

2

REVISÃO DA LITERATURA EMPÍRICA RECENTE SOBRE MÉTODOS DE SCREENING PARA A DETECÇÃO DE CARTÉIS¹

*Review of recent empirical literature on screening
methods for cartel detection*

Rodrigo Menon Simões Moita²

Faculdade de Economia, Administração e Contabilidade (FEA/USP) – São Paulo/SP, Brasil

Rafael Pereira Oliveira³

Faculdade de Economia, Administração e Contabilidade (FEA/USP) – São Paulo/SP, Brasil

Gabriel Barreiros Poveda⁴

Faculdade de Economia, Administração e Contabilidade (FEA/USP) – São Paulo/SP, Brasil

Maria Paula Heck de Jesus⁵

Faculdade de Economia, Administração, Contabilidade e Gestão de Políticas Públicas (FACE/UnB) –
Brasília/DF, Brasil

RESUMO ESTRUTURADO

Objetivo: o objetivo deste artigo é apresentar uma revisão da literatura empírica recente a respeito do uso de métodos de *screening* (ou filtros econômicos) para a detecção de cartéis no Brasil e no mundo.⁶ Tais métodos têm sido cada vez mais utilizados por autoridades antitruste na medida em que complementam e reforçam métodos reativos tradicionais de detecção de cartel, como acordos de leniência. Há diversos estudos que discutem suas aplicações, a maioria com foco na abordagem

Editor responsável: Prof. Dr. Víctor Oliveira Fernandes, Conselho Administrativo de Defesa Econômica (Cade), Brasília, DF, Brasil. **Lattes:** <http://lattes.cnpq.br/5250274768971874>. **ORCID:** <https://orcid.org/0000-0001-5431-4142>.

1 **Recebido em:** 19/01/2024 **Aceito em:** 06/06/2024 **Publicado em:** 19/06/2024

2 Bacharel em economia pela Faculdade de Economia, Administração e Contabilidade (FEA/USP). Mestre em economia pelo Instituto de Pesquisas Econômicas (IPE/USP). Doutor em economia pela University of Illinois.

E-mail: rodmoita@usp.br **Lattes:** <http://lattes.cnpq.br/8849680445810227> **ORCID:** <https://orcid.org/0000-0003-3244-9892>

3 Bacharel em economia pela Fundação Getúlio Vargas (FGV/SP). Mestre em economia pelo Instituto de Pesquisas Econômicas (IPE/USP).

E-mail: oliveirarafaelp1@gmail.com **Lattes:** <http://lattes.cnpq.br/8898014256402252>

ORCID: <https://orcid.org/0009-0000-2732-7802>

4 Bacharel em economia pela Faculdade de Economia, Administração e Contabilidade (FEA/USP). Mestre em economia pelo Instituto de Pesquisas Econômicas (IPE/USP).

E-mail: barreirosponsoreda@gmail.com **Lattes:** <http://lattes.cnpq.br/5580464669300677>

ORCID: <https://orcid.org/0009-0005-0150-9786>

5 Bacharel em relações internacionais e ciência política pelo Centro Universitário do Distrito Federal (UDF). Graduada e mestranda em economia pela Faculdade de Economia, Administração, Contabilidade e Gestão de Políticas Públicas (FACE/UnB).

E-mail: paula.mariahj@hotmail.com **Lattes:** <http://lattes.cnpq.br/3595655399541760>

ORCID: <https://orcid.org/0000-0003-1245-5566>

6 Agradecemos o Instituto de Pesquisa Econômica Aplicada (IPEA) e o Fundo de Defesa dos Direitos Difusos (FDD) pelo financiamento deste estudo, TED 01/2018 FDD-Ipea.



de *screening* comportamental. Este artigo visa a complementar tais trabalhos de duas maneiras: (i) avaliar a literatura mais recente sobre o tema, a qual tem se especializado, por exemplo, em metodologias de *machine learning*; e (ii) discutir aplicações de abordagens estruturais, que são métodos mais simplificados de detecção do que o *screening* comportamental, mas também utilizados por autoridades antitruste e na literatura.

Método: revisão e análise qualitativa da literatura sobre detecção de cartel nacional e internacional.

Conclusões: diversas autoridades antitruste têm seguido as recomendações de organizações internacionais de combinar o uso de métodos reativos com proativos na detecção de cartéis. Há iniciativas importantes no uso de *screenings*, especialmente no âmbito de licitações públicas dada a maior disponibilidade de dados. Na literatura empírica técnicas de *machine learning* têm ganhado espaço seja devido aos desafios de identificação dos modelos econométricos, seja pelo contexto de aumento na complexidade do funcionamento dos acordos colusivos. Trata-se de uma nova tendência que está voltada principalmente à maior previsibilidade e precisão no processo de detecção de cartéis, em detrimento de conclusões sobre causalidade. Tendo em vista as diferentes dinâmicas setoriais e regionais na economia, sua utilização ainda exige cautela por parte dos pesquisadores e autoridades antitruste, mas certamente representa avanço relevante e promissor no combate a cartéis.

Palavras-chave: métodos de *screening*; detecção; cartéis; abordagem estrutural; abordagem comportamental; *machine learning*.

STRUCTURED ABSTRACT

Objective: The objective of this article is to present a review of recent empirical literature regarding the use of *screening* methods to detect cartels in Brazil and around the world. Such methods have been increasingly used by antitrust authorities as they complement and reinforce traditional reactive methods of cartel detection, such as leniency agreements. There are several studies that discuss its applications, most focusing on the behavioral *screening* approach. This article aims to complement such work in two ways: (i) evaluate the most recent literature on the topic, which has specialized, for instance, in *machine learning* methodologies; and (ii) discuss applications of structural approaches, which are more simplified detection methods than behavioral *screening*, but also used by antitrust authorities and in the literature.

Method: Literature review and qualitative analysis on national and international cartel detection.

Conclusions: Several antitrust authorities have been following the recommendations of international organizations to combine the use of reactive and proactive methods in cartel detection. There are significant initiatives in the use of *screenings*, especially in the context of public tenders, given the increased availability of data. In empirical literature, *machine learning* techniques have gained traction, either due to the challenges in identifying econometric models or the rising complexity of collusive agreements. This represents a new trend primarily focused on enhancing predictability and precision in the cartel detection process, rather than drawing conclusions about causality. Given the diverse sectoral and regional dynamics in the economy, its use still requires caution on the part of researchers and antitrust authorities, but it undoubtedly represents a significant and promising advancement in the fight against cartels.

Keywords: *screening* methods; detection; cartels; structural approach; behavioural approach; *machine learning*.

Classificação JEL: C18; C52; D22; D23; D40; K21; K40; L20; L40.

Sumário: 1. Introdução; 2. O que podemos compreender por “cooperação antitruste a nível internacional”?; 3. A Singularidade do Mercado Digital e a Demanda por uma Resposta Regulatória Específica; 3.1. O mercado digital é verdadeiramente “único”? As características das big techs como fator de especificação da economia digital; 3.2. Representam as big techs um risco à concorrência no mercado digital?; 4. O Digital Markets Act como regulação paradigma para uma análise antitruste cooperativa; 5. Conclusões; Referências.

1. INTRODUÇÃO

O objetivo deste artigo é apresentar uma revisão da literatura empírica recente a respeito do uso de métodos de *screening* (ou filtros econômicos) para a detecção de cartéis, no Brasil e no mundo. O avanço recente no uso destes métodos justifica-se pela preocupação de autoridades antitruste com a eficiência dos métodos reativos de detecção de cartel, como é o caso dos programas de leniência (ICN, 2021). Conforme será abordado neste artigo, observou-se nos últimos anos que a dependência excessiva nos acordos poderia comprometer a própria efetividade deste instrumento e, portanto, métodos como os de *screening* deveriam ser vistos como complementares e não necessariamente substitutos aos métodos tradicionais de detecção de cartéis.

Há diversos estudos que discutem aplicações de *screenings*, a maioria com foco na abordagem comportamental. Este artigo visa a complementar tais trabalhos de duas maneiras: (i) avaliar a literatura mais recente sobre o tema, a qual tem se especializado em metodologias, por exemplo, de *machine learning*; e (ii) discutir aplicações de abordagens estruturais, métodos mais simplificados de detecção do que o *screening* comportamental, mas também utilizados por autoridades antitruste e na literatura.

No contexto de detecção de cartel⁷, métodos de *screening* caracterizam-se por modelos estatísticos que visam a identificar mercados cuja estrutura é propícia para cartel, onde há comportamento suspeito ou onde denúncias de consumidores e concorrentes exigem investigação mais aprofundada (PORTER, 2018). O *screening* estrutural consiste na análise de características do mercado ou indústria que tendem a facilitar a ocorrência de cartéis. Embora a literatura teórica acerca de fatores estruturais que afetam a estabilidade de cartéis seja vasta, há poucas aplicações práticas nesse sentido.

Métodos comportamentais, embora mais sofisticados, são mais comuns tanto na literatura empírica quanto nos programas de detecção de cartel das autoridades antitruste, em grande medida,

⁷ O uso de *screening* pode e deve ser usado em diversos outros contextos. Um exemplo prático é o uso que foi feito por funcionários do Ministério do Planejamento para identificar irregularidades em leilões virtuais. Mais detalhes em: Castro et al. (2018) e Rebouças et al (2015).



pela sua maior efetividade. Tal abordagem consiste em identificar comportamentos suspeitos que são mais consistentes com um regime de cartel do que de um mercado competitivo. Para tanto, baseia-se em diferentes tipos de dados, como: preços, quantidades, lances em licitações públicas, número de empresas concorrentes, *spreads* e *market shares*, custos, grau de transparência e inovação nos mercados, interação entre concorrentes, elasticidade-preço da demanda e barreiras de entrada (ABRANTES-METZ, 2011).

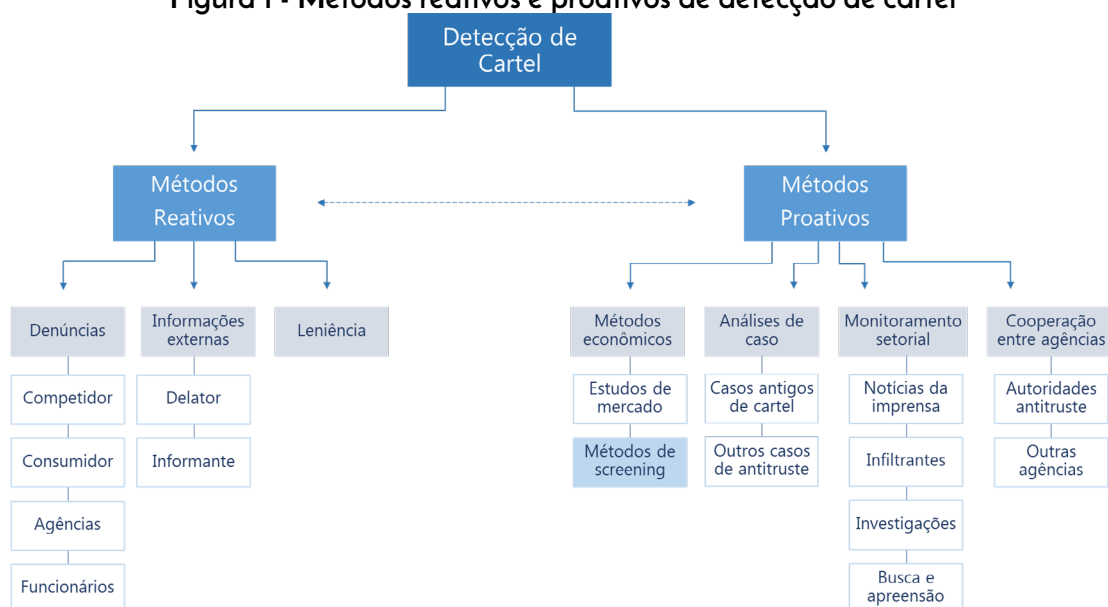
Assim, o *screening* pode ser utilizado para avaliar, dentre outros fatores: (i) características estruturais do mercado que tendem a facilitar a ocorrência de cartéis; (ii) independência condicional dos lances em uma licitação pública; (iii) preços médios e a variância dos preços no mercado; (iv) quebras estruturais nas séries de preço, lances e quantidades; (v) taxas de *pass through* entre custos e preços; (vi) estabilidade de *market shares* no mercado ou entre um grupo de empresas; ou até (vii) adequação da distribuição de preços ou lances a leis matemáticas, como a chamada Lei de Benford .

