

UNIVERSIDADE FEDERAL DE JUIZ DE FORA
FACULDADE DE ECONOMIA

Leonan Luiz Ferreira

**ALGORITMOS, INTELIGÊNCIA ARTIFICIAL E IMPACTOS NO NÍVEL DE
COMPETIÇÃO: UMA INTRODUÇÃO**

JUIZ DE FORA - MG
2021

Leonan Luiz Ferreira

**ALGORITMOS, INTELIGÊNCIA ARTIFICIAL E IMPACTOS NO NÍVEL DE
COMPETIÇÃO: UMA INTRODUÇÃO**

Monografia apresentada à Faculdade de Ciências Econômicas da Universidade Federal de Juiz de Fora, como requisito à obtenção do título de bacharel em Ciências Econômicas.

Orientadora: Silvinha Vasconcelos

JUIZ DE FORA - MG
2021

Ficha catalográfica elaborada através do programa de geração automática da Biblioteca Universitária da UFJF, com os dados fornecidos pelo(a) autor(a)

Ferreira, Leonan.

Algoritmos, inteligência artificial e impactos no nível de competição : uma introdução / Leonan Ferreira. -- 2022.
38 p. : il.

Orientadora: Silvinha Vasconcelos
Trabalho de Conclusão de Curso (graduação) - Universidade Federal de Juiz de Fora, Faculdade de Economia, 2022.

1. Algoritmos. 2. conluio tácito. 3. inteligência artificial . 4. antitruste. I. Vasconcelos , Silvinha , orient. II. Título.



UNIVERSIDADE FEDERAL DE JUIZ DE FORA
REITORIA - FACECON - Depto. de Economia

Faculdade de Economia /UFJF

Ata de Aprovação de Monografia II (Mono B)

Ao Presidente da Comissão organizadora de Monografias

Na data de 18/02/2011 a Banca examinadora composta pelos professores

1. Silvinha Vasconcelos (Orientadora)
2. Rafael Morais de Sousa

reuniu-se para avaliar a monografia do acadêmico Leonan Luiz Ferreira, intitulada “Algoritmos, Inteligência Artificial e Impactos no nível de competição: Uma Introdução.”

Após primeira avaliação, resolveu a Banca sugerir alterações ao texto apresentado, conforme anotado pela orientadora.

Na data de 18/02/2022, voltou a Banca a reunir-se, avaliando novamente a monografia apresentada, após introduzidas as alterações propostas, resolvendo APROVAR a referida monografia.

Juiz de Fora, 18/02/2022.

Prof.^(a) Silvinha Vasconcelos

Prof.^(a) Rafael Morais de Sousa

Recebido em / / Presidente da C.C.M.



Documento assinado eletronicamente por **Silvinha Pinto Vasconcelos, Professor(a)**, em 18/02/2022, às 15:06, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Rafael Morais de Souza, Professor(a)**, em 18/02/2022, às 16:14, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no Portal do SEI-Ufjf (www2.ufjf.br/SEI) através do ícone Conferência de Documentos, informando o código verificador **0685621** e o código CRC **0BB065D9**.

RESUMO

A aplicação de algoritmos de precificação tem aumentado nos períodos recentes e com isso surgiram preocupações relacionadas ao seu uso favorecer resultados anticompetitivos. Este trabalho introduz os aspectos da estrutura de mercado capazes de afetar a coordenação entre agentes, discute o funcionamento dos algoritmos de aprendizado por reforço Q-learning e Deep Q-network e, por fim, analisa o papel das autoridades antitruste no combate a práticas colusivas. As evidências indicam que o conluio algorítmico é possível e as autoridades antitruste devem optar por uma abordagem pontual, investigando o uso de algoritmos apenas em casos suspeitos.

Palavras-chave: Algoritmos; conluio tácito; inteligência artificial; lei antitruste.

