitem uma análise mais completa e precisa da estrutura causal (BAUMGARTNER; AMBÜHL, 2018).

A CNA é uma abordagem que permite explorar as relações causais de maneira configuracional, ou seja, analisando padrões complexos de eventos que podem levar a determinados resultados. Isso é particularmente importante quando as relações entre os eventos não são correlacionais, mas sim configuracionais, ou seja, dependem de diferentes combinações de fatores para que um efeito se manifeste (BAUMGARTNER; EPPLE, 2014).

Considerando a complexidade dos fenômenos estudados nas ciências sociais e na administração, que são frequentemente influenciados por múltiplos fatores, surge a necessidade de compreender as relações causais de forma mais precisa e abrangente. Portanto, o problema de pesquisa é: **como a utilização de métodos configuracionais comparativos, especificamente a Análise de Coincidências (CNA), pode contribuir para uma análise mais aprofundada das relações causais em estudos sociais e de administração?**

Portanto, o objetivo geral deste artigo é discutir a relevância do conceito de causa e da teoria de causalidade por regularidade em estudos explicativos, utilizando os métodos configuracionais comparativos, mais especificamente a Análise de Coincidências (CNA), como uma ferramenta metodológica para uma análise mais aprofundada das relações causais associadas a pesquisa social e aos fenômenos observados em estudos de Administração.

Pesquisa explicativa, relações causais e eventos complexos na área de administração

Diferentemente das pesquisas exploratórias e descritivas, que se limitam a registrar, analisar e interpretar os dados, a pesquisa explicativa busca aprofundar o conhecimento da realidade para entender a razão e o porquê dos fenômenos. Deste modo, esse tipo de pesquisa tem como principal finalidade identificar as causas que levam à ocorrência de determinados fenômenos (CRESWELL, 2014; GIL, 2018).

A causa pode ser definida como um fator, ou conjunto de fatores, que desencadeia um determinado evento ou processo. Em outras palavras, a causa é aquilo que provoca ou influencia algo a acontecer. Entender a causa de um evento é fundamental para o avanço do conhecimento, pois permite identificar as relações de causa e efeito que ocorrem no mundo (REITER, 2017).



A pesquisa explicativa é uma forma de estudar as causas de determinados fenômenos, utilizando o método científico para estabelecer expectativas teóricas, verificar hipóteses e testar teorias. Essa metodologia busca responder a perguntas do tipo “por que?” e “como?”, a fim de entender as relações de causa e efeito que envolvem um determinado evento (CRESWELL, 2014; GIL, 2018).

As pesquisas sociais, em especial, são frequentemente do tipo “por que?” e “como?”. Isso porque a sociedade é complexa e dinâmica, sendo muitos os fatores que influenciam o comportamento humano e as relações sociais, o que torna natural o interesse em compreender as razões e as condições que influenciam a ocorrência de determinados fenômenos (CRESWELL, 2014).

Na Administração, a pesquisa explicativa é especialmente importante, uma vez que os fenômenos que ocorrem nessa área são influenciados por uma série de fatores interconectados e complexos, que podem ser difíceis de serem compreendidos apenas pela observação ou pela coleta de dados descritivos. Compreender essas relações é fundamental para a solução de problemas práticos.

Nesse tipo de pesquisa, a explicação das causas envolve a análise de relações entre variáveis, estabelecendo a causalidade entre elas. Algumas perguntas de pesquisa explicativas na Administração que envolvem complexidades causais são demonstradas no Quadro 1, a seguir:

Quadro 1 – Temas e perguntas de pesquisas explicativas

Tópico	Pergunta de Pesquisa
Ética nos Negócios	Como as configurações morais dos gestores estão relacionadas às suas respostas a boicotes morais?
Marketing e Comportamento do Consumidor	Como a polarização da rivalidade entre times de futebol influencia o não consumo de produtos de marcas patrocinadoras?
Comportamento do Consumidor	Como as características maternas se combinam em perfis que explicam a intenção e a não intenção de comprar produtos de segunda mão para crianças?
Estratégia Empresarial e Política	Como ocorre a influência da estratégia na relação entre negócios e o Estado em casos brasileiros?
Empreendedorismo e Estratégia Empresarial	Como os estrategistas em um contexto empreendedor utilizam lógicas de causalidade e efeito em racionalizações prospectivas e retrospectivas de estratégias?
Estratégia Empresarial	Por que a análise contínua da concorrência é um elemento crucial no planejamento estratégico eficaz?
Gestão Empresarial e Estratégia	Por que uma liderança eficaz é um fator crítico na implementação bem-sucedida de estratégias organizacionais?

Fonte: Elaborado pelos autores.

A pesquisa explicativa na Administração tem como objetivo compreender as relações complexas que influenciam os fenômenos dessa área. Para isso, é fundamental o uso de teorias que possam explicar as relações de causa e efeito entre os fatores que influenciam esses fenômenos. A filosofia da causalidade é um campo de estudo que se dedica justamente a explorar as questões fundamentais relacionadas à natureza e ao papel da causa em eventos e processos do mundo.

Filosofia da causalidade

A filosofia da causalidade é um campo de estudo que busca explicar como o mundo funciona e como as coisas se relacionam. A busca por uma compreensão mais profunda da causalidade remonta a filósofos da Grécia Antiga, como Aristóteles, que argumentava que tudo o que existe tem uma causa e que a causa é uma explicação para a existência de algo (ANJUM; MUMFORD, 2018).

No entanto, a filosofia da causalidade é um campo que se desenvolveu significativamente ao longo do tempo e que apresenta uma grande variedade de teorias e abordagens. Alguns filósofos, por exemplo, se concentram na análise da causalidade na ciência, enquanto outros se preocupam mais com questões ontológicas e metafísicas da causalidade (HITCHCOCK, 2017).

Uma das questões centrais da filosofia da causalidade é a distinção entre condições necessárias e suficientes. Uma condição necessária é aquela sem a qual o evento não teria ocorrido, enquanto uma condição suficiente é aquela que, por si só, é capaz de produzir o evento (BAUMGARTNER, 2009a). Por exemplo, a gravidade pode ser uma condição necessária para a queda de uma árvore, enquanto um corte feito por um lenhador seria uma condição suficiente para a ocorrência da queda.

Outra questão importante na filosofia da causalidade é a relação entre causa e efeito. Alguns filósofos argumentam que a causa é o que produz o efeito, enquanto outros afirmam que a causa é simplesmente uma condição para que o efeito ocorra. Essa discussão se torna ainda mais complexa quando se considera que alguns eventos podem ter várias causas, e que uma única causa pode produzir diferentes efeitos em diferentes contextos (HITCHCOCK, 2017).

Uma das teorias mais influentes na filosofia da causalidade é a teoria da causalidade de David Hume (HUME, 2000), que argumenta não ser possível observar a causa e o efeito diretamente, apenas a sua associação frequente. Segundo Hume, a causalidade não é uma propriedade objetiva do mundo, mas uma construção mental baseada em experiências passadas. Essa teoria foi muito criticada por outros filósofos, que a consideravam uma negação da realidade da causalidade.

Outra teoria importante na filosofia da causalidade é a teoria da causalidade de John Stuart Mill (MILL, 2009), que preconiza que a causalidade é uma relação necessária entre eventos que pode ser inferida por meio da observação e da experimentação. Segundo Mill, a causalidade é uma relação de causa e efeito que pode ser descoberta por meio de métodos científicos e que é essencial para a compreensão do mundo natural.

Além dessas teorias, a filosofia da causalidade também se dedica a explorar questões como a causalidade em sistemas complexos, a relação entre causalidade e probabilidade, além da causalidade em eventos sociais e históricos. Essas questões são especialmente relevantes em campos como a sociologia, a economia, as ciências sociais e a administração, que lidam com eventos que são influenciados por múltiplas causas e que ocorrem em contextos sociais e culturais complexos.

Teorias da causalidade aplicáveis às ciências sociais

As teorias da causalidade são fundamentais para a compreensão das relações de causa e efeito que ocorrem em diversos fenômenos, incluindo aqueles relacionados às ciências sociais. Dentre as principais teorias nesse campo, destacam-se a contrafactual, a probabilística, a intervencionista, a mecanística e a de regularidade (BAUMGARTNER, 2020).

A teoria contrafactual define que uma relação causal é estabelecida quando, diante de



uma situação específica, uma mudança que tivesse ocorrido na causa teria levado a uma mudança no efeito. Em outras palavras, é quando podemos dizer que se a causa não tivesse ocorrido, o efeito também não ocorreria. A teoria contrafactual busca estabelecer a relação causal por meio da comparação de diferentes situações, uma em que a causa ocorreu e outra em que a causa não ocorreu (WOODWARD, 2005).

A teoria probabilística busca estabelecer a relação causal por meio do cálculo da probabilidade de o efeito ocorrer dada a causa. Ou seja, essa teoria considera a probabilidade de um evento ocorrer, dado que outro evento ocorreu. Assim, ela não propõe uma relação determinística, mas requer a identificação das probabilidades de cada variável que contribui para o resultado (PEARL, 2009).

Por sua vez, a teoria intervencionista defende que as relações causais só podem ser estabelecidas por meio de intervenções controladas em variáveis. A teoria propõe que as causas são intervenções em um sistema, que alteram a probabilidade de um evento ocorrer. Essa abordagem enfatiza a importância das ações, que podem mudar o curso dos eventos e, portanto, influenciam as relações causais (BAUMGARTNER, 2020; HITCHCOCK, 2013).

Já a teoria mecanística busca entender as relações causais em termos de mecanismos subjacentes que explicam como uma causa produz um efeito. Ela defende que as causas são processos que ocorrem em um sistema e produzem um efeito. Nessa abordagem, é importante entender como as partes de um sistema interagem entre si para produzir um resultado, a fim de estabelecer uma relação causal precisa (BAUMGARTNER, 2020).

Por fim, a teoria da regularidade, é uma teoria clássica de causalidade que se fundamenta na premissa de que eventos causais ocorrem de forma regular e em conjunto com outros eventos (BAUMGARTNER, 2020). Essa teoria postula que uma causa é uma condição necessária e suficiente para produzir um efeito e que, portanto, se uma causa não estiver presente, o efeito não ocorrerá (BAUMGARTNER; FALK, 2019).

Os métodos configuracionais comparativos (MCC) são utilizados para verificar regularidades na pesquisa social empírica. Esses métodos buscam identificar configurações específicas de fatores que podem resultar em determinados resultados, e são úteis para explorar relações causais complexas em que uma única variável explicativa pode não ser suficiente para explicar o fenômeno em questão (BAUMGARTNER; AMBÜHL, 2020). O Quadro 2 traz uma síntese das teorias da causalidade e métodos de inferência causal discutidos nessa seção.

Quadro 2 – Síntese das teorias da causalidade e métodos de inferência causal

Teoria	Definição	Métodos adequados
Contrafactual	Estabelece a relação causal por meio da comparação de diferentes situações, uma em que a causa ocorreu e outra em que a causa não ocorreu.	Experimentos aleatórios, estudos observacionais que utilizam técnicas de pareamento e/ou regressão
Probabilística	Calcula a probabilidade de o efeito ocorrer dada a causa. Não propõe uma relação determinística, mas requer a identificação das probabilidades de cada variável que contribui para o resultado.	Modelagem de equações estruturais



Intervencionista	Defende que as relações causais só podem ser estabelecidas por meio de intervenções controladas em variáveis. As causas são intervenções em um sistema que alteram a probabilidade de um evento ocorrer.	Experimento controlado, análise de regressão com variáveis instrumentais
Mecanística	Busca entender as relações causais em termos de mecanismos subjacentes que explicam como uma causa produz um efeito. As causas são processos que ocorrem em um sistema e produzem um efeito.	Simulação de modelos
Regularidade	Postula que uma causa é uma condição necessária e suficiente para produzir um efeito e que, portanto, se uma causa não estiver presente, o efeito não ocorrerá.	Métodos Configuracionais Comparativos (MCC)

Fonte: Elaborado pelos autores.

Teorias da causalidade baseadas em regularidade

A teoria da regularidade é uma das perspectivas para compreender a causalidade dentro dos campos da filosofia e da ciência. Essa teoria afirma que uma causa é uma condição que, quando presente, sempre resulta em um efeito, e que, quando essa causa está ausente, o efeito nunca acontece (BAUMGARTNER; FALK, 2019). Essa teoria preconiza que os eventos causais são caracterizados por padrões repetitivos e previsíveis na natureza.