Este artigo realiza uma revisão da literatura empírica recente a respeito do uso destes métodos no contexto de detecção de cartel e está organizado da seguinte forma, além desta Introdução. A Seção 2 compara os métodos reativos e proativos (como o *screening*) de detecção de cartel, evidenciando que o *screening* tem papel importante, inclusive, para poupar recursos e garantir maior efetividade de métodos reativos como acordos de leniência. A Seção 3 discute as propriedades e limitações das abordagens estruturais e comportamentais de *screening*. A Seção 4 apresenta a revisão da literatura empírica recente acerca dos diferentes tipos de aplicação e a Seção 5 traz as considerações finais.

2. SCREENING COMO MEIO PARA FORTALECER ACORDOS DE LENIÊNCIA

De modo geral, os métodos de detecção de cartel podem ser caracterizados entre proativos e reativos. De acordo com ICN (2021), métodos reativos dependem de eventos externos ocorrerem antes da autoridade antitruste reconhecer ou ganhar consciência de algum fato, enquanto métodos proativos têm origem dentro da autoridade e não dependem de fatores externos. A Figura 1 detalha as diferentes abordagens de detecção de cartel.

Figura 1 - Métodos reativos e proativos de detecção de cartel

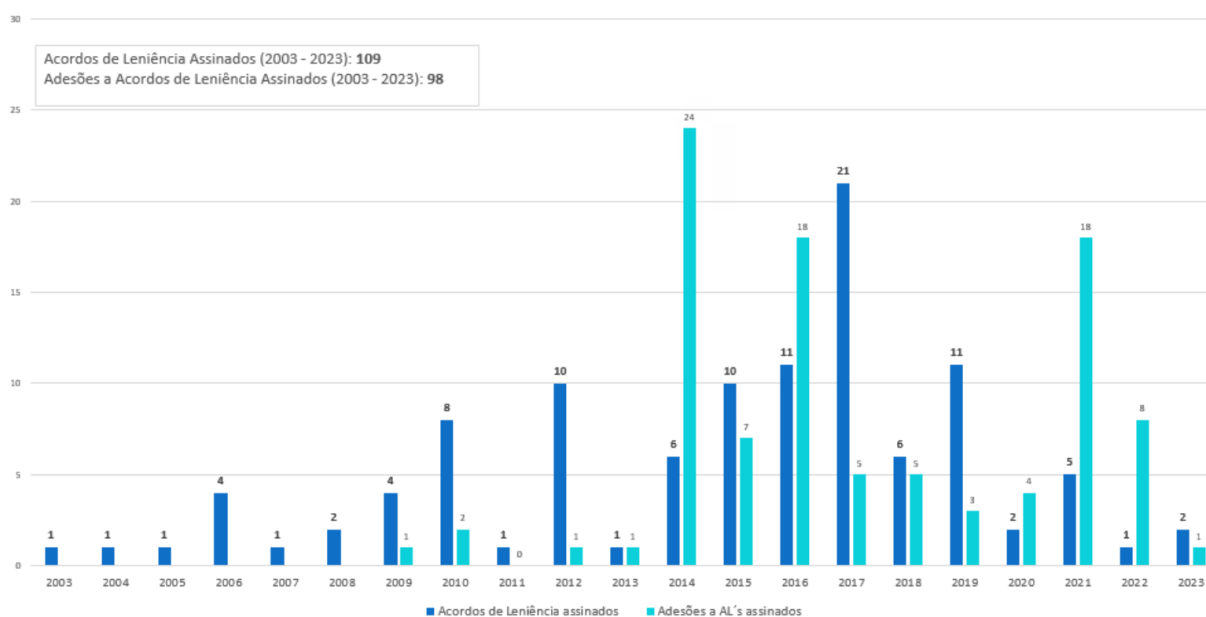


Fonte: adaptado de Hüsichelrath (2010).

O avanço recente no uso de métodos de *screening* justifica-se pela preocupação de autoridades antitruste com a eficiência dos métodos reativos de detecção de cartel (ICN, 2021). Observou-se que a dependência excessiva em programas de leniência, por exemplo, poderia comprometer a própria efetividade deste instrumento. Salgado (2022) explora como os acordos de leniência, dentre outras ferramentas, impactam a dinâmica da política de combate a cartéis. Além disso, evidências sugerem que tais programas tendem a detectar cartéis maduros ou em já estágio final (CHAMMAS, 2015).

De fato, como mostra o Gráfico 1, no caso brasileiro, após forte alta no número de acordos de leniência assinados pelo Conselho Administrativo de Defesa Econômica (Cade) entre 2013 e 2017, ano em que foram assinados 21 acordos, observa-se uma tendência de queda no uso deste instrumento até 2023 (quando houve apenas dois acordos assinados).

Gráfico 1 - Número de acordos de leniência e adesões a acordos assinados pelo Cade (2003-2023)



Fonte: Estatísticas (2023) do Programa de Leniência do Cade. Atualizado em 01/03/2023.

Não à toa, nos últimos dez anos a recomendação de organizações internacionais tem sido que os acordos de leniência e demais métodos reativos devem ser reforçados e combinados com métodos proativos de detecção (OECD, 2013; ICN, 2021). Conforme destaca Porter (2018), métodos como os de *screening* devem ser complementares e não necessariamente substitutos aos métodos tradicionais. Ademais, quando implementados da maneira adequada⁸, tais métodos podem poupar recursos significativos das autoridades antitruste.

Nessa linha, diversas autoridades antitruste têm desenvolvido e aprimorado projetos para detecção de cartéis via métodos de *screening*⁹. No que tange à abordagem estrutural, chama a atenção

8 Abrantes-Metz (2011) e Gonzaga (2018) definem os critérios necessários para a implementação adequada de um método de *screening*, que deve: (i) ser aplicável em diferentes mercados; (ii) ter baixo custo marginal; (iii) ser discreto e não invasivo; (iv) ser robusto do ponto de vista empírico e teórico; e (v) ser preciso, de forma a minimizar falsos positivos e, principalmente, falsos negativos.

9 Para uma análise mais detalhada e com mais exemplos internacionais, ver a subseção 3.2 de Beth e Gannon (2022).

a experiência da autoridade holandesa, a *Netherlands Competition Authority* (NMa), com o chamado *Competition Index*¹⁰. Trata-se de um índice de competição que agrega nove indicadores estruturais e que visa a detectar indústrias mais propensas à ocorrência de comportamentos anticompetitivos (PETIT, 2012)¹¹. Os resultados, na época, indicaram que os setores manufaturados no país eram os mais propensos à ocorrência de comportamentos anticompetitivos, em particular, os segmentos de produção de malte, outras bebidas fermentadas e não destiladas, cal e gesso.

Com relação ao uso de *screenings* comportamentais para a detecção de cartel em licitações públicas, destaca-se a experiência da *Korean Fair Trade Commission* (KFTC), na Coreia do Sul, por meio do *Bid Rigging Indicator Analysis System* (BRIAS), iniciado em 2006 (OECD, 2016). Vale destacar também as experiências da *Comisión Federal de Competencia Económica* (CFCE), no México, que implementou métodos de *screening* no período de 2003 a 2007 (MENA-LABARTHE, 2012); e da *Competition Commission* (Comco), na Suíça, cujo projeto de *screening*, iniciado em 2008, resultou em uma investigação cinco anos depois, com a posterior condenação das empresas envolvidas (GONZAGA, 2018).

No Brasil, o Cade tem enfatizado a implementação tanto de técnicas reativas quanto proativas. Ainda em 2013, a autoridade brasileira deu início a um projeto para a criação de *screenings* para detecção de cartel que resultou, no ano seguinte, no chamado “Projeto Cérebro”. Referência para as demais autoridades antitruste e com foco em licitações públicas, o programa tem combinado testes estatísticos com mineração de dados para dar suporte para o início de investigações *ex-officio*, investigações em curso e demais unidades do órgão (OECD, 2018). A principal base de dados utilizada pelo Cade no âmbito do Cérebro é a do Comprasnet, portal de compras do Governo Federal, mas o órgão também tem nos últimos anos buscado acordos e dados de outros órgãos de governo, além de bancos de dados públicos (PRADO FILHO; GENOVA, 2023; OECD, 2021).

Tal postura ativa do órgão brasileiro no combate a cartéis esteve refletida em seu planejamento estratégico para o período entre 2017 e 2020¹² e no planejamento estratégico para o período de 2021 até 2024¹³. Exemplo concreto de tal estratégia é a “Operação Ponto de Encontro”, deflagrada em outubro de 2018 para apurar suposta formação de cartel em licitações realizadas por órgãos federais para contratação de serviços terceirizados (PIMENTA, 2019). Além deste caso, o método de *screening* também contribuiu para outra operação federal contra cartéis, desta vez em junho de 2017 no mercado de órteses, próteses e materiais médicos especiais (PIMENTA, 2019).

Também vale destacar o Processo Administrativo (PA) nº 08700.004095/2020-15, em que foram avaliadas possíveis infrações à ordem econômica no mercado nacional de produtos e serviços

10 Outras iniciativas de *screening* estrutural podem ser observadas na Índia (ICN; CCI, 2018), o “*Cartel Intelligence Project*” implementado pela *Australian Competition and Consumer Commission* (ACCC), na Austrália; o “*Unified Electronic Information System*” (UEIS) criado pela *Federal Antimonopoly Service* (FAS), na Rússia; e o programa de monitoramento de preços da gasolina nos Estados Unidos, implementado pelo *Federal Trade Commission* (FTC) (JINDGAR, 2019; CHAMMAS, 2015).

11 Os nove indicadores estruturais utilizados são: (i) número de associações comerciais; (ii) relação entre preços praticados na Holanda e nos demais países da União Europeia; (iii) Índice de *Herfindahl-Hirschman* (HHI, em inglês); (iv) número de concorrentes na indústria; (v) taxa de importação; (vi) taxa de crescimento da indústria; (vii) taxa de rotatividade (número de firmas entrando e saindo do mercado); (viii) taxa de sobrevivência (número de firmas que sobreviveram os quatro primeiros anos desde sua entrada); e (ix) Pesquisa e Desenvolvimento (P&D) como proporção das vendas.