ABSTRACT

The application of pricing algorithms has increased in recent periods. Consequently, concerns related to their use favoring anti-competitive results have arisen. This work introduces some aspects of the market structure capable of affecting the coordination between agents, discusses the functioning of reinforcement learning algorithms Q-learning and Deep Q-network, and, finally, analyzes the role of antitrust authorities in the fight against collusive practices. Evidence indicates that algorithmic collusion is possible, and the antitrust authorities should opt for a one-off approach, investigating the use of algorithms only in suspected cases.

Keywords: Algorithms; tacit collusion; artificial intelligence; competition law.

LISTA DE ILUSTRAÇÕES

Figura 1 - Sistema de interações do algoritmo Q-learning.....	20
Figura 2 - Arquitetura da Q-network.....	25

LISTA DE ABREVIATURAS E SIGLAS

UFJF – Universidade Federal de Juiz de Fora

IA – Inteligência Artificial

AR – Aprendizado por Reforço

AM – Aprendizado de Máquina

CADE – Conselho Administrativo de Defesa Econômica

OI – Organização Industrial

RNAs – Redes Neurais Artificiais

DQN – Deep Q-Network

DNN – Deep Neuronal Network

PDM – Processo de Decisão de Markov

SUMÁRIO

1. INTRODUÇÃO	6
2. JUSTIFICATIVA	8
3. ESTRUTURA DE MERCADO	9
3.1 Número de firmas.....	9
3.2 Barreiras a Entrada.....	10
3.3 Comunicação.....	11
3.4 Interação	11
3.5 Transparência.....	12
3.6 Diferenciação de produtos	13
3.7 Assimetria de Custos.....	13
4. REVISÃO DA LITERATURA	15
4.1 Referencial teórico	15
4.2 Referencial empírico	17
5. ALGORITMOS	19
5.1 Q-learning	19
5.1.1 Modelo de Bertrand.....	23
5.1.2 Resultados.....	24
5.2 Deep Q-Network	24
6. POLÍTICA ANTITRUSTE	26
6.1 Projeto Cérebro	27
7. CONSIDERAÇÕES FINAIS	28
8. REFERÊNCIAS	30

1. INTRODUÇÃO

A precificação através de algoritmos tem crescido nos últimos anos, estando acessível a grandes empresas e, cada vez mais frequentemente, também as médias e pequenas. A ascensão deste tipo de tecnologia tem incentivado uma intensa discussão ao redor do mundo sobre a possibilidade de a mesma causar impactos negativos no nível de competição. A principal preocupação gira em torno do uso de tais algoritmos para práticas colusivas, podendo ser implícitas ou explícitas. Isso é possível graças a capacidade de análise de dados e aprendizado dos softwares, que vem se tornando mais sofisticados nos períodos recentes. O comportamento de algoritmos é mais eficaz quando comparado a agentes humanos e pode se mostrar apto a efetivar e sustentar condutas nocivas ao consumidor.

Estes algoritmos implementam ferramentas da matemática, da engenharia, da ciência da computação e frequentemente tem sua estrutura baseada na Inteligência Artificial (IA) e no Aprendizado de Máquina (AM). Com esta ampla gama de áreas essenciais para estudar o funcionamento dos algoritmos fica clara a necessidade de uma abordagem interdisciplinar para tratar do assunto.

Quando a preocupação central é em relação a possibilidade de formação de conluio, a análise econômica assume um papel importante. Pensando nisto, a produção de artigos com o objetivo de estudar o impacto da implementação de algoritmos na política de preços tem aumentado. Alguns trabalhos que merecem destaque são os desenvolvidos por Waltman e Kaymak (2008), Tampuu *et al.* (2017), Zhou (2018), Klein (2019), Calvano *et al.* (2019; 2020), Assad *et al.* (2020), Meylahn e Den Boer (2020), Hettich (2021) e Wieting e Sapi (2021).

Apesar da crescente quantidade de trabalhos sendo produzidos, os estudos que vão a fundo na inteligência artificial são baseados em simulações e não análises empíricas. Isso ocorre por dois motivos. O primeiro e mais obvio é que a implementação desses algoritmos bem como a informação sobre os mesmos é mantida em completo sigilo pelas empresas, dificultando amplamente os estudos. O segundo está relacionado a forma que os algoritmos são construídos. É particularmente difícil analisar seu processo de tomada de decisão, tanto porque eles não necessitam de treinamento prévio com uma base de dados quanto por serem capazes de descobrir de forma autônoma o resultado que otimiza a política de preços de um determinado agente.