Vários filósofos compartilham a visão de que a causalidade é baseada em regularidades observadas na natureza. Eles argumentam que a relação causal é inferida a partir da observação de que um evento sempre é seguido por outro evento em circunstâncias semelhantes. A inferência é uma parte fundamental do processo de pensamento científico, pois permite que os cientistas criem leis que descrevem as regularidades naturais (BAUMGARTNER, 2009a).

David Hume foi um filósofo escocês do século XVIII que argumentou que a ideia de causa e efeito não é algo que possa ser observado diretamente, mas sim uma crença que se desenvolve a partir de hábito ou costume. Ele defendeu que não há razão lógica ou necessidade que justifique a crença de que um evento é a causa de outro. Para o filósofo, a relação causal entre eventos não pode ser estabelecida pela observação empírica (HUME, 2000).

Hume é conhecido por sua ideia de que a causalidade é uma relação de contiguidade temporal e constância conjuntural. Segundo ele, apesar de não ser possível observar diretamente a causalidade, a mente humana tem uma tendência natural a associar eventos que ocorrem juntos repetidamente. Essa propensão é o que permite que a causalidade seja inferida e utilizada na vida cotidiana e na ciência (BAUMGARTNER; FALK, 2019).

John Stuart Mill, filósofo britânico do século XIX, desenvolveu a teoria da causalidade por regularidade, que argumenta que a relação causal entre eventos pode ser estabelecida pela

observação empírica. Mill argumentou que é possível inferir relações causais observando regularidades entre eventos. Ele acreditava que as leis naturais eram necessárias para explicar essas regularidades (MILL, 2009).

Mill desenvolveu a teoria das constantes conjunturais, onde a causalidade é vista como uma relação objetiva que existe no mundo e é descoberta através da observação e experimentação. Para Mill, a inferência causal é possível porque a mente humana é capaz de identificar padrões repetitivos na sequência de eventos (BAUMGARTNER, 2009a).

Na discussão filosófica atual, o estudo de Baumgartner e Falk (2019) apresenta uma nova abordagem analítica para a teoria da causação por regularidade, denominada “Boolean Difference-Making” (causalidade baseada em diferenças booleanas). Essa abordagem se baseia na lógica booleana e se concentra na identificação de condições minimamente necessárias e suficientes para que um evento seja a causa de outro.

Essa visão se fundamenta no princípio da dependência Booleana livre de redundância, que foi proposto originalmente por Broad em 1930 e posteriormente aprimorado por Mackie em sua teoria INUS em 1974 (sigla em inglês para “parte insuficiente, mas não redundante, de uma condição desnecessária, mas suficiente”). O princípio afirma que apenas as dependências booleanas que não contêm redundâncias são capazes de rastrear adequadamente a relação de causa e efeito entre eventos (BAUMGARTNER; FALK, 2019).

Esse princípio foi essencial para superar os problemas encontrados em propostas teóricas clássicas da causalidade, como as teorias da regularidade de Hume e Mill. Essas teorias possuem dificuldades em lidar com a complexidade das relações causais no mundo real e muitas vezes falham em explicar adequadamente como eventos específicos são causados por outros eventos. A teoria INUS aborda essas limitações, permitindo uma compreensão mais sofisticada da causalidade e da relação entre eventos (BAUMGARTNER; FALK, 2019).

A teoria INUS foi refinada por Graßhoff e May (2001). Enquanto a teoria INUS reconhece que várias condições podem contribuir para um evento, sem serem a única causa, a teoria (M)INUS introduziu uma hierarquia entre essas condições, identificando a parte mínima, não redundante e necessária de uma condição suficiente para a ocorrência de um efeito (BAUMGARTNER; AMBÜHL, 2023).

A teoria (M)INUS, portanto, define a causalidade em termos de estruturas de dependência booleanas livres de redundância e, mais importante, não requer que as causas e seus resultados sejam dependentes de pares. Como tal, é construído sob medida para dar conta de estruturas com conjuntividade e disjuntividade. Dessa forma, a teoria MINUS trouxe maior precisão para a análise das relações causais, identificando de forma mais clara as condições que contribuem para a ocorrência de um evento (BAUMGARTNER; AMBÜHL, 2023).

No artigo “Boolean Difference-Making: A Modern Regularity Theory of Causation”, os autores argumentam que as explicações clássicas de Hume e Mill sobre a relação de causalidade entre eventos são problemáticas por algumas razões. Primeiramente, a explicação de Hume de que a causalidade é baseada na constante conjunção de eventos não é suficiente para explicar todos os casos de causalidade. Há situações em que eventos não ocorrem juntos com constância, mas ainda assim há uma relação causal entre eles.

Em segundo lugar, a explicação de Mill de que a causalidade é baseada em uma lei universal que conecta um tipo de evento a outro tipo de evento também é insuficiente. Muitas vezes, não é claro qual lei universal deve ser invocada para explicar uma relação causal entre eventos específicos. Além disso, existem múltiplas causas para um único efeito, ou casos em que a causa é um processo gradual que ocorre ao longo do tempo.

Em síntese, os autores argumentam que ambas as explicações clássicas não levam em



conta a importância da disjuntividade e da sequencialidade na causalidade. Em muitos casos, há várias causas possíveis para um efeito e a causalidade pode ocorrer através de uma sequência de eventos em vez de apenas uma constante conjunção. Para Baumgartner e Falk (2019), a conjuntividade, disjuntividade e sequencialidade representam as três relações básicas entre eventos que permitem identificar e explicar regularidades causais.

A conjuntividade refere-se ao fato de que as causas de um evento geralmente ocorrem em conjunto, ou seja, várias causas contribuem para a ocorrência do evento em questão. Essas causas podem ser independentes ou interdependentes, mas a ideia é que elas não ocorrem isoladamente. Já a disjuntividade se refere à existência de caminhos alternativos que levam a um mesmo evento. Isso significa que mais de uma causa pode ser responsável por um determinado efeito. Essas causas podem ser equivalentes em termos de sua capacidade causal, ou podem ser desigualmente importantes.

Por fim, a sequencialidade é a ideia de que as causas estão ligadas em uma cadeia causal, em que uma causa leva a outra, que por sua vez leva a um terceiro evento, e assim por diante. Nessa perspectiva, a causa inicial de um evento é chamada de causa primária, enquanto as causas subsequentes são chamadas de causas secundárias ou intermediárias. O Quadro 3 apresenta a lógica das propriedades da regularidade da causalidade.

Quadro 3 – Lógica das propriedades da regularidade da causalidade

Conceito	Lógica Booleana	Exemplo
Conjuntividade	“AND” / “NOT”	Se o efeito X ocorreu somente quando as causas Y e Z estavam presentes, podemos usar a lógica booleana para verificar se Y e Z ocorreram juntos.
Disjuntividade	“OR” / “NOT”	Se o efeito X pode ser produzido tanto pela causa Y quanto pela causa Z, podemos usar a lógica booleana para verificar se Y ou Z foi suficiente para produzir X.
Sequencialidade	“AND” / “NOT”	Se a causa Y deve ocorrer antes da causa Z para produzir o efeito X, podemos usar a lógica booleana para verificar se Y ocorreu antes de Z.

Fonte: Elaborados pelos autores.

A lógica booleana desempenha um papel central em sua teoria moderna da causalidade. Baumgartner e Falk (2019), afirmam que a causalidade é uma questão de diferença booleana, o que significa que uma causa faz uma diferença verdadeiro/falso em seu efeito. A lógica booleana fornece uma maneira formal de entender e representar a relação entre a causa e o efeito em termos de proposições verdadeiras ou falsas.

A ideia é que, se uma causa é necessária para que um efeito ocorra, então a presença da causa faz uma diferença booleana no estado do mundo, tornando verdadeira uma proposição que seria falsa na ausência da causa. Por outro lado, se uma causa é suficiente para um efeito, então a presença da causa também faz uma diferença booleana no estado do mundo, tornando falsa uma proposição que seria verdadeira na ausência da causa.

Assim, a lógica booleana é usada para identificar as diferenças causais relevantes que permitem que uma causa seja responsável por um efeito. A abordagem dos autores é uma tentativa de fornecer uma teoria causal baseada em padrões regulares e precisos que pode ser aplicada a diferentes áreas, incluindo a física, biologia, psicologia, ciências sociais, administração e outros campos onde a causalidade é importante.

A partir da ideia de que uma causa faz uma diferença booleana na ocorrência do efeito, é possível resolver muitos problemas da teoria causal tradicional, como a questão da não



identidade e da causalidade circular. A abordagem de Baumgartner e Falk (2019) é epistêmica e usa lógica booleana para estabelecer relações causais entre eventos. Combinando isso com métodos comparativos configuracionais, eles apresentam uma teoria e uma metodologia poderosa da causalidade que pode transformar a forma como se pensa sobre ela.

Métodos configuracionais comparativos

Os Métodos Configuracionais Comparativos (MCC) buscam entender a relação entre as configurações de variáveis e suas consequências, baseados na ideia de que a relação causal não pode ser entendida examinando cada variável isoladamente, mas em conjunto com outras variáveis que formam um padrão específico (FURNARI *et al.*, 2020).

Os MCC são valiosos para entender como uma combinação de fatores contribui para um resultado, ao contrário da regressão que busca quantificar padrões de efeitos líquidos e dinâmica entre variáveis, sendo útil em questões não resolvíveis por métodos estatísticos tradicionais (BAUMGARTNER; AMBÜHL, 2018).

Os MCC examinam hipóteses de implicação que vinculam valores específicos de fatores, como “ $X = \chi_i$ é [não redundantemente – teoria (M) INUS] suficiente / necessário para $Y = \gamma_i$ ”. Eles utilizam uma ordem booleana em conjuntos de causas, localizando seus elementos em caminhos causais distintos ou semelhantes para o resultado final, examinando as propriedades booleanas, conforme descritas pelas teorias de regularidade causal (BAUMGARTNER; AMBÜHL, 2018).

A Análise Qualitativa Comparativa (QCA), desenvolvida por Charles Ragin (1981, 1987, 2008), é um MCC comumente utilizado para identificar padrões que explicam uma determinada condição ou evento por meio de uma tabela verdade. Essa técnica é uma combinação de aspectos dos métodos quantitativos e qualitativos, que emprega a teoria dos conjuntos e análise booleana para realizar pesquisas que se concentram na comparação de casos. (MARX; CAMBRÉ; RIHOUX, 2013).

A QCA tem sido amplamente utilizada em diversos campos de pesquisa, incluindo estudos organizacionais (CRAGUN, 2020). Fiss (2011), por exemplo, utilizou essa abordagem para criar tipologias de organizações, a partir da combinação de variáveis, testando hipóteses causais a partir dessas tipologias. Para Fiss, essa abordagem é mais adequada para entender as complexas relações causais em organizações, que muitas vezes não são binárias ou excludentes.

No entanto, a QCA apresenta limitações ao lidar com a complexidade das relações causais na análise de dados. Ela possui uma estrutura algorítmica *top-down* na criação de modelos suscetível a questionamentos sobre a sua capacidade de encontrar o que se propõe a identificar (BAUMGARTNER, 2009a). Assim, embora seja uma abordagem útil para identificar algumas relações de causalidade, ela falha ao lidar com múltiplas causas e com a sequencialidade causal. De fato, atualmente questiona-se se ela de fato rastreia causalidade ou alguma outra relação não causal (HAESEBROUCK; THOMANN, 2022)

Para superar as limitações da QCA, Baumgartner (2009a) propôs uma nova abordagem em MCC denominada Análise de Coincidência (CNA). A CNA é capaz de lidar com a complexidade causal, permitindo a análise de múltiplas causas e seus efeitos no resultado final. Ela utiliza um algoritmo de otimização próprio que busca encontrar condições minimamente necessárias e minimamente suficientes, cumprindo os requisitos necessários para de fato inferir causalidade de acordo com uma teoria formal da causação (BAUMGARTNER; EPPLÉ, 2014).