12 O Objetivo Estratégico 2 (OE2) do Planejamento Estratégico - 2017/2020 do CADE trata de iniciativas voltadas para “Fortalecer o combate a condutas anticompetitivas”, a partir de projetos como “Projeto Combustível - Combate a cartéis na revenda de combustíveis” e “<Projeto Cérebro> Ampliação e Disseminação da Ferramenta Cérebro no Combate a Crimes contra Concorrência em Licitações” (BRASIL, 2017, p. 6).

13 O OE2 do Planejamento Estratégico - 2021/2024 do CADE também fez menção ao “Projeto Combustível - Combate a cartéis na revenda de combustíveis” (BRASIL, 2023, p. 25).

de inteligência de negócios. Com base em um acordo de leniência entre a Superintendência-Geral do Cade e uma empresa do setor, foi instaurado uma investigação *ex-officio*, que contou com, dentre outras fontes de informação, o uso do Cérebro para analisar dados da Receita Federal e do Redsim e constatar o envolvimento dos acusados na participação das empresas investigadas¹⁴. Em 2021, o Cérebro também foi utilizado para a instauração de investigação sobre suposto cartel em licitação para a contratação de serviços de brigada de incêndio (PA nº 08700.004914/2021-05) (PRADO FILHO; GENOVA, 2023). Na ocasião, foi aplicado *screening* para avaliar o padrão das propostas apresentadas no certame¹⁵.

3. SCREENING ESTRUTURAL VS. COMPORTAMENTAL

O *screening* estrutural consiste na análise de características do mercado ou indústria que tendem a facilitar a ocorrência de cartéis. Trata-se de ferramenta útil para as autoridades antitruste na medida em que permite fazer um levantamento preliminar dos mercados ou indústrias propensos a cartelizar e que, portanto, podem exigir investigações mais aprofundadas (JINDGAR, 2019). Conforme afirma Gonzaga (2018), há um *trade-off* importante relacionado à coleta e análise de indicadores estruturais. Embora seja simples de implementar e de fácil entendimento, a precisão deste método costuma ser baixa. Isso porque os dados setoriais são tipicamente agregados e pode haver uma elevada taxa de falsos positivos¹⁶.

A literatura teórica é vasta no que diz respeito aos fatores estruturais que afetam a estabilidade de cartéis. Em geral, observa-se que a estabilidade do conluio é maior se: há poucos competidores no mercado; os produtos são homogêneos; a demanda é previsível; o mercado encontra-se em estágio maduro em termos de inovação; as variáveis estratégicas das firmas são fáceis de se observar (mercado muito transparente); há elevadas barreiras à entrada; há simetrias relevantes nos custos e capacidades de produção de concorrentes; e se os consumidores têm pouco poder de barganha (MARSHALL; MARX; MEURER 2012).

Na literatura, os métodos de *screening* estrutural são mais utilizados na forma de indicadores agregados de propensão a cartelizar. Isto é, coletam-se dados de variáveis estruturais disponíveis, define-se um critério de ponderação e, então, agregam-se todos os indicadores, de modo que seja possível identificar quais mercados ou indústrias estão mais sujeitos à ocorrência de um cartel¹⁷. Em termos econométricos, seria possível descrever o *screening* estrutural de acordo com a seguinte equação (GONZAGA, 2018; PORTER, 2018):

$$\text{Cartel}_i = \beta X_i + u_i$$

14 SEI nº 1325015.

15 SEI nº 0955048.

16 A questão dos falsos positivos é amplamente debatida na literatura de detecção de cartel. De maneira geral, o falso positivo não gera implicações graves, pois o filtro utilizado não tem caráter probatório. Ao analisar a probabilidade de existência de cartel, Huber e Imhof (2019) sugerem que seja utilizado uma referência entre 50% e 70% (isto é, se a probabilidade de existência de cartel estiver acima deste patamar, o modelo apontará para existência de cartel); Silveira *et al.* (2022) recomendam um patamar de referência entre 60% e 75%.

17 Embora esteja sujeito a um determinado grau de arbitrariedade, tal critério de ponderação costuma ser baseado na literatura teórica e na experiência prática das autoridades antitruste.



em que $Cartel_i$ representa uma dada medida de incidência de cartel, como o número de cartéis descobertos no mercado ou indústria i , multas de cartel aplicadas no mercado ou indústria i , lucro estimado de cartéis detectados no mercado ou indústria i ou uma *dummy* igual a 1 se o mercado ou indústria i já foi alvo de ao menos um cartel e zero, caso contrário; X_i contempla variáveis estruturais do mercado ou indústria i ; e u_i é um termo de erro aleatório.

Ou seja, com base em uma medida a respeito de cartéis já descobertos em um dado setor, deseja-se verificar o poder explicativo de um conjunto de indicadores estruturais. Note-se, no entanto, que o fato de $Cartel_i$ subestimar a ocorrência de cartéis (ao desconsiderar cartéis não detectados) gera um viés no coeficiente β , o que pode comprometer a capacidade preditiva do modelo. Além disso, há um claro problema de seleção, uma vez que os cartéis que não foram detectados podem compartilhar uma característica fundamental para sua não descoberta que não será captada pelo modelo.

O *screening* comportamental, por sua vez, consiste em identificar comportamentos suspeitos que são mais consistentes com um regime de cartel do que de um mercado competitivo. Trata-se de uma análise baseada nos resultados observados nos mercados (*outcome-based analysis*). Harrington (2007) propõe dois tipos de determinantes comportamentais de conluio (*collusive markers*), que devem ser comparados a algum benchmark competitivo (outra região geográfica, outra indústria ou outro período): (i) indicadores de preço¹⁸; e (ii) indicadores de quantidade^{19,20}. Como, em geral, não há recursos suficientes para investigar todos os mercados, tal método costuma ser utilizado a partir da investigação de denúncias de consumidores ou concorrentes a respeito de firmas em um determinado setor (OECD, 2018). Da mesma forma que o *screening* estrutural, o *screening* comportamental também pode ser descrito em termos econométricos (GONZAGA, 2018):

$$S_{it} = \alpha_0 + \alpha_1 Cartel_{it} + \beta X_{it} + u_{it}$$

Nesse caso, S_{it} representa a variável de interesse do modelo utilizado (algum dos *collusive markers* mencionados anteriormente) no mercado ou indústria i no instante de tempo t ; $Cartel_{it}=1$ se há cartel no mercado i no instante t e zero, caso contrário; X_{it} é a matriz de covariadas, assim como no *screening* estrutural; e u_{it} é o termo de erro aleatório. Considerando $\alpha_1 \neq 0$, então $E[S_{it}]$ difere sob concorrência e cartel. No entanto, ressalte-se que há problemas de identificação na medida em que $Cartel_{it}$ representa variável que não é observada. Ademais, um resultado confiável depende de uma boa definição do contrafactual competitivo, o que pode não ser uma tarefa trivial.

18 Preços relativamente elevados e baixa variância; aumentos permanentes de preço que são precedidos por uma forte queda; preço das firmas fortemente correlacionados; elevado grau de uniformidade nos preços praticados pelas concorrentes tanto de seus produtos quanto de serviços complementares; preços alternam de patamar periodicamente (quebras estruturais).

19 *Market shares* estáveis ao longo do tempo; existência de um grupo de firmas em um mercado em que seus *market shares* intragrupo são estáveis ao longo do tempo; *market shares* das firmas negativamente correlacionados.

20 A fim de complementar tais fatores, Marshall, Marx e Meurer (2012) apresentam uma lista de “*super plus behavioural factors*”, que caracterizam comportamentos altamente suspeitos: (i) compartilhamento de informações sensíveis entre concorrentes; (ii) transações entre concorrentes a preços fora do mercado (a preços diferentes daqueles cobrados de terceiros); (iii) mudança repentina de incentivos e estratégias da firma (como alterar preços ao invés de volume); (iv) preços e lucros crescendo quando firmas restringem a produção; e (v) modelo econométrico competitivo bem especificado, mas que se adequa mal ao mercado em questão em um determinado período.

Como será discutido adiante, boa parte da literatura foca em testar técnicas de *screening* já com conhecimento prévio acerca da ocorrência ou não de cartel em um dado mercado, para, a partir daí, aplicar o método em outros contextos. Já os trabalhos que não se baseiam em conhecimento prévio a respeito do cartel costumam lidar com o problema de endogeneidade por meio de diferentes abordagens, como por exemplo: (i) *switching regressions*; (ii) definição de benchmarks ou contrafactuais de acordo com outras informações de mercado; (iii) uso de outliers como ponto de partida para os testes (GONZAGA, 2018)²¹.

Conforme mostra Chammas (2015), para além dos problemas de identificação dos modelos econométricos de *screening*, que restringem seu uso no meio acadêmico, tais métodos podem estar sujeitos a outras limitações. Primeiro, trata-se de ferramentas intensivas em dados, isto é, que exigem quantidade considerável de informações de qualidade²². Além disso, *screenings* costumam ser intensivos em recursos já que exigem treinamento e capacitação técnica, além de métodos econométricos para análise e processamento dos dados, o que pode ser uma limitação para a implementação em grande escala.

Como qualquer método estatístico, *screenings* podem também estar sujeitos a uma elevada taxa de falsos positivos e, principalmente, de falsos negativos. Embora úteis para a condução de investigações, não são capazes de distinguir casos de colusão tácita de colusão explícita. Por fim, conforme adiciona Jindgar (2019), os métodos de *screening* também estão sujeitos à adaptabilidade por parte das firmas. Isto é, ao saber o que gera suspeita por parte da autoridade, as firmas podem evitar certos comportamentos a fim de não serem detectadas²³.

4. APLICAÇÕES RECENTES NA LITERATURA EMPÍRICA DE MÉTODOS DE SCREENING

Bergman *et al.* (2019) classificam a literatura empírica de detecção de cartel em duas categorias: estudos com conhecimento prévio a respeito da existência de cartel e estudos sem nenhum conhecimento prévio, ou seja, trabalhos de verificação e teste de técnicas econométricas, e trabalhos de *screening* propriamente dito (detecção de cartéis desconhecidos), respectivamente. No entanto, segundo os autores, não há uma distinção clara entre ambos, dado que os fatores suspeitos e potenciais provas de conluio podem variar significativamente²⁴.

Boa parte da literatura faz parte do primeiro grupo. Isto é, em geral as aplicações de *screening* até hoje, sejam estruturais ou comportamentais, baseiam-se em informações prévias de cartéis já investigados e condenados. A Subseção 3.1 trata da escassa literatura a respeito de *screenings* estruturais, com destaque para o trabalho de Grout e Sonderegger (2005). Já a Subseção 3.2 aborda

21 Exemplos de discussões e aplicações dos modelos de *switching regressions* na literatura incluem Kiefer (1980), Porter (1983) e Lee e Porter (1984).

22 Conforme destaca Abrantes-Metz (2011): “If you put garbage in, you get garbage out”.

23 Tal adaptabilidade, no entanto, pode ou significar maiores custos de implementação do cartel aos cartelistas ou, de alguma forma, diminuir o impacto negativo do suposto cartel, o que, em ambos os casos, representariam resultados positivos da aplicação do *screening* para a autoridade antitruste e para a sociedade.