Esta otimização, em suma, significa que os algoritmos buscam maximizar o retorno total. E é a partir de agentes com este objetivo que é pensado o cenário mais simplificado possível, onde a interpretação econômica pode ser bastante clara. Um duopólio com ambas as

empresas fazendo uso de algoritmos e interagindo estrategicamente por um número indefinido de períodos. A forma mais adequada de simular este cenário, de acordo com Silver et al (2016), é lançando mão de ferramentas mais prováveis de serem utilizadas na prática, que é o caso dos algoritmos baseados em aprendizado por reforço. Este tipo de algoritmo aprende por tentativa e erro enquanto interage com o ambiente de mercado e é o mais indicado para estudar a precificação por algoritmos.

Como já citado anteriormente, observar empiricamente a possibilidade de conluio tácito no uso de algoritmos é uma tarefa complicada quando não existe no mercado alvo informação disponível em abundância (Assad *et al.* 2020), portanto, diversas abordagens são realizadas através de simulações com caráter experimental (Hettich. 2021; Calvano *et al.* 2020; Meylahn e Den Boer. 2020).

Neste trabalho discutiu-se mais a fundo alguns dos métodos que implementam a IA e o aprendizado por reforço para simular a interação entre algoritmos. Utiliza-se como base o Q-Learning, que foi proposto originalmente por Watkins (1989). Posteriormente foi provado por Watkins e Dayan (1992) que este algoritmo converge para a política ótima com probabilidade igual a 1, contanto que todas as ações sejam repetidamente testadas em todos os estados. O objetivo deste tipo de simulação é realizar interações entre agentes e o ambiente de mercado, e então verificar se o resultado obtido é consistente com o comportamento colusivo. Este método foi aplicado em uma simulação no trabalho de Calvano *et al.* (2020 e as implicações econômicas amplamente discutidas. Este estudo serve de base para este trabalho enquanto observamos outros algoritmos mais sofisticados que foram aplicados com propósitos semelhantes.

Outro ponto de extrema importância discutido é se a legislação antitruste brasileira, que faz parte da jurisdição do Conselho Administrativo de Defesa da Concorrência (CADE), está apta a lidar com os desafios criados pela implementação de inovações no mercado como a utilização dos algoritmos de precificação. Os livros *Virtual Competition* (2016) e *Research Handbook on the Law of Artificial Intelligence* (2018) discutem de forma abrangente a situação da política antitruste frente a inteligência artificial e servirem de base para nossas discussões. Alguns outros trabalhos que servem de referência são os desenvolvidos por Rab (2019), Calvano *et al.* (2019), Zarzur (2020), Ezrachi e Stucke (2017; 2020).

Ao transitar dos algoritmos para a efetividade da política antitruste em enfrentar este tipo de problema surge o desafio, de acordo com Stucke e Ezrachi (2018), de identificar se o nível de preços em um mercado é de fato o resultado de um conluio tácito. E, claro, para verificar tal resultado é essencial conhecer e monitorar o comportamento dos algoritmos. Toda esta abordagem exige recursos e as opções serão discutidas mais à frente.

O presente estudo foi estruturado em sete capítulos, incluindo a atual. No capítulo 2 discutiu-se os motivos pelos quais a compreensão do uso de algoritmos na formação de preços é relevante, no capítulo 3 foram abordados alguns aspectos importantes em relação a estrutura de mercado. No capítulo 4 foi feita uma revisão da literatura teórico e empírica, no capítulo 5 foram abordados alguns métodos utilizados para simular os algoritmos de precificação, no capítulo 6 foram apresentados os pontos que servem como base para a política antitruste brasileira e, por último, na seção 7, foi feita a conclusão.