A CNA adota uma abordagem *bottom-up*, combinando valores de fatores individuais

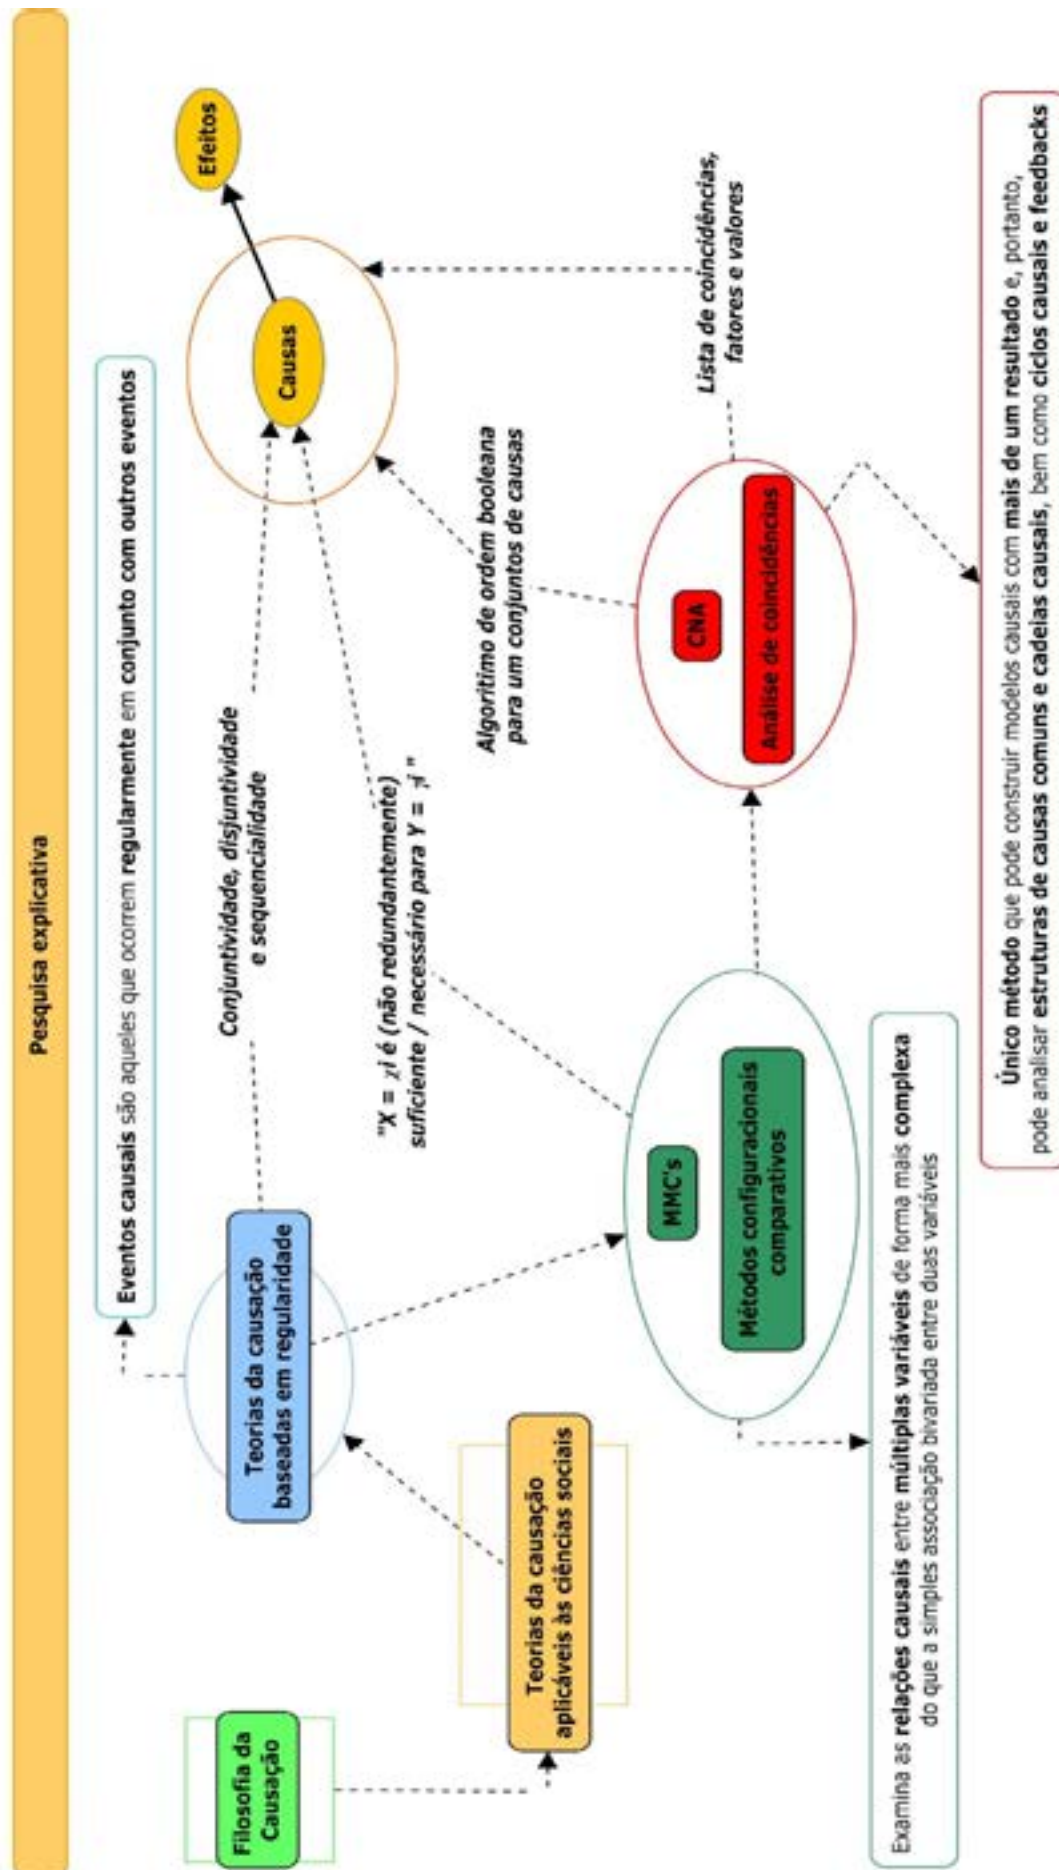
em estruturas de dependências mais complexas (BAUMGARTNER; AMBÜHL, 2020). Ela começa selecionando um resultado a ser explicado para identificar um conjunto de condições relevantes para explicar o resultado. Em seguida, a CNA utiliza a lógica booleana para testar todas as combinações possíveis dessas condições, visando identificar as configurações causais minimamente necessárias e suficientes para o resultado em questão (BAUMGARTNER, 2009a).

Desse modo, a CNA é capaz de analisar estruturais e cadeias causais, permitindo comparações cruzadas sistemáticas, garantindo, também, a complexidade de cada caso (BAUMGARTNER; EPPLE, 2014). Isso possibilita incluir hipóteses ajustadas e modelar interações entre causas, colocando-a em um nível mais avançado para análise de dados, em comparação com a QCA (SWIATCZAK; HAESEBROUCK, 2020).

A CNA é uma ferramenta valiosa para pesquisadores e profissionais que buscam entender a complexidade dos fenômenos em diferentes áreas do conhecimento. Para Baumgartner e Ambühl (2021), a CNA é o único método existente já testado em estudos de benchmarking metodológico que permite construir modelos causais com mais de um resultado, favorecendo a análise de estruturas de causas comuns e cadeias causais, assim como ciclos causais e *feedbacks*.

A Figura 1 sintetiza a pesquisa explicativa para a compreensão da complexidade causal, levando em conta as discussões realizadas até o momento, antes de um maior aprofundamento na metodologia CNA.

Figura 1 – Síntese da pesquisa explicativa para compreensão da complexidade causal



Fonte: Elaborado pelos autores



Metodologia da Análise de coincidências (CNA)

A *Coincidence Analysis* (CNA) - Análise de Coincidências, busca identificar padrões de relações causais a partir de uma lista de coincidência. Uma coincidência refere-se à instanciamento de diferentes valores de fator pelo mesmo caso, onde os fatores são propriedades categóricas (característica qualitativa) usadas para particionar casos em subconjuntos; e valores são atribuições que consideram o pertencimento ou não pertencimento a uma unidade de observação no subconjunto identificado (BAUMGARTNER; AMBÜHL, 2021).

A lista de coincidências pode apresentar fatores com propriedades bivaloradas ou multivaloradas. Os fatores bivalorados (que definem apenas 2 subconjuntos disjuntos) podem ser classificados como atribuição nítida (*crisp-set*), caracterizada por uma separação clara e definida entre duas opções ou categorias distintas; ou atribuição difusa (*fuzzy-set*), que apresenta uma escala contínua de pertinência, permitindo que um objeto ou evento pertença a um conjunto em diferentes graus de intensidade (BAUMGARTNER; AMBÜHL, 2018).

Para os fatores atribuídos de forma nítida (*crisp-set*), apenas dois escores são levados em consideração: “pertence” ou “não pertence”, representados por “1” e “0”, respectivamente. Já para os fatores de conjunto difuso (*fuzzy-set*), a avaliação da pertinência pode variar em uma escala contínua no intervalo fechado de $[0,1]$, em que “1” indica pertinência total; “0” indica não pertinência total; “0,5” indica máxima ambiguidade quanto à pertinência nos conjuntos em questão; e valores nos intervalos abertos de $(0,0,5)$ e $(0,5,1)$ indicam graus variados de pertinência (BAUMGARTNER; AMBÜHL, 2018).

Por exemplo, em uma coincidência envolvendo um fator binário “A” (exemplo, consumidor ou não consumidor de tecnologia *mobile baking*) e um fator de conjunto difuso “B” (exemplo, interesse ou não interesse em utilizar tecnologia *mobile baking*), se a pontuação de pertinência de “A” for “1”, isso significa que o relacionamento pertence a “A” (consumidor de tecnologia *mobile baking*), e se a pontuação de pertinência de “B” for “0,8”, isso significa que o relacionamento é mais pertencente a “B” (interesse de utilizar tecnologia *mobile baking*) do que a não-B (ou “b”).

No caso de fatores multivalorados (onde existem três ou mais subconjuntos apenas é possível determinar os escores de pertinência se um escore nítido (*crisp-set*) for utilizado para identificar o subconjunto ao qual um caso pertence. Assim, dado que os subconjuntos são disjuntos, quando um caso pertence a um subconjunto específico (exemplo, estrato econômico Classe A), simbolizado por “1”, isso implica que esse caso não pertence a outros subconjuntos, representado simbolicamente por “2” e etc. (exemplo, estrato econômico Classe B).

Em sistemas de pontuação difusa (*fuzzy-set*) com fatores multivalorados, é essencial definir as pontuações de pertencimento para todos os subconjuntos, exceto o último avaliado. Isso ocorre porque, uma vez que os subconjuntos são disjuntos e a soma de todas as pontuações de pertencimento difusas de um caso é igual a 1 (exemplo, uso do *mobile banking* para pagamento de contas), é possível deduzir a pontuação do último subconjunto (THIEM, 2014).

O Quadro 4 apresenta um exemplo de lista de coincidências com fatores bivalorados e multivalorados.

Quadro 4 – Exemplo de uma lista de coincidências com propriedades bivaloradas e multivaloradas

Propriedade		Consumidor de tecnologia <i>mobile baking</i>	Interesse no uso de <i>mobile baking</i>	Categoria socioeconômica	Serviços Mobile banking de interesse
Fator		A	B	C	D
Valor		A: Consumidor a: Não consumidor (Bivalorado)	B: Interessado b: Não interessado (Bivalorado)	1: Classe A 2: Classe B 3: Classe C 4: Classe D ou E (Multivalorado)	1: Pagamentos de contas 2: Transferências/Pix 3: Investimentos (Multivalorado)
Escore		<i>Crisp-set</i>	<i>Fuzzy-set</i>	<i>Crisp-set</i>	<i>Fuzzy-set</i>
Coincidências	C1	0 [a]	0,8 [B]	3 [Classe C]	(0,8, 0,2, 0,0) [1]
	C2	0 [a]	0,2 [b]	2 [Classe B]	(0,0, 1,0, 0,0) [2]
	C3	1 [A]	1 [B]	4 [Classe D ou E]	(0,6, 0,5, 0,5) [1]

Fonte: Adaptado de Freitas (2021).

A atribuição de pontuações de pertencimento é importante para se compreender o grau de pertencimento de cada elemento a um conjunto ou categoria específica. Essas pontuações podem ser usadas para identificar padrões, tendências ou relações entre os dados coletados, permitindo a análise e tomada de decisões mais precisas e fundamentadas (FREITAS, 2021).