24 Dentre os trabalhos de destaque da literatura tradicional de detecção de cartel que se aproveitam da informação da ocorrência de cartel em um dado mercado estão: Froeb Koyak e Werden (1993); Porter e Zona (1993, 1999); Lee (1999); Pesendorfer (2000); Gupta (2001, 2002); e Lee e Hahn (2002). Já no segundo grupo, destacam-se: Bajari e Ye (2003), Ishii (2009), Kawai e Nakabayashi (2014) e Conley e Decarolis (2016).

diversas aplicações de técnicas comportamentais, com ênfase em trabalhos mais recentes que têm focado em métodos de *machine learning*.

4.1 Métodos de *screening* estrutural

Embora seja vasta a literatura teórica acerca de fatores estruturais que afetam a estabilidade de cartéis, há poucas aplicações práticas de *screenings* estruturais. A baixa precisão do método, traduzida em elevadas taxas de falsos positivos e negativos, limita seu uso por autoridades antitruste. Destaca-se neste artigo o estudo de Grout e Sonderegger (2005)²⁵, que é uma referência na literatura na aplicação deste método.

Na linha da equação anterior proposta por Gonzaga (2018), os referidos autores estimam modelos de resposta discreta para identificar setores com elevada probabilidade de ocorrência de cartel no Reino Unido²⁶. Com base em casos investigados na União Europeia desde 1990 e nos Estados Unidos desde 1994, criam uma variável dependente que busca medir a incidência de cartel em diversos setores industriais²⁷. Fatores estruturais que caracterizam estes setores e afetam a estabilidade de cartéis são utilizados como variáveis de controle. Aproveitando-se dos resultados desta primeira estimação, são selecionadas variáveis estruturais do Reino Unido para estimar as probabilidades de conluio.

Conforme discutido na Seção 3, o modelo sofre de problemas de identificação uma vez que a variável de cartelização desconsidera cartéis não detectados, os quais podem apresentar características estruturais distintas daqueles descobertos. Tal problema do viés de seleção deve ser um dos principais pontos da discussão metodológica sobre esses modelos, pois é possível que a diferença nessas características seja precisamente o motivo pelo qual os casos desconsiderados não foram detectados. A principal fragilidade da ferramenta, portanto, é que o modelo não identifica potenciais novos cartéis, mas setores que possuem características similares àqueles em que há evidência de cartel (FOREMNY; DORABIALSKI, 2018)²⁸.

Dentre as hipóteses implícitas no modelo, estão: (i) a localização de cartéis descobertos é informativa a respeito da localização dos cartéis não descobertos (em termos de quais setores industriais são os mais prováveis); (ii) as diferenças estruturais entre os setores é informativa a respeito das diferenças de cartelização entre os setores; e (iii) as diferenças estruturais entre os setores industriais na União Europeia e nos Estados Unidos são similares às diferenças encontradas no Reino Unido. Os resultados indicaram que, na ocasião, os três setores mais propensos à cartelização no Reino Unido eram o de “Telecomunicações”, com probabilidade de 0,84; o de “Produção de aeronaves

25 O trabalho, encomendado pelo departamento antitruste do governo do Reino Unido na época, *Office of Fair Trading* (OFT), é dividido em três partes. Primeiro, os autores fazem uma revisão da literatura teórica a respeito dos fatores mais relevantes para a formação e estabilidade de conluios. A segunda etapa constitui um exercício econométrico. Por fim, são discutidos estudos de caso.

26 São estimados modelos Logit, Logit ordenado, além de Mínimos Quadrados Ordinários (MQO) para o caso de variável dependente contínua.

27 Para cada jurisdição é construído um índice que indica quantos cartéis ocorreram em uma determinada indústria no período considerado (ou uma *dummy* igual a 1 para as indústrias que já foram alvo de ao menos um caso de cartel e zero, caso contrário). Sob uma agregação de três dígitos segundo a *Standard Industrial Classification* (SIC), observa-se forte correlação entre as bases de dados, de 0.68.

28 Embora reconheçam os problemas econométricos, os autores afirmam que o modelo ainda é válido na medida em que é capaz de identificar padrões significantes nos dados.

e naves espaciais” (0,65); e o de “Produção de produtos cereais e amiláceos” (0,61)²⁹.

Com base na literatura teórica e em estudos de casos de cartéis investigados, Grout e Sonderegger (2005) elencam quais são os fatores estruturais mais relevantes para a ocorrência de cartéis. Um dos principais deriva do lado da demanda: declínios nos preços estão fortemente associados com a formação de cartéis, seja via quedas prolongadas de médio e longo prazo ou via quedas abruptas, geradas por um choque negativo na demanda³⁰. Segundo os autores cartéis mostram-se mais prováveis quando as condições de mercado são estáveis.

Os resultados indicam também que a maioria dos casos analisados ocorreu em setores concentrados, com poucos concorrentes e produtos homogêneos, em linha com a literatura teórica. Embora diferenças no tamanho das empresas estejam relacionadas com assimetrias de custo, que por sua vez tendem a desestabilizar cartéis, nota-se nos casos analisados significativa heterogeneidade nos *market shares*³¹.

Em suma, ainda que possa contribuir com o processo de detecção de cartéis por parte de autoridades, observa-se que o *screening* estrutural constitui um método relativamente pouco sofisticado. Assim, não se deve assumir que os resultados derivados de sua aplicação e as conclusões deles derivados são representativas da realidade, sendo mais adequado interpretar os resultados como indicadores de mera probabilidade e não necessariamente de existência de cartel. Como se verá na próxima seção, a literatura nacional sobre detecção de cartéis avançou mais na direção do *screening* comportamental do que no estrutural.

4.2 Métodos de *screening* comportamental

Harrington (2008) divide a literatura empírica de *screenings* comportamentais em quatro categorias. Há estudos que testam: (i) se um dado comportamento observado difere de forma estatisticamente significativa daquele esperado em um regime de concorrência; (ii) se o comportamento de um determinado grupo de firmas tem comportamento distinto das demais; (iii) se há quebras estruturais no comportamento dos agentes; e (iv) se um modelo de conluio descreve melhor os dados do que um modelo competitivo. A seguir são discutidos trabalhos recentes com base nessa categorização³², segmentando entre literatura nacional e internacional.

A literatura acadêmica nacional possui alguns exemplos de estudos que se enquadram nas

29 A lista completa de 30 setores apresentada no artigo deriva da análise conjunta dos diferentes modelos estimados e desconsidera setores industriais em que já houve casos de cartel detectados, quais sejam: produtos químicos, transportes aquáticos, farmacêutico, tubulações, processamento de alimentos, bebidas não alcoólicas, borracha, produtos plásticos e pesticidas.

30 Dentre os exemplos citados de cartéis formados após quedas abruptas de preço estão os casos no setor de operadores ferroviários – *Currency Sur-charges Case* (97/84/EC); no setor de carne bovina na França (2003/600/EC); e no setor bancário na Alemanha (2003/25/EC). Já dentre cartéis influenciados por condições adversas prolongadas, destacam-se casos no setor petroquímico (94/599/EC); no setor de tubulações de aço (2003/382/EC); e no segmento de eletrodos de grafite (2002/271/EC).

31 Nota-se que a análise se baseia em cartéis detectados, o que significa que a heterogeneidade nos *market shares* pode ter, de fato, contribuído com sua desestabilização.

32 Como se verá, tais categorias não são necessariamente excludentes. Trabalhos de detecção de cartel em licitações, por exemplo, enquadram-se tanto no primeiro quanto no segundo grupo proposto por Harrington (2008) e há inúmeros exemplos de aplicações na literatura. Porter (2005) e Abrantes-Metz e Prewitt (2015) fazem uma ampla revisão da literatura nesse sentido.

duas primeiras categorias apontadas por Harrington (2008). Com relação à primeira delas, Ragazzo e Silva (2006) propõem uma metodologia que analisa a relação entre preços, custos e margens de revenda no mercado de gasolina no Brasil. Já Vasconcelos e Vasconcelos (2009) aplicam um filtro de DDV (*Directed Divergence Statistic*) neste mesmo mercado para medir a diferença entre as distribuições de preços de concorrentes³³.

Trabalhos focados no comportamento dos agentes em licitações também pertencem às duas primeiras categorias, e há exemplos nacionais e internacionais. No caso brasileiro, destaca-se Lima e Resende (2019)³⁴, que avaliam o mercado brasileiro de equipamentos cardiovasculares, alvo de um cartel entre 2005 e 2015. Baseados em Lundberg (2017), os autores aplicam a estatística de I de Moran nos resíduos da regressão do vetor de lances sobre variáveis do mercado³⁵. Assim, a potencial autocorrelação entre lances observada por meio da estatística I de Moran pode ser atribuída a variáveis não observáveis, dentre as quais estão um possível comportamento colusivo.

Já na literatura internacional, dentre os estudos mais recentes, vale destacar o de Bergman *et al.* (2020), que lança mão de modelos econométricos espaciais para testar a hipótese de independência condicional dos lances nos leilões do mercado de asfalto na Suécia³⁶. Em 2001, foram realizadas buscas e apreensões em diversas cimenteiras no país e, dois anos depois, nove delas foram condenadas por participar de um cartel. A base de dados utilizada pelos autores contempla o período de 1995 e 2009, o que permite a implementação do teste antes e depois do início das investigações. Com base no conhecimento prévio a respeito dos integrantes do cartel e em todas as informações disponíveis aos licitantes, os autores aplicam uma metodologia espacial para avaliar se os lances realizados no leilão dependem dos demais. Os resultados indicam comportamento colusivo entre os membros do cartel antes de 2002, enquanto o parâmetro de interesse que sugere existência de cartel é insignificante após 2003, indicando lances competitivos.

Huber e Imhof (2019), por sua vez, combinam métodos de *screening* com técnicas de *machine learning* para prever colusão em licitações fraudulentas nos mercados de construção e serviços de engenharia na Suíça. Também se aproveitando do conhecimento prévio de cartéis, os autores identificam corretamente 84% de todos os 584 processos licitatórios analisados como colusivos ou não colusivos. Com esse mesmo propósito, Walliman e Sticher (2023) avaliam lances feitos em licitações para construções e manutenções na infraestrutura ferroviária suíça. Para tanto, os autores utilizam técnicas de *machine learning* para encontrar padrões suspeitos nos lances de alguns grupos de empresas. Para treinar os modelos no reconhecimento de padrões suspeitos (em mercado sem conhecimento prévio de cartel), os autores baseiam-se em cartéis condenados em outros setores da economia suíça.

Especificamente com relação à segunda categoria indicada por Harrington (2008), de estudos que avaliam se o comportamento de um determinado grupo de firmas tem comportamento distinto

33 Ambas as aplicações são discutidas em Cuiabano *et al.* (2014), que fazem uma revisão da literatura empírica de *screenings* comportamentais com foco no Brasil. Conforme explicam os autores, boa parte das aplicações no país tratam do mercado de combustíveis devido à elevada disponibilidade de dados da Agência Nacional de Petróleo (ANP).

34 Outro artigo nacional que trata de fraude em licitações é de Souza e Louzada (2020).

35 A estatística I de Moran utilizada leva em conta os pesos de uma matriz de ponderação, W , e foi introduzida pela primeira vez por Moran (1948).