2. JUSTIFICATIVA

A utilização de algoritmos para desenvolver a estratégia de preços de vendedores em grandes plataformas de comércio eletrônico tem se mostrado uma prática cada vez mais comum. Somado a isto, a construção de algoritmos mais sofisticados é uma tendência. Neste cenário onde a política de preços fica, de certa forma, relegada a algoritmos autônomos, surgiram algumas preocupações. Entre elas, a possibilidade de os mercados adotantes produzirem resultados anticompetitivos, ampliando significativamente a capacidade de discriminar preços e, ainda, podendo criar e sustentar práticas colusivas sem nenhum tipo de intervenção humana.

A quase totalidade dos trabalhos tratando destes temas, através de uma perspectiva econômica, estão escritos em idiomas que não o português. Desta forma, este trabalho busca ser uma porta de entrada para que mais estudos sejam realizados neste idioma e futuramente possam auxiliar o sistema de defesa da concorrência brasileiro a estar mais capacitado para lidar com a implementação de algoritmos.

Algoritmos relativamente simples utilizados para a formação dos preços aprendem sistematicamente a utilizar estratégias que podem resultar em conluio e isto gera preocupações relacionadas a possibilidade das leis antitruste no país, que são encargo do Conselho Administrativo de Defesa Econômica (CADE), não estarem capacitadas para lidar com tais desafios, portanto, este trabalho visa realizar um apanhado em torno do material teórico e empírico para fortalecer a discussão ao redor dos algoritmos de precificação no Brasil.

3. ESTRUTURA DE MERCADO

Para analisar a possibilidade da formação de conluio tácito no contexto dos algoritmos de precificação é essencial compreender as características do mercado. Isso é necessário pois a capacidade das firmas coordenarem o comportamento depende fortemente de como o mercado está estruturado. Para entender melhor como a possibilidade de conluio é afetada por tais características, neste capítulo serão discutidos sete fatores relevantes. O número de firmas, barreiras à entrada, comunicação, interação, transparência, diferenciação de produtos e assimetria de custos.

3.1 Número de firmas

O primeiro ponto que assume importância crucial é o número de competidores envolvidos (number effects). Existe uma correlação negativa entre estes e a possibilidade de conluio tácito. Resultados que evidenciam esta tendência foram demonstrados nos trabalhos de Potters e Suetens (2014) e Engel (2015). Para o caso do duopólio, a coordenação entre firmas é muito mais simples de ocorrer se comparada a um mercado com três firmas ou mais.

Em um cenário de conluio, as firmas participantes do mercado obtêm lucros semelhantes, assim, quanto mais empresas participantes, menor será a fatia de cada uma delas. Como resultado, ocorre um aumento no incentivo para desviar do preço colusivo e obter uma maior fatia de mercado. Ao mesmo tempo, aumenta o custo para a manutenção do conluio no longo prazo, exatamente por longos desvios do preço colusivo se tornarem lucrativos.

Por outro lado, com a interação entre algoritmos, é importante considerar as características dos softwares que competem no mercado, bem como suas semelhanças e diferenças. Este ponto é importante uma vez que diferenças entre as estruturas dos algoritmos podem resultar em diferentes velocidades de aprendizado e também, diferentes processos de tomada de decisão. Como foi observado por Hettich (2021), a implementação de algoritmos heterogêneos entre si inibe fortemente a coordenação. Conseqüentemente, ambientes onde são empregados diferentes tipos de algoritmos podem ser mais saudáveis, em vista que este cenário impossibilita a compreensão e a articulação entre algoritmos.

Tem se tornado um consenso que a entrada de algoritmos em um determinado mercado pode facilitar significativamente práticas colusivas mesmo quando existe um maior número de firmas participantes, sem que seja necessário nenhum tipo de comunicação entre os agentes. Esta talvez seja a mais escancarada mudança de paradigma na compreensão dos mercados que

a inteligência artificial causa, sendo possível o conluio até mesmo em mercados não oligopolizados.