A atribuição das pontuações de pertencimento do tipo *fuzzy set* com fatores bivalorados pode ocorrer de duas maneiras: (1) absoluta, através da Atribuição Direta (*direct assignment* - DA) e (2) relativa, através da abordagem Totalmente Difusa e Relativa (*Totally Fuzzy and Relative* - TFR) (DUÇA, 2021).

O método de atribuição direta permite a atribuição de pontuações em um conjunto difuso, sem a necessidade de estabelecer critérios, equações ou outros cálculos para a definição dos limites entre as categorias de pertinência. Essa técnica é uma das mais simples formas de se obter uma condição calibrada de dados brutos. No entanto, para evitar a máxima ambiguidade (0,5) na pontuação *fuzzy*, especialistas geralmente optam por escalas de 4 ou 6 pontos para converter dados brutos em conjuntos difusos (DUÇA, 2021).

Por sua vez, o método de atribuição Totalmente Difusa e Relativa (TFR), proposto por Cheli e Lemmi (1995), e aprimorado por Filippone, Cheli e D'Agostino (2001) como TFRa, utiliza a teoria dos conjuntos difusos para modelar a incerteza e a subjetividade envolvidas nas avaliações multidimensionais de determinados construtos. O método consiste em três etapas: calibração, normalização e atribuição.

Para analisar a causalidade, os fatores de uma lista de coincidências podem ser obtidos por meio de diversas técnicas de coleta de dados, como entrevistas estruturadas em grades de repertório para Análise de Conteúdo de Honey e Análise das Categorias de Construtos-chave, como demonstrado no estudo de Santos, Martins e Freitas (2023), ou a aplicação de *survey* com escalas tipo *Likert*, como usado no estudo de Nunes *et al.* (2022). Experimentos baseados em cenários também podem ser usados para coletar dados, conforme mostrado na pesquisa de Brescia (2021).

Na CNA, as coincidências são utilizadas para identificar as condições minimamente necessárias e suficientes para um determinado resultado, chamado de resultado equifinal. Em outras palavras, diferentes combinações de condições podem atingir o mesmo objetivo



final por meio de caminhos diferentes e com condições iniciais distintas. A identificação dessas condições pode auxiliar na compreensão de fenômenos sociais complexos, particularmente em pesquisas comparativas (BAUMGARTNER; THIEM, 2015).

Para identificar modelos causais em uma lista de coincidências, a CNA utiliza a lógica booleana por meio de um algoritmo formal implementado em um pacote do *software* livre R[®]. O algoritmo opera em duas etapas, buscando condições minimamente suficientes e minimamente necessárias para instanciar um resultado específico, testando valores de fatores isoladamente ou combinados conjuntamente pelo operador “e” e “ou”, respectivamente. (BAUMGARTNER; THIEM, 2015).

A estratégia de busca consiste em encontrar condições mínimas suficientes (“*minimally sufficient conditions*”, *msc*) para instanciar um resultado específico, começando com valores únicos de um fator e progredindo para combinações de vários fatores. Se a busca inicial não for bem-sucedida, a pesquisa avança para encontrar outras condições *msc*, através de conjunções formadas pelo operador “e” lógico, combinando dois ou mais valores de diferentes fatores (BAUMGARTNER, 2009a,b).

A segunda etapa da estratégia de busca envolve encontrar as condições mínimas necessárias para alcançar o resultado desejado, usando as *msc* já identificadas. A busca começa com *msc* individuais e, se necessário, avança para disjunções de duas ou mais *msc*. Essas disjunções são formadas pelo operador “ou” lógico e são usadas somente se a busca anterior por *msc* não tiver êxito. (BAUMGARTNER, 2009a,b).

Os modelos provenientes das condições encontradas, representam a “forma disjuntiva normal” (“*disjunctive normal form*”, *dnf*), ou seja, disjunções minimamente necessárias de condições minimamente suficientes para a instanciação do resultado (BAUMGARTNER; AMBÜHL, 2018; BAUMGARTNER; FALK, 2019). Os resultados obtidos após o término da operação são modelos potencialmente causais, denominados Teorias Mínimas, que contêm os modelos causais mais parcimoniosos na explicação dos resultados analisados.

A solução final é livre de redundância, podendo ser uma solução atômica para um único *output* [representada pelas “fórmulas de solução atômicas” (“*atomic solution formulas*”, *asf*)] ou uma solução complexa para múltiplos *outputs* [as chamadas “fórmulas de solução complexas” (“*complex solution formulas*”, *csf*)], de acordo com a Teoria da Regularidade mais recente (BAUMGARTNER; FALK, 2019).

Um exemplo de modelo causal gerado pela CNA é a expressão “ $(A + B \leftrightarrow C) * (D + AB \leftrightarrow E)$ ”, que evidencia as três propriedades booleanas já discutidas, conjuntividade, disjuntividade e sequencialidade (BAUMGARTNER; AMBÜHL, 2021), onde:

A, B, C, D e E representam os valores de fatores;

O símbolo asterisco (*) representa o produto booleano (operação de conjunção na lógica de proposições) e é traduzido como “e”;

O símbolo de adição (+) representa a soma booleana (operação de disjunção na lógica de proposições) e é traduzido como “ou”;

O símbolo \leftrightarrow representa a igualdade booleana (operação de equivalência na lógica de proposições) e é traduzido como “se”, e “somente se”, “necessário e suficiente para” ou “suficiente e necessário para”.

De maneira exemplificativa, uma das expectativas teóricas sobre o comportamento de uso tecnologia *mobile baking* por consumidores idosos poderia ser representada pela seguinte expressão $CMB * CRE * RAF \leftrightarrow ICF$, em que:

- *CMB*: pertencente ao conjunto de consumidores com maior **frequência de uso** de tecnologia *mobile baking*;

- *CRE*: pertencente ao conjunto de idosos com **crenças positivas** em relação ao uso de



tecnologia *mobile baking*;

- *RAF*: pertencente ao conjunto de idosos com **razões a favor** do uso de tecnologia *mobile baking*;

- *ICF*: pertencente ao conjunto de idosos com maior **intenção de uso futuro** de tecnologia *mobile baking*.

Para garantir o rigor de uma pesquisa explicativa com abordagem qualitativa-formal, a CNA incorpora duas propriedades em sua metodologia: a consistência e a cobertura. A consistência é responsável por assegurar a fiabilidade e a replicabilidade dos resultados da modelagem causal, representando o grau em que a evidência empírica é consistente com a relação teórica dos conjuntos. Já a cobertura busca considerar todas as possíveis causas relevantes, indicando a relevância empírica ou importância de condições (RIHOUX; RAGIN, 2009).

A análise de robustez é outra propriedade inerente à CNA. A robustez é uma medida da capacidade de um modelo resistir a variações nos limites mínimos de consistência e cobertura estabelecidos para a construção dos seus modelos. Na modelagem causal, a robustez refere-se à capacidade do modelo (ou versões mais simples ou mais complexas dele) ser inferido, mesmo quando há variações nesse parâmetro (PARKKINEN; BAUMGARTNER, 2023).

Um exemplo de código utilizado na CNA é dado e explicado no Quadro 5: *cna(df, ordering=list("PRTH"), notcols="PRTH", strict=TRUE, con=0.75, cov=0.75, maxstep=c(3,3,9)) robust <- frscore(df, rat = c(0.95, 0.75, -0.05), allconcov=T, ordering=list("PRTH"), notcols='PRTH', strict=TRUE, output="asf", normalize=F, verbose=F, type="cs", inus.only=T, maxstep = c(3,3,9)) robust\$order(robust\$score, decreasing=T),]*

Quadro 5 – Descrição dos parâmetros do exemplo de função CNA e Fscore

Parâmetros	Descrição
df	Conjunto de dados a ser analisado
ordering	Ordem na qual os fatores serão avaliados
notcols	Colunas que serão consideradas na análise
strict	Indica se a análise deve ser restrita ou não
con	Pontuação mínima de consistência para considerar uma relação
cov	Cobertura mínima para considerar um subconjunto
maxstep	Número máximo de etapas para identificar um subconjunto
rat	Vetor de três valores que define a taxa de corte para cada etapa da análise
allconcov	Indica se todas as coberturas devem ser consideradas ou apenas a maior
output	Formato de saída
normalize	Indica se as pontuações devem ser normalizadas
verbose	Indica se mensagens de status devem ser impressas
type	Define o tipo de corte para a análise
inus.only	Indica se apenas os resultados da última etapa devem ser considerados

Fonte: Elaborado pelos autores.

Resultados de estudos com aplicação da CNA

Nesta seção, é apresentada a aplicabilidade prática da ferramenta metodológica CNA para uma análise mais detalhada das relações causais associadas à pesquisa social e aos fenômenos observados nos estudos de Administração. Para isso, são mostrados alguns estudos realizados por pesquisadores no Brasil e em outras partes do mundo nos últimos anos.

Cadeia de suprimentos

Um primeiro estudo apresentado é o Santos, Martins e Freitas (2023), que utilizaram a CNA para identificar como o capital social contribui para o desenvolvimento da resiliência nas redes de suprimentos da administração pública. A pesquisa seguiu uma abordagem qualitativa-formal, utilizando entrevistas estruturadas com a técnica da grade de repertório para a coleta de dados. Os dados coletados foram submetidos à análise de conteúdo de Honey e à análise de construtos-chave, antes da aplicação da CNA.

Um total de 247 construtos foram identificados na pesquisa, agrupados em 18 fatores (atributos do capital social) que poderiam explicar causalmente a resiliência nas redes de suprimentos. Esses fatores foram considerados causalmente relevantes, uma vez que apareceram em pelo menos uma das soluções selecionadas. Os fatores que apresentaram frequência superior a 10% das soluções encontradas (50 modelos) foram destacados, ou seja, aqueles que ocorreram mais de cinco vezes.