36 Métodos de econometria espacial são tradicionalmente utilizados em áreas como economia do setor público, economia regional e urbana, economia agrícola e do meio ambiente (ANSELIN, 2003).

das demais, vale citar também outro exemplo no Brasil, que é o de Silveira *et al.* (2022). Os autores aplicam diversos métodos de *machine learning* na análise de cartel em postos de gasolina que foram detectados pelo Cade em algumas cidades do Brasil. Os resultados encontrados mostram que, a partir da implementação da metodologia, seria possível prever com sucesso uma parcela significativa dos casos de cartel nesse setor. Destaca-se também a calibragem do modelo visando a diminuir erros. Ao ajustar o modelo para diminuir o número de falsos-positivos, observou-se que o número de falsos-negativos aumentou consideravelmente, o que pode não ser desejado pelas autoridades competentes.

Já com relação a testes de quebra estrutural, terceira categoria da literatura empírica sugerida por Harrington (2008), a literatura nacional é incipiente, sendo necessário recorrer à literatura internacional para encontrar tais tipos de estudo. Nesse sentido, destaca-se o trabalho pioneiro de Abrantes-Metz *et al.* (2006). Após o colapso de um cartel de licitação na indústria de peixes congelados na Filadélfia, nos Estados Unidos, os autores identificam uma redução de 16% no preço médio e um aumento de 200% no seu desvio padrão, sem nenhuma contrapartida justificável na estrutura de custos das empresas. Assim, a hipótese é de que a formação de cartéis em outras indústrias poderia exibir movimentos similares, mas no sentido contrário. A mesma metodologia foi então aplicada para o mercado de varejo de gasolina em Louisville, no estado americano de Kentucky³⁷. Esposito e Ferrero (2006) também aplicaram a técnica de *variance screen* para dois cartéis italianos, um no mercado de combustíveis e outro no mercado de produtos de higiene pessoal e leite para crianças.

Bolotova, Connor e Miller (2008) avaliaram os cartéis internacionais de ácido cítrico e lisina, ocorridos no final da década de 1990. Por meio de extensões dos modelos de heteroscedasticidade condicional auto-regressiva (ARCH, na sigla em inglês) e ARCH generalizado (GARCH), os autores testam a hipótese de que o comportamento dos dois primeiros momentos da distribuição de preço em um regime de cartel é diferente daquele observado durante períodos de concorrência, em que se espera preços menores e mais voláteis. Os resultados indicam que o cartel elevou o preço médio de ácido cítrico em 9 centavos de dólar por libra em relação ao período competitivo. Não se identificaram efeitos significativos para a variância. No caso da lisina, o aumento relativo no preço médio foi de 24,79 centavos de dólar por libra, enquanto a variância diminuiu. Diante de resultados ambíguos para a variância, os autores sugerem cautela na implementação de *variance screens* para detecção de cartel³⁸.

Já Blanckenburg, Kholodilin e Geist (2012) argumentam em favor da técnica. Com base em dados de 11 casos condenados de cartel, os autores avaliam informações a respeito da média, curtose e assimetria das distribuições de preços e concluem que apenas a variância poderia ser entendida como um indicador robusto para a ocorrência de colusão. Hüschelrath e Veith (2013), no entanto, chegam em uma conclusão diferente ao analisar 340 mil transações realizadas durante um cartel no mercado de cimento na Alemanha. Por meio de testes de média sequenciais para detectar quebras estruturais nos preços, os autores afirmam que com essa abordagem seria possível ter detectado o cartel antes dele ter sido descoberto pela autoridade antitruste alemã.

37 Conforme afirmam Abrantes-Metz e Froeb (2008), foi a partir de então que diferentes autoridades antitruste passaram a utilizar o método para identificar mercados com variância de preços relativamente baixa.

38 Segundo os autores, modelos que lidam com diferentes momentos da distribuição de preços de forma conjunta tendem a tratar comportamentos colusivos de forma mais robusta do que modelos que lidam apenas com preço médio ou variância, separadamente.



Heijnen, Haan e Soetevent (2015) optam por uma abordagem mais sofisticada do *variance screen* ao identificar clusters de variância relativamente reduzida no mercado de combustível na Holanda. Já Crede (2015) propõe um novo método de *screening* comportamental que se baseia na identificação de quebras estruturais no processo gerador dos dados. O autor avalia três mercados de massas, na Itália, Espanha e França, sendo que nos dois primeiros foram identificados casos de cartel e no último foi observado um aumento significativo dos preços, mas devido a um choque nos custos. O método é capaz de detectar os cartéis que de fato ocorreram e não identifica um falso positivo no mercado francês.

Por fim, a maioria dos modelos estruturais de *screening*, os quais compõem a quarta categoria sugerida por Harrington (2008), fazem parte de uma literatura mais tradicional de conduta. Davis e Garcés (2010) apresentam detalhada revisão da literatura tradicional de identificação de conduta, assim como Doane *et al.* (2015). Neste caso vale destacar artigo da literatura internacional, de Hyytinen, Steen e Toivanen (2010), em que os autores aplicam o *Hidden Markov Model* (HMM) com o objetivo de avaliar a existência de colusão na indústria manufatureira na Finlândia.

Como é possível observar, seja na literatura nacional, seja na internacional, observa-se uma preferência cada vez maior pela aplicação de técnicas de *machine learning* no contexto de detecção de cartel. De acordo com Beth e Gannon (2022), em um contexto de constante aumento na complexidade do funcionamento de cartéis, a utilização desta abordagem para adaptar e melhorar os filtros existentes à medida que mais informações são coletadas torna-se fundamental. Segundo os autores, com uma base rica o suficiente de casos conhecidos de cartel, passa a ser possível treinar algoritmos específicos para a detecção de padrões que se repetem com a presença de cartel. Quanto mais dados estiverem disponíveis, mais aprimoramentos na metodologia podem ser feitos, de modo que a implementação dessas técnicas não representa uma solução definitiva, mas sim uma maneira gradual de conseguir resultados cada vez mais precisos e refinados na busca por cartéis.

Harrington e Imhof (2022) destacam um detalhe relevante do ponto de vista teórico no âmbito destas aplicações. De acordo com os autores, a utilização de *machine learning*, no geral, não é feita para identificar uma relação causal entre um evento X e um evento Y, mas sim utilizar X para prever Y. Essa diferenciação é fundamental, pois, assim, boa parte dos problemas econométricos oriundos da identificação de um modelo desaparecem, em particular, a elevada colinearidade entre as variáveis explicativas. Prioriza-se com tais técnicas a previsibilidade (minimização de erros de previsão), em detrimento da causalidade, objeto de análise em abordagens econométricas. Ademais, a forma funcional do modelo utilizado pode ser bem flexível e não-linear, já que o objetivo do modelo não é estimar os coeficientes associados às variáveis explicativas, mas sim prever o resultado da variável explicada (que geralmente é uma variável binária indicando a presença, ou não, de cartel). Isto é, a existência de viés nos estimadores pode deixar de ser um problema, ao contrário das abordagens econométricas em que é fundamental que os modelos sejam não-viesados³⁹.

Contudo, há de se ter cautela com o uso de *machine learning* na detecção de cartéis. Em primeiro lugar, como visto, bons resultados dependem fortemente de uma boa (e vasta) base de dados para treinar os modelos. Ademais, pode ser forte a hipótese de que um modelo treinado para

39 Mais detalhes sobre a diferenciação entre técnicas de *machine learning* e abordagens econométricas podem ser vistas no vídeo “Métodos de Quantificação de Danos de Cartéis e Bid-Rigging: Proposta de Guia Parte 2.” disponível no canal do IPEA (MÉTODOS..., 2020).

detectar cartéis em um determinado setor, em uma determinada região e em um determinado período é adequado para detectar cartéis em outras circunstâncias⁴⁰. Harrington e Imhof (2022) discutem esse tema e chamam esse problema de “transposição preditiva do modelo”. Para os autores, mesmo que a transposição seja feita para o mesmo setor, é necessário ter cautela na utilização dos resultados advindos de um modelo treinado em outro contexto.

Tendo em vista a variedade de abordagens, modelos e premissas dos métodos de *screening* comportamental para detecção de cartéis, tanto no Brasil quanto no resto do mundo, há diferentes maneiras de categorizar a literatura empírica, tal como fez Harrington (2008). O Quadro 1 apresenta uma lista não exaustiva de artigos relevantes classificando-os a partir de dois critérios: se a aplicação do *screening* possui ou não conhecimento prévio a respeito da existência do cartel, e o método de *screening* comportamental utilizado. Em negrito os artigos que aplicam técnicas de *screening* no Brasil.

40 Huber, Imhof e Ishii (2022) analisam exatamente essa questão com base em dados do setor de construção na Suíça e no Japão. Os autores encontram que mesmo os modelos de *machine learning* com melhores índices de acertos perdem uma parte de sua capacidade preditiva ao serem utilizados em um país diferente do qual foram treinados (vale ressaltar, contudo, que mesmo assim eles ainda podem ser úteis).



Quadro 1 - Tabela-resumo com classificação da literatura empírica de *screening* comportamental

Método de <i>screening</i>		Conhecimento prévio a respeito da existência do cartel	Nenhum conhecimento prévio a respeito da existência do cartel
Abordagem econométrica	Séries de tempo	Gülen (1996) – <i>Is OPEC a Cartel? Evidence from Cointegration and Causality Tests</i> Vasconcelos e Vasconcelos (2005) – Investigações e obtenção de provas de cartel: por que e como observar paralelismo de conduta Bolotova, Connor e Miller (2008) – <i>The impact of collusion on price behavior: Empirical results from two recent cases</i> Hüschelrath e Veith (2013) – <i>Cartel Detection in Procurement Markets</i> Albuquerque e Cuiabano (2015) – <i>Two stage screening for cartel detection</i>	Abrantes-Metz et al. (2006) – <i>A variance screen for collusion</i> Vasconcelos e Vasconcelos (2009) – Ferramentas de detecção dos acordos em preços no mercado de gasolina a varejo Mena-Labarthe (2012) – <i>Mexican Experience in Screens for Bid-Rigging*</i>
		Crede (2015) – <i>A structural break cartel screen for dating and detecting collusion</i> Silveira et al. (2021) – Cartel Screening in the Brazilian Fuel Retail Market	
	Econometria espacial	Lundberg (2017) – <i>On cartel detection and Moran’s I*</i> Bergman et al. (2020) – <i>Interactions Across Firms and Bid Rigging*</i> Lima e Resende (2019) WP – <i>Using the Moran’s I to Detect Bid Rigging in Brazilian Procurement Auctions*</i>	
Modelos em painel	Modelos em painel	Porter e Zona (1993) – <i>Detection of bid rigging in procurement auctions*</i> Porter e Zona (1999) – <i>Ohio school milk markets: An analysis of bidding*</i> Lee (1999) – <i>Non-cooperative tacit collusion, complementary bidding and incumbency premium*</i> Pesendorfer (2000) – <i>A study of collusion in first-price auctions (desenvolve modelo teórico)*</i> Gupta (2001) – <i>The effect of bid rigging on prices: A study of the highway construction industry*</i> Fetter (2012) – Detecção de cartéis por marcadores de colusão	Bajari e Ye (2003) – <i>Deciding between competition and collusion (desenvolve modelo teórico)*</i> Ishii (2009) – <i>Favour exchange in collusion: Empirical study of repeated procurement auctions in Japan*</i>
		Hyytinen et al. (2010) – <i>Cartels Uncovered</i> Conley e Decarolis (2016) – <i>Detecting bidders groups in collusive auctions (desenvolve modelo teórico)*</i>	