3.2 Barreiras a Entrada

É evidente que em um mercado sem barreiras de entrada a formação e manutenção do conluio é muito difícil. Isso se dá em decorrência da facilidade de aumentar o número de participantes no mercado, assim, qualquer manutenção dos preços acima do nível competitivo incentivaria a entrada de novas firmas, desestabilizando o conluio através da corrosão de sua lucratividade (Ivaldi et al, 2001). Em decorrência disto, se uma firma reduz o preço, a retaliação por este comportamento é cada vez menor. Portanto, é bem estabelecido na teoria econômica que quanto menores forem as barreiras à entrada em um determinado mercado, mais difícil é formar e sustentar o conluio.

Quando consideramos um mercado onde algoritmos são utilizados, é incerto o impacto dos mesmos nas barreiras à entrada. Por um lado, a agilidade dos algoritmos em encontrar respostas ótimas a situações específicas, como por exemplo a entrada de um novo competidor no mercado, pode facilitar respostas agressivas por parte de empresas já estabelecidas, porém, como no caso das plataformas de vendas online, não se sabe ao certo se a origem destas barreiras reside na utilização dos algoritmos ou nas barreiras naturais do mercado (e.g. oligopólios, economias de escala e escopo). Por outro lado, a transparência nos mercados cada vez maior, juntamente com o mais fácil desenvolvimento de algoritmos podem reduzir dramaticamente o custo de entrada. Este último ponto é novamente ambíguo.

Embora o acesso à informação esteja sendo facilitado pela transparência, ainda existem diversos dados chave que permanecem de conhecimento privado. Um caso que ilustra isso é o da Amazon, que foi explicitado em um relatório da Comissão Europeia em 10 de novembro de 2020. Neste texto a Amazon é notificada sobre a investigação que tem como alvo seu suposto comportamento nocivo dentro do ramo do comércio eletrônico. O ponto relevante aqui é que ao mesmo tempo que a Amazon fornece uma plataforma digital para diversos vendedores e tem acesso a todos seus dados não-públicos relacionados a vendas, ela é também um dos vendedores. Este é um caso de assimetria informacional passível de prejudicar a competição, aumentando barreiras à entrada e dificultando a permanência de outros vendedores no mercado.

3.3 Comunicação

De acordo com a literatura tradicional (Crawford e Sobel, 1982; Fonseca e Normann, 2012; Engel, 2015; Schwalbe, 2018), a comunicação tem um papel importante quando o mercado é composto por mais de duas firmas, isso acontece pois, com o aumento do número de empresas participantes, o ambiente se torna muito complexo e acordos são necessários para criar e sustentar preços colusivos.

A comunicação é frequentemente apontada como o fator que diferencia o conluio tácito do conluio explícito. Seu papel é tão importante que existem alguns trabalhos sugerindo que a política antitruste deveria mudar o seu foco da análise nos padrões de preços para uma abordagem centrada em verificar os mais efetivos tipos de comunicação capazes de fortalecer o conluio (e.g. Kühn (2001)). De acordo com Kühn (2001) existem dois tipos distintos de comunicação. O primeiro está relacionado a planos futuros para o mercado, como acordos para definir preços e a quantidade produzida, discussões sobre criar novos produtos e possíveis expansões. Este tipo de informação é chamado de “soft information” pois não são imediatamente verificáveis durante o processo de tomada de decisão. O segundo tipo diz respeito a situação atual das firmas, bem como contextos passados e costuma ser nomeado por “hard information”. Ele recebe este nome pois a veracidade deste tipo de informação pode ser facilmente verificada. Alguns bons exemplos deste tipo são as decisões tomadas em períodos passados e informações sobre os consumidores.

No âmbito jurídico, o primeiro tipo carrega a essência do comportamento colusivo. Um dos grandes desafios impostos pelo uso de algoritmos é que o mesmo muda drasticamente a necessidade de comunicação, fazendo com que a coordenação seja possível, mesmo em mercados complexos, sem a necessidade de comunicação previa (Calvano *et al.* 2020). Hettich (2021) demonstra através de simulações que, com a presença de algoritmos, até mesmo situações onde existem de 3 a 7 participantes no mercado é possível observar comportamentos colusivos sem nenhum tipo de comunicação. É neste sentido que surgem as preocupações em relação à política antitruste, em vista que a legislação pode considerar casos onde de fato esteja ocorrendo conluio tácito como falsos-negativos (Ezrachi e Stucke, 2020).