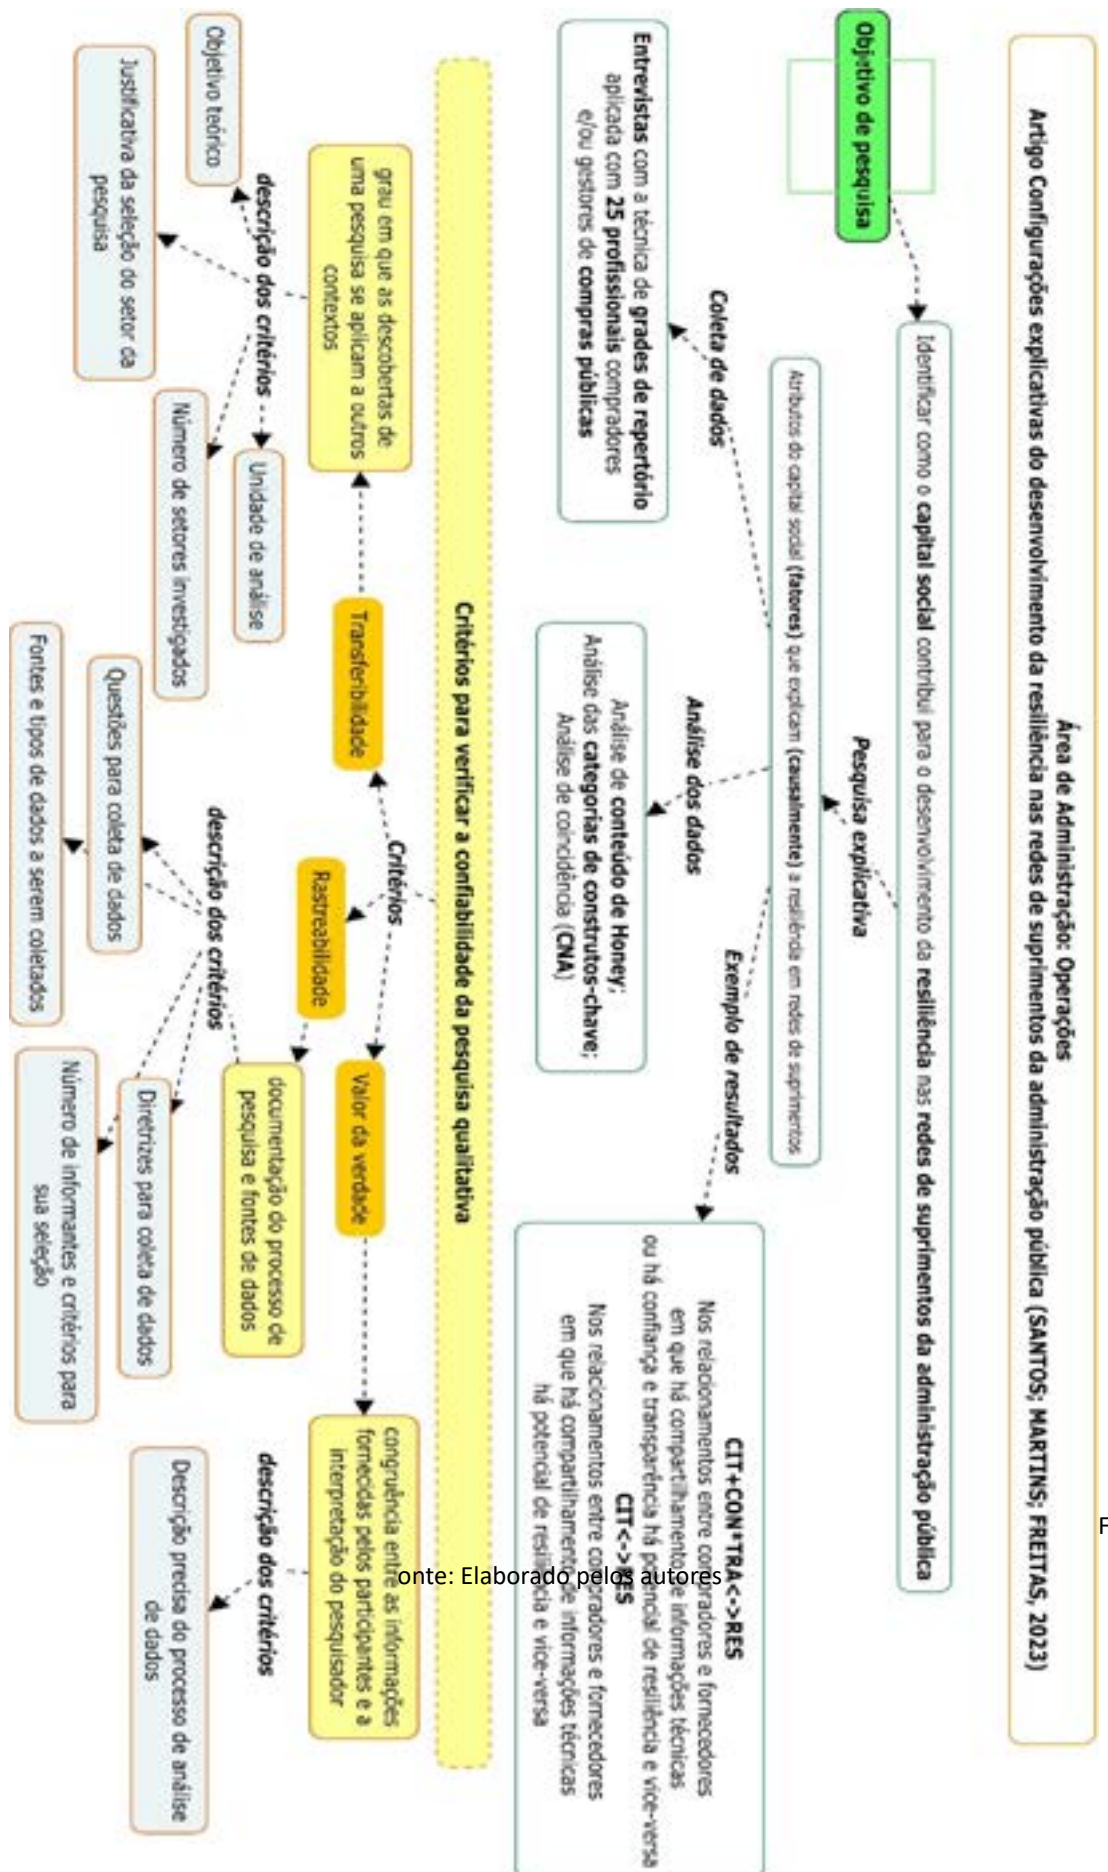
O estudo contribui para a literatura ao compreender o capital social como um constructo multinível que influencia o desenvolvimento da resiliência nas cadeias de suprimentos e ao priorizar os construtos que mais impactam a resiliência no setor público, considerando a perspectiva dos praticantes do relacionamento interorganizacional.

A pesquisa apontou que o desenvolvimento da resiliência nas redes de suprimentos da administração pública está fortemente relacionado ao capital social, destacando-se os atributos de compartilhamento de informações técnicas, precisão na comunicação, antecipação na comunicação de informações relevantes, reciprocidade, confiança, transparência e comprometimento.

Esses resultados têm implicações significativas para as empresas e organizações do setor público, pois evidenciam a importância de construir e fortalecer o capital social para aumentar a resiliência das redes de suprimentos. Isso pode levar a uma melhor coordenação, colaboração e adaptação em situações de crise ou perturbação, beneficiando não apenas as organizações envolvidas, mas também a sociedade como um todo.

A Figura 2 apresenta a estrutura da pesquisa explicativa em cadeia de suprimentos com aplicação da CNA.

Figura 2 – Exemplo pesquisa explicativa na cadeia de suprimentos da administração pública com aplicação da CNA.



Fonte: Elaborado pelos autores

Marketing esportivo

Um segundo estudo apresentado foi desenvolvido por Nunes *et al.*, (2022), que aplica a CNA para avaliar como fatores descritivos de rivalidade se combinam de diferentes formas para constituir esses sentimentos que se manifestam em diferentes graus de intensidade. Utilizando uma abordagem qualitativa-formal, foi aplicado um questionário com questões fechadas na escala Likert de 7 pontos na pesquisa em questão. Os dados coletados de mais de 1000 torcedores foram analisados por meio da técnica de análise de coincidências.

No estudo, o construto de investigação foi a Rivalidade (RIV), que se refere aos sentimentos que um grupo de torcedores nutre pelos torcedores, organização, patrocinadores e demais envolvidos com a equipe rival. A agregação das pontuações foi utilizada para tratar a constituição dos fatores que compuseram a Rivalidade (Concorrência indireta, Espírito esportivo *outgroup*, Senso de satisfação, *Glory out of reflected failure*, *Schadenfreude* e Percepção de rivalidade recíproca).

A partir da CNA, os autores identificaram os fatores mais relevantes para a constituição da rivalidade entre torcedores de futebol. A estratégia inovadora de verificar a constituição dos construtos separadamente, antes de interpretar a solução de segundo nível (relacionamento entre explicações de primeiro e de segundo nível em termos de agregação), proporcionou complementaridade entre os diferentes níveis explanatórios.

De acordo com o estudo, a relação do torcedor com o patrocinador do seu clube é o único fator causal relevante para o consumo consistente de produtos patrocinados. A rivalidade é um fator importante na rejeição de um produto, mas apenas quando combinada com a identificação do torcedor com seu clube e sua relação positiva com as empresas que investem em sua equipe. O estudo sugere que a ausência de rivalidade é suficiente para explicar o consumo de produtos de patrocinadores rivais.

Os resultados do estudo têm grande potencial para futuras pesquisas em marketing esportivo. A perspectiva assimétrica de análise pode ser aplicada a outros fatores para entender melhor as relações entre eles. Além disso, o estudo indica que a rivalidade pode afetar o relacionamento com patrocinadores e a rejeição de marcas, o que pode ser útil para patrocinadores e gerentes de marketing esportivo compreenderem o comportamento dos fãs.

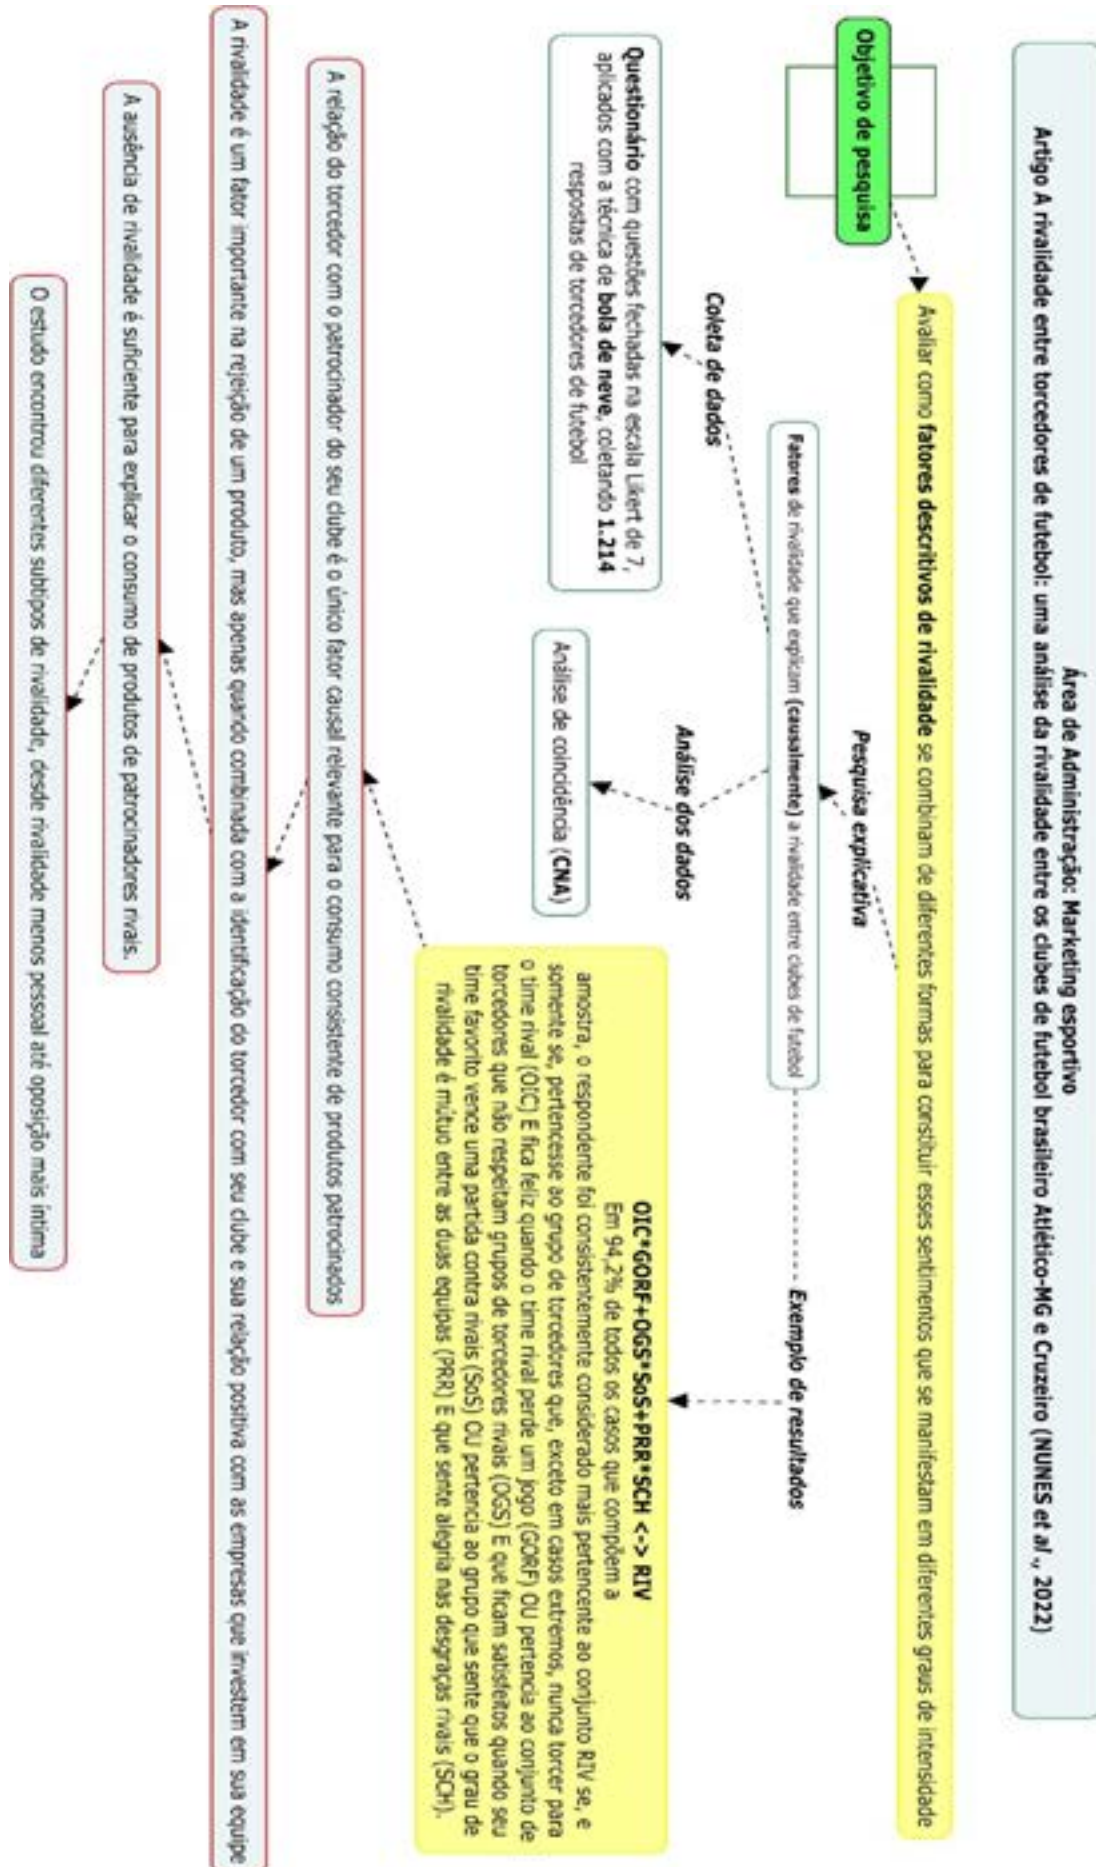
O estudo também encontrou diferentes subtipos de rivalidade, desde rivalidade menos pessoal até oposição mais íntima. Isso sugere que a rivalidade pode ser formada por combinações alternativas, que parecem estar associadas a diferentes subtipos deste sentimento. A contribuição do estudo é relevante para a avaliação da rivalidade a partir de uma perspectiva individual, em vez de analisar objetivamente uma partida específica.