<p>Abordagens estatísticas</p>	<p>Esposito e Ferrero (2006) – <i>Variance screen for detecting collusion – an application to two cartel cases in Italy</i></p> <p>Samà (2014) – <i>Cartel Detection and Collusion Screening: An Empirical Analysis of the London Metal Exchange</i></p> <p>Gani (2017) – <i>Detection of abusively low prices in Tunisian public procurement using control charts*</i></p> <p>Imhof (2017) WP – <i>Simple Statistical Screens to Detect Bid Rigging*</i></p> <p>Wachs e Kertesz (2019) – <i>A network approach to cartel detection in public auction markets*</i></p>	<p>Conti e Naldi (2008) – <i>Detection of anomalous bids in procurement auctions*</i></p> <p>Lorenz (2008) – <i>Screening markets for cartel detection – collusive marker in the CFD cartel-audit</i></p> <p>Haider e Hunter (2010) – <i>Screening and Testing for Collusive Conduct in the Absence of a Smoking Gun</i></p> <p>Heijnen, Haan e Soetevent (2015) – <i>Screening for collusion: a spatial statistics approach</i></p> <p>OECD (2016) – <i>Country case: Korea FTC BRIAS*</i></p> <p>Imhof, Karagök e Rutz (2018) – <i>Screening for Bid-Rigging – Does it Work?*</i></p> <p>Carijo (2019) – Análise estatística dos preços de combustíveis para auxílio na detecção de cartéis no setor de distribuição</p>
	<p>Kawai e Nakabayashi (2014) – <i>Detecting Large-Scale Collusion in Procurement Auctions*</i></p>	
<p>Algoritmos e <i>Machine Learning</i></p>	<p>Huber e Imhof (2019) – <i>Machine learning with screens for detecting bid-rigging cartels*</i></p> <p>Harrington e Imhof (2022) – <i>Cartel screening and machine learning*</i></p> <p>Silveira et al. (2022) – <i>Won't get fooled again: A supervised machine learning approach for screening gasoline cartels</i></p> <p>Huber et al. (2022) – <i>Transnational machine learning with screens for flagging bid-rigging cartels*</i></p>	<p>de Souza e Louzada (2020) – Detectando conluio em compras governamentais: Uma abordagem utilizando red flags e a Teoria Dempster-Shafer*</p> <p>Walliman e Sticher (2023) – <i>On suspicious tracks: machine-learning based approaches to detect cartels in railway-infrastructure procurement*</i></p>

Fonte: elaboração própria. (*) Com asterisco os trabalhos que tratam de conluio em licitações públicas. Os trabalhos nacionais estão destacados em negrito.

Em suma, observa-se que a literatura acadêmica nacional de detecção de cartel a partir de *screenings* comportamentais encontra-se bastante alinhada com a literatura internacional. Dada a maior disponibilidade de dados e, inclusive, a própria ênfase que tem sido dada pelo Cade no âmbito do Projeto Cérebro, muitos artigos no Brasil têm focado em avaliar comportamentos colusivos em licitações públicas. Outro aspecto que chama atenção, em linha com a experiência internacional, é a recente priorização por técnicas de *machine learning*, também objeto de estudos do Cérebro.

Tais tendências têm se mostrado muito relevantes para autoridades antitruste no que tange à detecção de cartéis. Isso porque, como na abordagem de *machine learning* o objetivo é minimizar erros de previsão sobre a possível existência de cartel, e não necessariamente isolar efeitos de outras variáveis para se estabelecer relações de causalidade (como no caso de abordagens econométricas



tradicionais), a tendência recente de priorização desta metodologia pela comunidade antitruste – ainda mais quando voltadas para licitações públicas (com maior disponibilidade de dados) –, será importante para elevar a frequência de trabalhos de *screening* sem conhecimento prévio de cartel.

5. CONSIDERAÇÕES FINAIS

Buscou-se neste artigo apresentar uma revisão da literatura empírica recente, nacional e internacional a respeito do uso de métodos de *screening* para a detecção de cartéis no Brasil e no mundo. Além de focar em estudos mais recentes, os quais têm focado em técnicas de *machine learning*, este artigo contribui com a literatura na medida em que também discute *screenings* estruturais.

Note-se que diversas autoridades antitruste têm seguido as recomendações de organizações internacionais de combinar o uso de métodos reativos com proativos na detecção de cartéis. Há iniciativas importantes no uso de *screenings*, especialmente no âmbito de licitações públicas, dada a maior disponibilidade de dados. O mesmo se observa na literatura empírica, em que técnicas de *machine learning* têm ganhado espaço. Abordagens estruturais são pouco comuns, dado que costumam ser pouco precisas e apenas indicam uma propensão à cartelização.

Pode-se afirmar que ainda não há consenso a respeito da melhor técnica de *screening* comportamental. Há estudos, por exemplo, que focam na variância dos preços, outros que buscam quebras estruturais no nível e aqueles que combinam análises de diferentes momentos das distribuições de preços. Comum à maioria dos trabalhos é o fato de se basearem no conhecimento prévio a respeito da existência de cartel. Dessa forma, o desafio de identificação dos modelos econométricos continua sendo um entrave para o uso dos métodos de *screening*.

Nos últimos anos, contudo, seja devido à complexidade dos desafios de identificação dos modelos econométricos, seja pelo contexto de aumento na complexidade do funcionamento dos acordos colusivos, tem ganhado espaço o uso de técnicas de *machine learning*, tal como vem fazendo o Projeto Cérebro no Cade. Trata-se de uma nova tendência na literatura empírica de métodos de *screening* que, aproveitando-se de uma maior oferta de dados (como são os casos de licitações públicas), está voltada principalmente à maior previsibilidade e precisão no processo de detecção de cartéis, em detrimento da causalidade.

Tendo em vista as diferentes dinâmicas setoriais e regionais, seu uso ainda exige cautela por parte dos pesquisadores e autoridades antitruste, mas certamente representa avanço relevante e promissor no combate a cartéis. Em particular, tal tendência recente será importante para elevar a frequência de trabalhos de *screening* sem conhecimento prévio de cartel, beneficiando as autoridades antitruste no mundo todo.

REFERÊNCIAS

ABRANTES-METZ, Rosa M. *et al.* A variance screen for collusion. **International Journal of Industrial Organization**, [S. l.], v. 24, n. 3, p. 467-486, maio 2006. Disponível em: <https://tinyurl.com/25ualw2k>. Acesso em: 1 abr. 2024.

ABRANTES-METZ, Rosa M. **Screens for Conspiracies and their Multiple Applications**. Washington: The

American Bar Association (ABA), 2011. Disponível em: <https://tinyurl.com/23csc4k9>. Acesso em: 1 abr. 2024.

ABRANTES-METZ, Rosa M.; FROEB, Luke M. Competition Agencies Are *Screening* for Conspiracies: What Are They Likely to Find? **Economics Committee Newsletter**, [S. l.], v. 8, n. 1, 2008. Disponível em: <https://tinyurl.com/2bmzk9nh>. Acesso em: 1 abr. 2024.

ABRANTES-METZ, Rosa M.; PREWITT, Elizabeth. **Antitrust compliance 2.0**: The use of structural analysis and empirical screens to detect collusion and corruption in bidding procurement processes. **Competition Policy International**, [S. l.], 2015. Disponível em: <https://tinyurl.com/2c5x474o>. Acesso em: 1 abr. 2024.

ALBUQUERQUE, Pedro H. M.; CUIABANO, Simone Maciel. Two stage *screening* for cartel detection. In: ANNUAL COMPETITION CONFERENCE: COMPETITION POLICY AND *ENFORCEMENT* IN BRICS COUNTRIES, 9., 2015, Durban. **Anais [...]**. Durban: *Competition Commission* South Africa, 2015. Disponível em: <https://tinyurl.com/24hrqrvk>. Acesso em: 1 abr. 2024.

ANSELIN, Luc. Spatial econometrics. In: BALTAGI, Badi H (ed.). **A Companion to Theoretical Econometrics**. Malden: Blackwell Publishing, 2003. p. 310–330. Disponível em: <https://tinyurl.com/2dlw6aw6>. Acesso em: 1 abr. 2024.

BAJARI, Patrick; YE, Lixin. Deciding between competition and collusion. **Review of Economics and statistics**, [S. l.], v. 85, n. 4, p. 971-989, nov. 2003. Disponível em: <https://tinyurl.com/2cfduyqn>. Acesso em: 1 abr. 2024.

BERGMAN, Mats. A. *et al.* Interactions across firms and bid rigging. **Review of Industrial Organization**, [S. l.], v. 56, p. 107-130, 2020. DOI: <https://doi.org/10.1007/s11151-018-09676-0>. Disponível em: <https://tinyurl.com/29na7mc5>. Acesso em: 1 abr. 2024.

BETH, Hannes; GANNON, Oliver. Cartel *screening*: can competition authorities and corporations afford not to use big data to detect cartels? **Competition Law & Policy Debate**, v. 7, n. 2, p. 77-88, mar. 2022. DOI: [doi: 10.4337/clpd.2022.0001](https://doi.org/10.4337/clpd.2022.0001). Disponível em: <https://tinyurl.com/22z5ykph>. Acesso em: 2 abr. 2024.

BLANCKENBURG, Korbinian Von.; KHOLODILIN, Konstantin A.; GEIST, Alexander. The Influence of Collusion on Price Changes: New Evidence from Major Cartel Cases. **German Economic Review**, [S. l.], v. 13, n. 3, p. 245–256, 2012. DOI: <https://doi.org/10.1111/j.1468-0475.2011.00558.x>. Disponível em: <https://tinyurl.com/2appgbq7>. Acesso em: 1 abr. 2024.

BOLOTOVA, Yuliya; CONNOR, John M.; MILLER, Douglas J. The impact of collusion on price behavior: Empirical results from two recent cases. **International Journal of Industrial Organization**, [S. l.], v. 26, n. 6, p. 1290-1307, 2008. Disponível em: <https://tinyurl.com/2brvwhld>. Acesso em: 1 abr. 2024.

BRASIL. Conselho Administrativo de Defesa Econômica. **Plano de gestão anual 2020**: planejamento estratégico CADE - 2017/2020. Brasília, DF: CADE, 2017. Disponível em: <https://tinyurl.com/2cf3rnx8>. Acesso em: 8 jan. 2024.

BRASIL. Conselho Administrativo de Defesa Econômica. Plano Estratégico CADE 2024: por um Brasil mais competitivo. 2. rev. Brasília, DF: CADE, 2023. Disponível em: <https://tinyurl.com/2d9x3wq5>. Acesso em: 8 jan. 2024.

CARRIJO, Gustavo Dantas. **Análise estatística dos preços de combustíveis para auxílio na detecção**



de cartéis no setor de distribuição. 2019. Monografia (Especialização em Governança e Controle da Regulação em Infraestrutura) – Escola Nacional de Administração Pública, Brasília, 2019. Disponível em: <https://tinyurl.com/237wg2l7>. Acesso em: 8 jan. 2024.

CASTRO, André *et al.* **Identifying Behaviors and Irregularities in Public Procurement in the Brazilian Federal Government.** Brasília, DF: Ministério do Planejamento, Orçamento e Gestão, 2018. Disponível em: <https://tinyurl.com/27o7hnes>. Acesso em: 15 abr. 2024.

CHAMMAS, Mona. International Experiences with *Screening* to Detect Cartels. In: **Presentation from the Organisation for Economic Co-operation and Development (OCDE) Competition Division.** Brussels: OCDE, 2015.

CONLEY, Timothy G.; DECAROLIS, Francesco. Detecting bidders groups in collusive auctions. **American Economic Journal: Microeconomics**, [S. l.], v. 8, n. 2, p. 1-38, maio 2016. DOI: 10.1257/mic.20130254. Disponível em: <https://tinyurl.com/2aslecx3>. Acesso em: 5 abr. 2024.

CONTI, Pier Luigi; NALDI, Maurizio. Detection of anomalous bids in procurement auctions. **Decision Support Systems**, [S. l.], v. 46, n. 1, p. 420-428, 2008. DOI: <http://dx.doi.org/10.2139/ssrn.1493346>. Disponível em: <https://tinyurl.com/27wv79gz>. Acesso em: 8 jan. 2024.

CREDE, Carsten J. A structural break cartel screen for dating and detecting collusion. **Centre for Competition Policy Working Paper**, Norwich, n. 15-11, 2015. Disponível em: <https://tinyurl.com/278mudx8>. Acesso em: 8 jan. 2024.

CUIABANO, Simone Maciel *et al.* Filtrando cartéis: a contribuição da literatura econômica na identificação de comportamentos colusivos. **Revista de Defesa da Concorrência**, Brasília, DF, v. 2, n. 2, p. 43-63, nov. 2014. Disponível em: <https://tinyurl.com/2bd6djm4>. Acesso em: 8 jan. 2024.

DAVIS, Peter; GARCÉS, Eliana. **Quantitative techniques for competition and antitrust analysis.** Nova Jersey: Princeton University Press, 2010.

DOANE, Michael J. *et al.* Screaming for collusion as a problem of indifference. In: BLAIR, Roger D.; SOKAL, Daniel D. (edit.). **Oxford handbook of international antitrust economics.** Nova York: Oxford University Press, 2015. v. 2. p. 523-553.

ESPOSITO, Fabio Massimo; FERRERO, Massimo. *Variance screens* for detecting collusion: an application to two cartel cases in Italy. In: WORKSHOP ON FORENSIC ECONOMICS IN COMPETITION LAW ENFORCEMENT, 2., Amsterdam, 2006. **Documento de Trabalho** [...]. Amsterdam: ACLE, 2006. Disponível em: <https://tinyurl.com/27cmt7qh>. Acesso em: 8 jan. 2024.

ESTATÍSTICAS do Programa de Leniência do Cade. **Conselho Administrativo de Defesa Econômica**, Brasília, 8 maio 2024. Disponível em: <https://tinyurl.com/2ynfujo8>. Acesso em: 13 abr. 2024.

FETTER. Seiji Kumon. **Detecção de cartéis por marcadores de colusão.** Orientador: Paulo Furquim de Azevedo. 2012. Dissertação (Mestrado em Economia) - Escola de Economia de São Paulo, Fundação Getúlio Vargas, São Paulo, 2012. Disponível em: <https://tinyurl.com/25sgbum8>. Acesso em: 9 jan. 2024.

FOREMNY, Andrzej; DORABIALSKI, Wojciech. Review of collusion and bid rigging detection methods in the construction industry. In: CREATIVE CONSTRUCTION CONFERENCE, 2018, Ljubljana. **Proceedings** [...]. Ljubljana: Mirosław J. Skibniewski & Miklos Hajdu, 2018. Disponível em: <https://tinyurl.com/29ln5w3r>. Acesso em: 5 jun. 2024.

FROEB, Luke M.; KOYAK, Robert A.; WERDEN, Gregory J. What is the effect of bid-rigging on prices? **Economics Letters**, [S. l.], v. 42, n. 4, p. 419-423, 1993. DOI: [https://doi.org/10.1016/0165-1765\(93\)90095-T](https://doi.org/10.1016/0165-1765(93)90095-T). Disponível em: <https://tinyurl.com/292xca7g>. Acesso em: 9 jan. 2024.

GANI, Walid. Detection of abusively low prices in Tunisian public procurement using control charts. **International Journal of Procurement Management**, [S. l.], v. 10, n. 5, p. 568-580, 2017. Disponível em: <https://tinyurl.com/2ce9d8lb>. Acesso em: 12 abr. 2024.

GONZAGA, Pedro. **Cartel Screens in the Digital Era**. Paris: OECD, 2018. Presentation from the Organisation for Economic Co-operation and Development. Disponível em: <https://tinyurl.com/2ybm7gkb>. Acesso em: 12 abr. 2024.

GROUT, Paul; SONDEREGGER, Silvia. **Predicting cartels (OFT773)**. [S. l.]: Office of fair trading, 2005.

GÜLEN, S. Gücan. Is OPEC a cartel? Evidence from cointegration and causality tests. **The Energy Journal**, [S. l.], v. 17, n. 2, p. 43-57, 1996. DOI: <https://doi.org/10.5547/ISSN0195-6574-EJ-Vol17-No2-3>. Disponível em: <https://tinyurl.com/28nlqna9>. Acesso em: 9 jan. 2024.

GUPTA, Srabana. Competition and collusion in a government procurement auction market. **Atlantic Economic Journal**, [S. l.], v. 30, p. 13-25, 2002. DOI: <https://doi.org/10.1007/BF02299143>. Disponível em: <https://tinyurl.com/2brtj6ry>. Acesso em: 9 jan. 2024.

GUPTA, Srabana. The effect of bid rigging on prices: a study of the highway construction industry. **Review of Industrial Organization**, [S. l.], v. 19, p. 451-465, 2001. Disponível em: <https://www.jstor.org/stable/41799060>. Acesso em: 8 jan. 2024

HAIDER, Laila; HUNTER, Graeme. *Screening* and Testing for Collusive Conduct in the Absence of a Smoking Gun. **Nera Economic Consulting**, [S. l.], 2010. Disponível em: <https://tinyurl.com/25z8oe2h>. Acesso em: 8 jan. 2024.

HARRINGTON JR, Joseph E.; IMHOF, David. *Cartel screening* and *machine learning*. **Stanford Computational Antitrust**, [S. l.], v. 2, p. 133-154, 2022. Disponível em: <https://tinyurl.com/2bjmvser>. Acesso em: 1 jan. 2024.

HARRINGTON JR., Joseph E. *Behavioural Screening* and the Detection of Cartels. In: EHLERMANN, Claus-Dieter D.; ATANASIU, Isabela I (ed.). **European Competition Law Annual 2006: enforcement of Prohibition of Cartels**. Oxford: Hart Publishing, 2007.

HARRINGTON JR., Joseph E. Detecting cartels. In: BUCCIROSSI, Paolo (ed.). **Handbook of antitrust economics**. v. 1. Cambridge: MIT Press, 2008.

HEIJNEN, Pim; HAAN, Marco A.; SOETEVENT, Adriaan R. *Screening* for collusion: a spatial statistics approach. **Journal of Economic Geography**, [S. l.], v. 15, n. 2, p. 417-448, mar. 2015. DOI: <https://doi.org/10.1093/jeg/lbu012>. Disponível em: <https://tinyurl.com/24nwdoqu>. Acesso em: 9 jan. 2024.

HUBER, Martin; IMHOF, David. *Machine learning* with screens for detecting bid-rigging cartels. **International Journal of Industrial Organization**, [S. l.], v. 65, p. 277-301, 2019. DOI: <https://doi.org/10.1016/j.ijindorg.2019.04.002>. Disponível em: <https://tinyurl.com/254otawg>. Acesso em: 12 abr. 2024.

HUBER, Martin; IMHOF, David; ISHII, Rieko. Transnational *machine learning* with screens for flagging bid-rigging cartels. **Journal of the Royal Statistical Society: Series A: Statistics in Society**, [S. l.], v.



185, n. 3, p. 1074-1114, 2022. DOI: <https://doi.org/10.1111/rssa.12811>. Disponível em: <https://tinyurl.com/237pyqec>. Acesso em: 3 abr. 2024.

HÜSCHEL RATH, Kai. How are cartels detected? The increasing use of proactive methods to establish antitrust infringements. **Journal of European Competition Law & Practice**, [S. l.], v. 1, n. 6, p. 522-528, Dez. 2010. DOI: <https://doi.org/10.1093/jeclap/lpq047>. Disponível em: <https://tinyurl.com/269p776s>. Acesso em: 8 jan. 2024.

HÜSCHEL RATH, Kai; VEITH, Tobias. The impact of cartelization on pricing dynamics: evidence from the German cement industry. **ZEW-Centre for European Economic Research Discussion Paper**, [S. l.], n. 11-067, 2013. Disponível em: <https://tinyurl.com/27x2tqwo>. Acesso em: 4 abr. 2024.

HYYTINEN, Ari; STEEN, Frode; TOIVANEN, Otto. Cartels uncovered. **NHH Dept. of Economics Discussion Paper**, Bergen, n. 10/2010, 2010. Disponível em: <https://tinyurl.com/2da7zne3>. Acesso em: 6 abr. 2024.

IMHOF, David. Simple statistical screens to detect bid rigging. **Faculté des sciences économiques et sociales Working Paper**, Fribourg, n. 484, 2017. Disponível em: https://sonar.ch/documents/305523/files/WP_SES_484.pdf. Acesso em: 12 abr. 2024.

IMHOF, David; KARAGÖK, Yavuz; RUTZ, Samuel. *Screening* for bid rigging: does it work?. **Journal of Competition Law & Economics**, [S. l.], v. 14, n. 2, p. 235-261, jun. 2018. DOI: <https://doi.org/10.1093/joclec/nhy006>. Disponível em: <https://academic.oup.com/jcle/article-abstract/14/2/235/5058993>. Acesso em: 4 abr. 2024.

INTERNATIONAL COMPETITION NETWORK (ICN). **Anti-cartel enforcement manual**: Cartel Working Group: Subgroup 2: *Enforcement* Techniques. [S. l.]: International Competition Network, 2021. Disponível em: <https://tinyurl.com/26z2k8cm>. Acesso em: 8 jan. 2024.

INTERNATIONAL COMPETITION NETWORK; COMPETITION COMMISSION OF INDIA (CCI). **Cartel Enforcement and Competition**: ICN Special Project. [S. l.]: International Competition Network, 2018. Disponível em: <https://tinyurl.com/26n45aaw>. Acesso em: 8 jan. 2024.

ISHII, Rieko. Favor exchange in collusion: Empirical study of repeated procurement auctions in Japan. **International Journal of Industrial Organization**, [S. l.], v. 27, n. 2, p. 137-144, mar. 2009. DOI: <https://doi.org/10.1016/j.ijindorg.2008.05.006>. Disponível em: <https://tinyurl.com/252h4f94>. Acesso em: 9 jan. 2024.

JINDGAR, Jyoti. **Screens for Cartel Detection**. [S. l.: s. n.], 2019. Presentation from the *Competition Commission* of India. Disponível em: <https://tinyurl.com/29czlzy9>. Acesso em: 9 jan. 2024.

KAWAI, Kei; NAKABAYASHI, Jun. Detecting large-scale collusion in procurement auctions. **Journal of Political Economy**, [S. l.], v. 130, n. 5, 2014. Disponível em: <https://www.journals.uchicago.edu/doi/abs/10.1086/718913>. Acesso em: 20 jan. 2024.