Os resultados mostraram que a rivalidade combinada com a identificação do torcedor com seu clube e sua relação positiva com as empresas patrocinadoras influenciaram o consumo consistente de produtos patrocinados. Essas descobertas têm implicações para as empresas que investem em patrocínios esportivos, pois destaca a importância de considerar a rivalidade e a identificação do torcedor ao desenvolver estratégias de marketing esportivo. Compreender como esses fatores interagem pode ajudar as empresas a direcionar melhor seus esforços de marketing e fortalecer o relacionamento com os fãs, gerando impactos positivos nos negócios.

A Figura 3 apresenta a estrutura da pesquisa explicativa em marketing esportivo com aplicação da CNA.



Figura 3 – Exemplo pesquisa explicativa no campo do marketing esportivo com aplicação da CNA.



F

Fonte: Elaborado pelos autores.

Mudanças organizacionais

Um terceiro estudo apresentado foi realizado por Sprang, Miech e Gusler (2023). O estudo utiliza análise configuracional para determinar as condições necessárias e suficientes para produzir reduções nos sintomas de estresse traumático secundário (STS) nos trabalhadores, bem como melhorias de bem-estar de profissionais individuais dentro das organizações. A pesquisa envolveu um total de 6.033 profissionais trabalhando com indivíduos expostos a traumas representando 52 organizações.

A pesquisa investigou o papel dos campeões organizacionais na promoção de mudanças na abordagem do STS em organizações. Campeões organizacionais são indivíduos ou equipes que buscam promover mudanças em seu local de trabalho. Eles são fundamentais para promover mudanças em uma organização, disseminar ideias e estratégias inovadoras e criar mudanças em toda a empresa. O STS é um fenômeno que afeta profissionais indiretamente expostos ao trauma por meio de histórias traumáticas de seus pacientes ou clientes.

Metodologicamente, foram aplicadas as “condições minimamente suficientes” (ou seja, “*msc*”) dentro do pacote R “Cna” para examinar todos os 52 casos e todos os 15 fatores de uma só vez, visando identificar combinações específicas de condições com conexões especialmente fortes com o resultado de interesse. Esse processo exaustivo considera cada combinação de valores instanciados no conjunto de dados original e identifica todas as configurações de uma, duas e três condições que atendem ao limite de consistência especificado.

Os resultados da CNA mostraram que a mudança organizacional na abordagem do STS e nas estratégias de resolução de problemas lideradas pelos defensores (campeões organizacionais) resultou em reduções nos sintomas de STS dos profissionais individuais. Esses resultados indicam a importância dos campeões organizacionais na promoção de mudanças positivas na abordagem do STS em organizações.

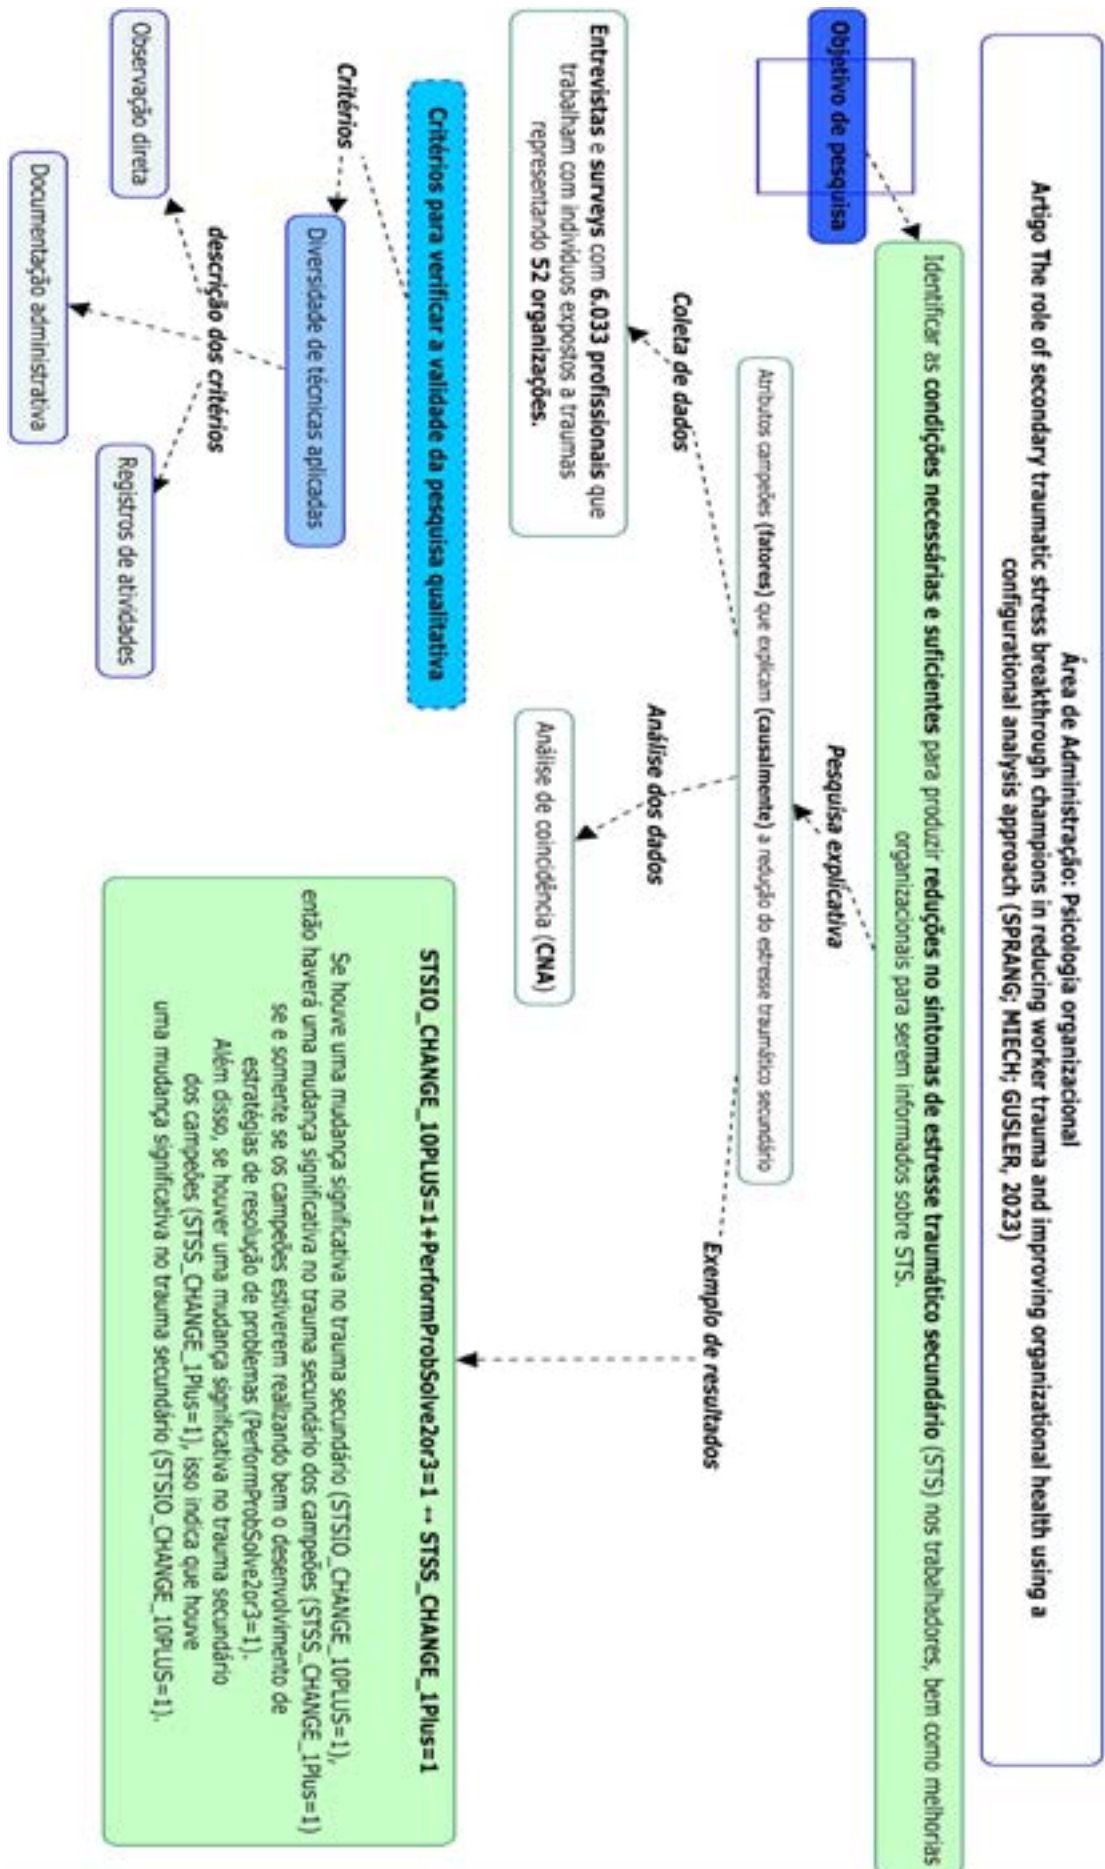
Além disso, o estudo também destacou a importância do envolvimento de pares e do compartilhamento de conhecimento entre os defensores em ambientes de bem-estar. Esse tipo de abordagem levou a melhorias em nível organizacional, mostrando que a mudança nesse nível pode ter um impacto direto no bem-estar individual. O estudo destaca a importância da conscientização sobre o estresse traumático secundário e sua abordagem em organizações.

A pesquisa sugere que organizações incentivem estratégias lideradas pelos campeões organizacionais e envolvimento de pares para criar uma cultura de bem-estar. As empresas devem fornecer recursos para lidar com o impacto do STS em seus funcionários e garantir um ambiente de trabalho saudável. A conscientização e a abordagem proativa do STS são fundamentais.

Em suma, as implicações desses resultados destacam a importância de reconhecer e abordar o estresse traumático secundário em organizações. Ao priorizar estratégias lideradas pelos campeões organizacionais e promover um ambiente de trabalho saudável, as empresas e organizações do setor público podem proteger o bem-estar de seus funcionários, promover mudanças positivas e melhorar a qualidade dos serviços oferecidos.