KIEFER, Nicholas M. A note on *switching regressions* and logistic discrimination. **The Econometric Society**, [S. l.], p. 1065-1069, maio 1980. DOI: <https://doi.org/10.2307/1912950>. Disponível em: <https://www.jstor.org/stable/1912950>. Acesso em: 8 jan. 2024.

LEE, In K. Non-cooperative tacit collusion, complementary bidding and incumbency premium. **Review of Industrial Organization**, [S. l.], v. 15, n. 2, p. 115-134, set. 1999. Disponível em: <https://www.jstor.org/stable/41798877>. Acesso em: 2 abr. 2024.

LEE, In Kwon; HAHN, Kyungdong. Bid-rigging in auctions for Korean public-works contracts and potential damage. **Review of Industrial Organization**, [S. l.], v. 21, p. 73-88, ago. 2002. Disponível em: <https://tinyurl.com/26upxu3q>. Acesso em: 2 abr. 2024.

LEE, Lung-Fei; PORTER, Robert H. Switching regression models with imperfect sample separation information: with an application on cartel stability. **The Econometric Society**, [S. l.], v. 52, n. 2, p. 391-418, mar. 1984. DOI: <https://doi.org/10.2307/1911495>. Disponível em: <https://www.jstor.org/stable/1911495>. Acesso em: 2 abr. 2024.

LIMA, Ricardo Carvalho de Andrade; RESENDE, Guilherme Mendes. **Using the Moran's I to Detect Bid Rigging in Brazilian Procurement Auctions**: Working Paper nº 005/2019. Brasília, DF: Administrative Council for Economic Defense, 2019. Disponível em: <https://tinyurl.com/282uwqmw>. Acesso em: 2 abr. 2024.

LORENZ, Christian. Screening markets for cartel detection: *collusive markers* in the CFD cartel-audit. **European Journal of Law and Economics**, [S. l.], v. 26, n. 2, p. 213-232, 2008. DOI:10.1007/s10657-008-9054-x.

LUNDBERG, Johan. On cartel detection and Moran's I. **Letters in Spatial and Resource Sciences**, [S. l.], v. 10, p. 129-139, 2017. DOI: 10.1007/s12076-016-0176-4. Disponível em: <https://tinyurl.com/2d3z6f9o>. Acesso em: 8 jan. 2024.

MARSHALL, Robert C.; MARX, Leslie M.; MEURER, Michael J. The Economics of Auctions and Bidder Collusion. [S. l.: s. n.], 2012. Disponível em: <https://tinyurl.com/2cw69nkz>. Acesso em: 9 jan. 2024.

MENA-LABARTHE, Carlos. Mexican experience in screens for bid-rigging. **CPI Antitrust Chronicle**, [S. l.], v. 1, p. 1-8, mar. 2012. Disponível em: <https://tinyurl.com/29ljhd63>. Acesso em: 5 abr. 2024.

MORAN, P. A. P. The interpretation of statistical maps. **Journal of the Royal Statistical Society: Series B-Methodological**, [S. l.], v. 10, n. 2, p. 243-251, jul. 1948. Disponível em: <https://tinyurl.com/24d3a2ox>. Acesso em: 5 abr. 2024.

ORGANISATION FOR ECONOMIC CO-OPERATION AND DEVELOPMENT (OECD). **Country case: Korea's Bid Rigging Indicator Analysis System (BRIAS)**. Public Procurement Toolbox. Paris: Organisation for Economic Co-operation and Development (OCDE), 2016. Disponível em: <https://tinyurl.com/2379pcze>. Acesso em: 15 abr. 2024.

ORGANISATION FOR ECONOMIC CO-OPERATION AND DEVELOPMENT (OECD). **Ex officio cartel investigations and the use of screens to detect cartels**. Paris: Organisation for Economic Co-operation and Development (OCDE), 2013. (Series Roundtables on Competition Policy, nº 147). Disponível em: <https://tinyurl.com/29xm2fsc>. Acesso em: 15 abr. 2024.

ORGANISATION FOR ECONOMIC CO-OPERATION AND DEVELOPMENT (OECD). **Summary of the workshop on cartel screening in the digital era**. Paris: Organisation for Economic Co-operation and Development (OCDE), 2018. Disponível em: <https://tinyurl.com/28rajwl3>. Acesso em: 5 abr. 2024.

ORGANISATION FOR ECONOMIC CO-OPERATION AND DEVELOPMENT (OECD). **Combate a cartéis em licitações no Brasil**: Uma revisão das Compras Públicas Federais. Paris: Organisation for Economic Co-operation and Development (OCDE), 2021. Disponível em: <https://tinyurl.com/2dmyjuob>. Acesso



em: 15 abr. 2024.

PESENDORFER, Martin. A study of collusion in first-price auctions. **The Review of Economic Studies**, [S. l.], v. 67, n. 3, p. 381-411, 2000. DOI: <https://doi.org/10.1111/1467-937X.00136>. Disponível em: <https://tinyurl.com/2ar76cl5>. Acesso em: 8 jan. 2024.

PETIT, Lilian. The economic detection instrument of the Netherlands Competition Authority: the *competition index*. **NMa Working Paper**, Netherlands, n. 6, jan. 2012. Disponível em: <https://tinyurl.com/2xqvn7cl>. Acesso em: 1 abr. 2024.

PIMENTA, Guilherme. Projeto Cérebro: Cade usa inteligência artificial no combate a cartéis. **Jota**, Brasília, 29 out. 2019. Disponível em: <https://tinyurl.com/2xqvn7cl>. Acesso em: 16 abr. 2024.

PORTER, Robert H. A study of cartel stability: the Joint Executive Committee, 1880-1886. **The Bell Journal of Economics**, [S. l.], v. 14, n. 2, p. 301-314, 1983. DOI: <https://doi.org/10.2307/3003634>. Disponível em: <https://www.jstor.org/stable/3003634>. Acesso em: 8 jan. 2024.

PORTER, Robert H. Detecting collusion. **Review of Industrial Organization**, [S. l.], v. 26, n. 2, p. 147-167, 2005. Disponível em: <https://www.jstor.org/stable/41799228>. Acesso em: 10 abr. 2024.

PORTER, Robert H. **Detection of Collusion**. Paris: Organisation for Economic Co-operation and Development (OCDE), 2018. Presentation at the Workshop on cartel *screening* in the digital era. Disponível em: <https://tinyurl.com/22jy8ldo>. Acesso em: 10 abr. 2024.

PORTER, Robert H.; ZONA, J. Douglas. Detection of bid rigging in procurement auctions. **Journal of Political Economy**, [S. l.], v. 101, n. 3, p. 518-538, jun. 1993. DOI: <https://doi.org/10.1086/261885>. Disponível em: <https://tinyurl.com/2956hx5e>. Acesso em: 18 jan. 2024.

PORTER, Robert H.; ZONA, J. Douglas. Ohio school milk markets: an analysis of bidding. **The RAND Journal of Economics**, [S. l.], v. 30, n. 2, p. 263-288, 1999. DOI: <https://doi.org/10.2307/2556080>. Disponível em: <https://www.jstor.org/stable/2556080>. Acesso em: 3 abr. 2024.

PRADO FILHO, José Inácio F. A.; GENOVA, Maria Eduarda de Jesus. Uso de IA na persecução administrativa: o "Projeto Cérebro" do CADE. **Migalhas**, [S. l.], 15 set. 2023. Disponível em: <https://tinyurl.com/23f6lp8a>. Acesso em: 16 abr. 2024.

RAGAZZO, Carlos Emmanuel Joppert; SILVA, R. M. D. **Aspectos econômicos e jurídicos sobre cartéis na revenda de combustíveis**: uma agenda para investigações: Documento de Trabalho SEAE nº 40. Brasília: Ministério da Fazenda, 2006.

REBOUÇAS, Rômulo Roseo *et al.* Detecção de figurantes em pregões eletrônicos do governo federal brasileiro. **Informação e Tecnologia**, João Pessoa, v. 2, n. 2, p. 5-21. 2015. Disponível em: <https://periodicos.ufpb.br/index.php/itec/article/view/25089/17496>. Acesso em: 2 abr. 2024.

SALGADO, Lucia Helena. Avaliando a eficácia da política brasileira de combate aos cartéis. **Revista de Defesa da Concorrência**, Brasília, v. 10, n. 1, p. 7-29, 2022. DOI: <https://doi.org/10.52896/rdc.v10i1.993>. Disponível em: <https://tinyurl.com/2bk757v7>. Acesso em: 5 abr. 2024.

SAMÀ, Danilo. Cartel detection and collusion *screening*: an empirical analysis of the London Metal Exchange. **Law & Economics LAB**, Rome, p. 1-18, 2014. Disponível em: <https://tinyurl.com/26mulyzm>. Acesso em: 6 mar. 2024.

SILVEIRA, Douglas *et al.* Cartel Screening in the Brazilian Retail Fuel Market. *Economia*. [S. l.], v. 22, n 1, p. 53-70. 2021. DOI: <https://doi.org/10.1016/j.econ.2021.01.001>. Disponível em: <https://tinyurl.com/27tlx39j>. Acesso em: 9 jan. 2024.

SILVEIRA, Douglas *et al.* Won't Get Fooled Again: A supervised *machine learning* approach for screening gasoline cartels. *Energy Economics*, [S. l.], v. 105, p. 105, jan. 2022. DOI: <https://doi.org/10.1016/j.eneco.2021.105711>. Disponível em: <https://tinyurl.com/2dxxzmel>. Acesso em: 10 mar. 2024.

SOUZA, Frederico Pinto de; LOUZADA, Fabiano da Rocha. Detectando conluio em compras governamentais: uma abordagem utilizando Red Flags e a Teoria Dempster-Shafer. **Revista da CGU**, Brasília, v. 12, n. 21, p. 80-99, jan./jun. 2020. Disponível em: <https://repositorio.cgu.gov.br/handle/1/64813>. Acesso em: 6 abr. 2024.

VASCONCELOS, Silvinha Pinto; VASCONCELOS, Claudio Roberto Fóffano. Investigações e obtenção de provas de cartel: por que e como observar paralelismo de conduta. **Ensaio da Fundação de Economia e Estatística**, Porto Alegre, v. 26, n. 2, 2005. Disponível em: <https://tinyurl.com/2xlydhoc>. Acesso em: 10 mar. 2024.

VASCONCELOS, Silvinha Pinto; VASCONCELOS, Claudio Roberto Fóffano. Ferramentas de detecção dos acordos em preços no mercado de gasolina a varejo. In: ENCONTRO NACIONAL DE ECONOMIA, 37., 2009, Foz do Iguaçu. **Anais [...]**. Niterói: Associação Nacional dos Centros de Pós-Graduação em Economia, 2009. Disponível em: <https://tinyurl.com/23w23dHz>. Acesso em: 12 abr. 2024.

WACHS, Johannes; KERTÉSZ, János. A network approach to cartel detection in public auction markets. **Scientific reports**, [S. l.], v. 9, n. 1, 2019. Disponível em: <https://tinyurl.com/2dno3afw>. Acesso em: 12 abr. 2024.

WALLIMANN, Hannes; STICHER, Silvio. On suspicious tracks: machine-learning based approaches to detect cartels in railway-infrastructure procurement. **Arxiv**, [S. l.], 2023. Disponível em: <https://tinyurl.com/2xmn7l4>. Acesso em: 12 abr. 2024.