A Figura 4 apresenta a estrutura da pesquisa explicativa em psicologia organizacional com aplicação da CNA.

Figura 4 – Exemplo pesquisa explicativa no campo psicologia organizacional com aplicação da CNA.



Fonte: Elaborado pelos autores.

Gestão enxuta (*Lean*)

Um quarto estudo apresentado foi realizado por Charns *et al.* (2023). A pesquisa buscou compreender quais os fatores e dinâmicas organizacionais que permitem a transformação da gestão enxuta (*Lean*) das organizações de cuidados de saúde. Os dados primários da pesquisa foram coletados por meio de duas ondas de entrevistas em 2016–2017 com 121 líderes e funcionários em sete centros médicos de veteranos que participam da transformação empresarial *Lean*.

No artigo, a CNA foi utilizada para identificar quais fatores e dinâmicas organizacionais possibilitaram a transformação da gestão enxuta (*Lean*) em sete centros médicos do departamento de assuntos de veteranos dos Estados Unidos. Para cada centro, 7 potenciais facilitadores foram identificados, codificados e classificados, e a medida de resultado foi a extensão da transformação *Lean*, avaliada por meio da codificação e classificação de 11 marcadores de profundidade e disseminação da transformação.

A CNA foi usada para identificar os facilitadores que distinguiram entre os centros com diferentes níveis de transformação *Lean*, e foram identificadas citações representativas para esses facilitadores. Como resultado, foi possível identificar que o suporte de liderança e o desenvolvimento de capacidades foram suficientes para alcançar a transformação *Lean* em três níveis com 100% de consistência e cobertura.

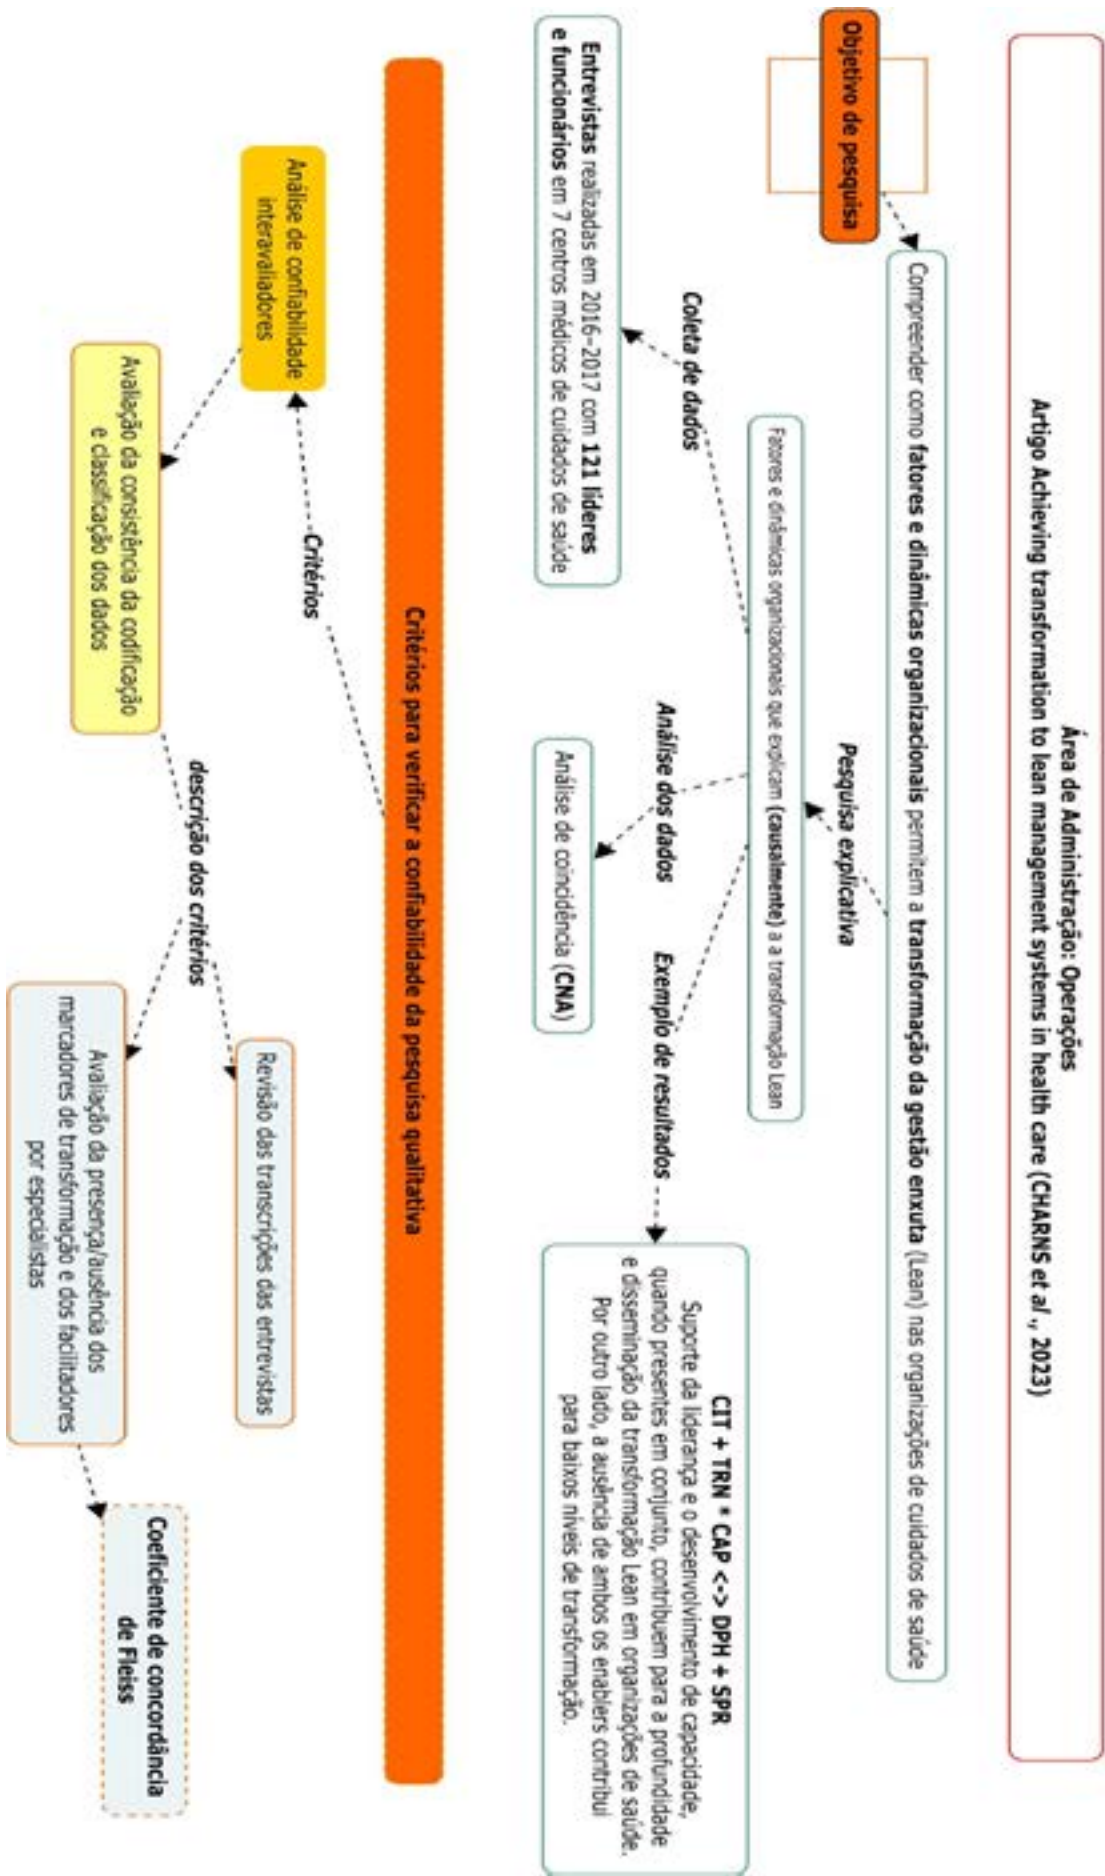
O estudo observa que altas pontuações em ambos os fatores estavam relacionadas a uma alta transformação *Lean*, médias pontuações em apenas um dos fatores correspondiam a uma transformação média, e baixas pontuações em ambos os fatores correspondiam a uma baixa transformação. Adicionalmente, baixas pontuações em comunicação e disponibilidade de dados, e pontuações muito baixas em alinhamento caracterizaram os centros com baixa transformação. Centros com alto suporte de liderança também apresentaram alto envolvimento de veteranos.

De modo geral, a aplicação da CNA permitiu que os pesquisadores identificassem quais fatores foram mais importantes na obtenção de uma transformação bem-sucedida e quais foram menos importantes. Isso pode ajudar as organizações de saúde a priorizar seus esforços de transformação e melhorar suas chances de sucesso.

A Figura 5 apresenta a estrutura da pesquisa explicativa em psicologia organizacional com aplicação da CNA. Vários outros estudos de aplicação da CNA podem ser encontrados na página *Literature and Software* do portal de CNA no site da Universidade de Bergen (<https://www.uib.no/en/cna/121344/cna-literature-and-software>).



Figura 5 – Exemplo pesquisa explicativa no campo da gestão de operações com aplicação da CNA.



Fonte: Elaborado pelos autores.

Considerações finais

Este artigo teórico explorou como a aplicação de métodos configuracionais comparativos, em particular a Análise de Coincidências (CNA), pode enriquecer a compreensão das relações causais de pesquisas explicativas desenvolvidas em estudos sociais e de administração.

A pesquisa explicativa é uma ferramenta importante para compreender eventos complexos nas diversas áreas de conhecimento. A Teoria da Causação por Regularidade é uma abordagem que pode ser utilizada para inferir relações causais com base em regularidades observadas, o que permite identificar as causas reais de um determinado evento ou comportamento.

Além disso, os Métodos Configuracionais Comparativos são uma maneira de identificar padrões complexos de relações causais entre valores de variáveis, levando em consideração a interação entre elas. Nesse sentido, a Análise de Coincidências (CNA) se destaca como uma ferramenta metodológica mais robusta e correta para explorar estruturas comuns e cadeias causais de maneira configuracional, permitindo uma compreensão mais aprofundada das complexas relações causais em contextos organizacionais.

A CNA apresenta propriedades de conjuntividade, disjuntividade e sequencialidade, o que permite uma análise mais completa da estrutura causal booleana, identificando as causas que tendem a acontecer em conjunto, existência de caminhos alternativos ou mais de uma causa, bem como as cadeias causais. Essas características possibilitam uma compreensão mais precisa da causalidade em um determinado evento.

A metodologia CNA é projetada para recuperar ligações causais booleanas, o que é particularmente relevante para analisar processos com causalidade conjuntural (causação componente) e equifinalidade (causação alternativa). Essas características tornam o CNA uma ferramenta essencial para a condução de pesquisas explicativas rigorosas na área de Administração e outras disciplinas que buscam compreender a complexidade das relações causais em fenômenos sociais e organizacionais.

A Análise de Coincidências (CNA) surge como uma abordagem promissora, superando as limitações da Análise Qualitativa Comparativa (QCA) e apresentando uma série de potencialidades e oportunidades para estudos de diversas naturezas. Ao utilizar a CNA, pesquisadores e profissionais têm acesso a uma metodologia avançada, capaz de lidar com a complexidade das relações causais e oferecer uma compreensão mais aprofundada dos fenômenos em diferentes áreas do conhecimento.

Uma das principais vantagens da CNA em relação à QCA é sua capacidade de lidar com múltiplas causas e a sequencialidade causal. Enquanto a QCA possui uma estrutura algorítmica *top-down* que pode apresentar dificuldades na identificação de relações complexas, a CNA adota uma abordagem *bottom-up*, permitindo a análise de múltiplas causas e seus efeitos no resultado final. Isso possibilita a modelagem de interações entre causas e a inclusão de hipóteses ajustadas, levando a uma compreensão mais precisa e abrangente dos fenômenos estudados.

A capacidade da CNA de analisar estruturas de causas comuns, cadeias causais, ciclos causais e feedbacks também é crucial para uma compreensão abrangente dos fenômenos estudados. Essa abordagem permite uma análise mais aprofundada das interações entre diferentes variáveis, auxiliando na identificação de relações complexas e na formulação de teorias causais mais robustas.

Em resumo, a Análise de Coincidências (CNA) apresenta-se como uma poderosa ferramenta de análise, superando as limitações da Análise Qualitativa Comparativa (QCA). Ao oferecer uma abordagem mais flexível, abrangente e precisa para a identificação de



relações causais, a CNA traz ganhos significativos para os negócios, as empresas e a sociedade, proporcionando *insights* valiosos para a tomada de decisões estratégicas, o aprimoramento de políticas públicas e a compreensão dos fenômenos complexos em diversas áreas do conhecimento.

Embora a QCA seja uma técnica bem estabelecida e utilizada na área de Administração, a CNA ainda é amplamente ignorada pelos pesquisadores dessa área. No entanto, a CNA tem ganhado destaque e dominado as aplicações de métodos configuracionais comparativos em *journals* de outras disciplinas de prestígio, em particular nas áreas de saúde pública, ciências sociais e políticas. Alguns dos principais *journals* com artigos publicados, e respectivo fator de impacto JCR de 2021, são: *Journal of General Internal Medicine* [FI 6.473], *Journal of Mixed Methods Research* [FI 5.746], *Sociological Methods & Research* [FI 4.677], *Health Services Research* [FI 3.734] e *Systematic Reviews* [FI 3.136], dentre outros.

A CNA foi introduzida pela primeira vez por Baumgartner (2009a) e generalizada por Baumgartner e Ambühl (2018). A literatura sobre a metodologia CNA e sua aplicação está em constante expansão. Uma página no site da Universidade de Bergen (<https://www.uib.no/en/cna/121344/cna-literature-and-software>) reúne a literatura que oferece uma visão geral e material atualizado com os últimos avanços da metodologia. Nessa página, uma biblioteca Zotero CNA Group fornece informações bibliográficas, atualmente com 76 trabalhos que envolvem a metodologia CNA.

Referências

ANJUM, Rani Lill; MUMFORD, Stephen. Causation in science and the methods of scientific discovery. Oxford University Press, USA, 2018. <https://doi.org/10.1093/oso/9780198733669.001.0001>

BAUMGARTNER, Michael. Inferring causal complexity. *Sociological methods & research*, v. 38, n. 1, p. 71-101, 2009a. <https://doi.org/10.1177/0049124109339369>

BAUMGARTNER, Michael. Uncovering deterministic causal structures: A Boolean approach. *Synthese*, v. 170, n. 1, p. 71-96, 2009b. <https://doi.org/10.1007/s11229-008-9348-0>

BAUMGARTNER, Michael; AMBÜHL, Mathias. Causal modeling with multi-value and fuzzy-set Coincidence Analysis. *Political Science Research and Methods*, v. 8, n. 3, p. 526-542, 2020. <https://doi.org/10.1017/psrm.2018.45>

BAUMGARTNER, Michael; AMBÜHL, Mathias. *cna: An R Package for Configurational Causal Inference and Modeling*. 2023. Disponível em: <<https://mirror.marwan.ma/cran/web/packages/cna/vignettes/cna.pdf>>. Acesso em 05/04/2023.

BAUMGARTNER, Michael; EPPLÉ, Ruedi. A coincidence analysis of a causal chain: The Swiss minaret vote. *Sociological Methods & Research*, v. 43, n. 2, p. 280-312, 2014. <https://doi.org/10.1177/0049124113502948>

BAUMGARTNER, Michael; FALK, Christoph. Boolean Difference-Making: A Modern Regularity Theory of Causation. *The British Journal for the Philosophy of Science*, 2019. <https://doi.org/10.1093/bjps/axz047>

BAUMGARTNER, Michael; THIEM, Alrik. Identifying Complex Causal Dependencies in Configurational Data with Coincidence Analysis. *The R Journal*, v. 7, n. 1, p. 176, 2015. Disponível em: <<https://journal.r-project.org/archive/2015-1/baumgartner-thiem.pdf>>. Acesso em 18/07/2023.

BRESCIA, Davi Pires Andrade. Respostas gerenciais a dilemas estratégicos: capturando políticas de decisão e suas fundações morais. 282 p. (Mestrado em Administração). Universidade Federal de Minas Gerais, 2021. Disponível em: <<http://hdl.handle.net/1843/38767>>. Acesso em 18/04/2023.

CHARNS, Martin. P.; LERNER, Benjamin; YAKOVCHENKO, Vera; URECH, Tracy H.; SHIN, Myung Hee; KIM, Byung Kook; KASAVICH, Barbara J.; VASHI, Ashwin A. Achieving transformation to lean management systems in health care. *Health Services Research*, v. 58, n. 2, p. 343-355, 2023. <https://doi.org/10.1111/1475-6773.14072>

CHELI, Bruno; LEMMI, Achille. A' Totally' fuzzy and relative approach to the multidimensional analysis of poverty. *Economic Notes-Siena*, p. 115-134, 1995. <https://www.scopus.com/record/display.uri?eid=2-s2.0-0010328443&origin=inward>

CRAGUN, Deborah. Configurational comparative methods. In: *Handbook on implementation science*. Edward Elgar Publishing, 2020. p. 497-504. <https://doi.org/10.4337/9781788975995.00034>

CRESWELL, John Wesley. *Research design: qualitative, quantitative, and mixed methods approaches*. Sage publications, 2014.

DUŞA, Adrian. QCA with R - A Comprehensive Resource. Disponível em: <<https://www.bookdown.org/dusadrian/QCABook/QCABook.pdf>>. Acesso em: 18 abr. 2023.

FILIPPONE, Andrea; CHELI, Bruno; D'AGOSTINO, Antonella. Addressing the interpretation and the aggregation problems in totally fuzzy and relative poverty measures. *ISER Working Paper Series*, 2001. Disponível em: <http://valutazione2003.stat.unipd.it/pdf/SienaGiu2001/Filippone-Cheli-Dagostino_Siena_Giugno2001.pdf>. Acesso em: 18 abr. 2023.

FISS, Peer C. Building better causal theories: A fuzzy set approach to typologies in organization research. *Academy of management journal*, v. 54, n. 2, p. 393-420, 2011. <https://doi.org/10.5465/amj.2011.60263120>

FREITAS, Thalita. Meyli Lin. Perfis maternos explicativos da intenção de compra de produtos de segunda mão para filhos. 199 p. (Mestrado em Administração). Universidade Federal de Minas Gerais, 2021.

FURNARI, Santi; CRILLY, Donal; MISANGYI, Vilmos. F.; GRECKHAMER, Thomas.; FISS, Peer. C.; AGUILERA, Ruth. V. Capturing causal complexity: Heuristics for configurational theorizing. *Academy of Management Review*, v. 46, n. 4, p. 778-799, 2021. <https://doi.org/10.5465/amr.2019.0298>

GIL, Antonio. Carlos. *Metodologia de Pesquisa em Ciências Sociais*. Editora Atlas, 2018.

GLYMOUR, Clark; SCHEINES, Richard; SPIRITES, Peter. Discovering causal structure: Artificial intelligence, philosophy of science, and statistical modeling. Academic Press, 2014.

GRAßHOFF, Gerd; MAY, Michael. Causal regularities. *Current issues in causation*, p. 85-114, 2001.

HAESEBROUCK, Tim; THOMANN, Eva. Introduction: Causation, inferences, and solution types in configurational comparative methods. *Quality & Quantity*, p. 1-22, 2022. <https://doi.org/10.1007/s11135-021-01209-4>

HAYES, Andrew F. Introduction to mediation, moderation, and conditional process analysis: A regression-based approach. Guilford publications, 2017.

HITCHCOCK, Christopher. The intransitivity of causation revealed in equations and graphs. *The Journal of Philosophy*, v. 98, n. 6, p. 273-299, 2001.

BEEBEE, Helen; HITCHCOCK, Christopher; PRICE, Huw (Ed.). Making a difference: Essays on the philosophy of causation. Oxford University Press, 2017.

HUME, David. An enquiry concerning human understanding: A critical edition. Oxford University Press on Demand, 2000.

MILL, John Stuart. A system of logic: Ratiocinative and inductive: Vol. I. Library of Alexandria, 2009.

MARX, Axel; CAMBRÉ, Bart; RIHOUX, Benoît. Crisp-set qualitative comparative analysis in organizational studies. In: *Configurational theory and methods in organizational research*. Emerald Group Publishing Limited, 2013. p. 23-47. [https://doi.org/10.1108/S0733-558X\(2013\)0000038006](https://doi.org/10.1108/S0733-558X(2013)0000038006)

NUNES Felipe Alexandre de Souza Félix; FREITAS, Jonathan Simões; FAGUNDES, André Francisco Alcântara; FLEURY, Fernando Andrade. Rivalry formation among football fans: an analysis of the rivalry between the Atlético-MG and Cruzeiro Brazilian football clubs. *REMark*, v. 21, n. 5, p. 1677, 2022. <https://doi.org/10.5585/remark.v21i5.20430>

PARKKINEN, Veli-Pekka; BAUMGARTNER, Michael. Robustness and model selection in configurational causal modeling. *Sociological Methods & Research*, v. 52, n. 1, p. 176-208, 2023. <https://doi.org/10.1177/0049124120986200>

PEARL, Judea.: Causality: Models, Reasoning, and Inference. Cambridge University Press, Cambridge, 2009.

PEARL, Judea; MACKENZIE, Dana. The book of why: the new science of cause and effect. Basic books, 2018. <https://doi.org/10.1007/s00146-020-00971-7>

REITER, Bernd. Theory and Methodology of Exploratory Social Science Research.

International Journal of Science and Research Methodology, v. 5, n. 4, p. 129, 2017. Disponível em < <https://ttu-ir.tdl.org/handle/2346/86610>>. Acesso em 05/04/2023.

RIHOUX, Benoit; RAGIN, Charles C. Configurational Comparative Methods: Qualitative Comparative Analysis (QCA) and Related Techniques. SAGE, 2009.

SANTOS, Laysse Fernanda Macêdo dos. O desenvolvimento da resiliência nas redes de suprimentos da administração pública: a perspectiva do capital social. 185 p. (Tese em Administração). Universidade Federal de Minas Gerais, 2022. Disponível em <<http://hdl.handle.net/1843/42177>>. Acesso em 05/04/2023.

SANTOS, Laysse Fernanda Macêdo dos; MARTINS, Ricardo Silveira; FREITAS, Jonathan Simões. Configurações explicativas do desenvolvimento da resiliência nas redes de suprimentos da administração pública. Revista de Administração Pública, v. 57, p. e-2022-0209, 2023. <https://doi.org/10.1590/0034-761220220209>

SPIRITES, Peter.; GLYMOUR, Clark. N.; SCHEINES, Richard.; HECKERMAN, D. Causation, prediction, and search. MIT Press, 2000.

SPRANG, Ginny; MIECH, Edward J.; GUSLER, Stephanie. The role of secondary traumatic stress breakthrough champions in reducing worker trauma and improving organizational health using a configurational analysis approach. Implementation Research and Practice, v. 4, p. 26334895231164582, 2023. <https://doi.org/10.1177/26334895231164582>

SWIATCZAK, Martyna Daria. Different algorithms, different models. Quality & Quantity, v. 56, n. 4, p. 1913-1937, 2022. <https://doi.org/10.1007/s11135-021-01193-9>

THIEM, Alrik. Unifying configurational comparative methods: Generalized-set qualitative comparative analysis. Sociological Methods & Research, v. 43, n. 2, p. 313-337, 2014. <https://doi.org/10.1177/0049124113500481>

VERKUILEN, Jay. Assigning membership in a fuzzy set analysis. Sociological Methods & Research, v. 33, n. 4, p. 462-496, 2005. <https://doi.org/10.1177/0049124105274498>

WEBER, Erik; LEURIDAN, Bert. Counterfactual causality, empirical research, and the role of theory in the social sciences. Historical Methods: A Journal of Quantitative and Interdisciplinary History, v. 41, n. 4, p. 197-201, 2008. <https://doi.org/10.3200/HTMS.41.4.197-201>

WOODWARD, James; WOODWARD, James Francis. Making things happen: A theory of causal explanation. Oxford University Press, 2005.