3.4 Interação

Sabendo que os principais fatores capazes de sustentar o conluio no longo prazo são punições por desvio, é evidente que há a necessidade de os agentes interagirem novamente após

o primeiro contato. Sem repetidas interações, apenas o resultado imediato é relevante e toda discussão de conluio tácito perde o sentido.

A interação frequente entre firmas é crucial para sustentar o conluio (Scherer, 1980; Ivaldi et al., 2003). Quanto mais frequente, mais rápida é a reação das empresas para efetivamente punir desvios do preço colusivo. Em contrapartida, interações que ocorrem com pouca frequência fazem com que as punições ocorram apenas em um futuro distante, reduzindo seu custo no curto prazo.

É possível aplicar esta discussão também para os ajustes de preços. Quanto mais frequente for o ajuste, mais rápido virá a retaliação por desvios. Este ponto é particularmente pertinente para a precificação por algoritmos. Um grande exemplo é o caso da Amazon, onde o trabalho de Chen et al. (2016) identificou vendedores que alteravam os preços centenas de vezes durante o dia. Ao contrário do que normalmente se espera em situações comuns, os vendedores podem fazer estas alterações sem grandes custos, correndo apenas o risco de aborrecer os consumidores com o intenso ritmo das modificações, bem como dificultar seu processo de pesquisa pelos melhores preços.

3.5 Transparência

O frequente ajuste de preços supracitado só é de fato relevante se houver transparência no mercado. Em suma, isso significa que as firmas precisam ter acesso aos novos preços através dos dados indiretos disponíveis no mercado para que o sistema de punição a desvios funcione (Stigler, 1964). Este fator é crucial para que o conluio se sustente.

O mecanismo em funcionamento aqui pode ser ilustrado pela contribuição de Tirole (1988) e que foi discutido no relatório produzido pela Comissão Europeia escrito por Ivaldi et al. (2003). Em um primeiro momento as firmas observam seus próprios preços e vendas, mas não o das outras firmas inseridas no mercado. Em um segundo momento, quando uma determinada firma não consegue vender seus produtos, a justificativa para tal pode ser um choque negativo na demanda ou porque outros participantes do mercado reduziram seus preços. Em ambos os casos é criado um obstáculo para a sustentação do conluio. Para superar este obstáculo as firmas podem via guerra de preços punir a firma que desviar do preço colusivo.

Outro ponto que vale a pena ser discutido é que a grande disponibilidade de dados em um mercado gera um incentivo significativo para que as firmas que ainda não adotaram nenhum tipo de algoritmo, o façam para que então desfrutem de vantagens competitivas. Sempre que firmas realizarem investimentos em tecnologia para analisar e fazer o uso mais eficiente

possível dos dados, existirão incentivos para que todas as firmas adotem comportamento semelhante (OCDE, 2017).

3.6 Diferenciação de produtos

A diferenciação de produtos pode ser vertical, horizontal ou assumir ambas as formas em certa medida. Primeiro, a diferenciação vertical está relacionada ao caso onde uma firma desenvolve um produto melhor que as demais. Neste caso, esta empresa tem menos a perder ao desviar do preço colusivo ao mesmo tempo que tem menos a temer frente a futuras retaliações. Já a diferenciação horizontal é mais ambígua, aqui o aprimoramento de uma determinada característica pode aumentar a utilidade do produto para alguns consumidores enquanto reduz para outros (Belleflamme e Peitz, 2010). Este caso é compatível com a fidelidade, onde o consumidor opta por continuar a adquirir um determinado produto mesmo se os concorrentes apresentarem redução de preço. Quando os preços de dois bens são iguais e o consumidor opta claramente por um deles é outra situação que se enquadra na diferenciação horizontal.

De forma geral, as autoridades consideram a diferenciação de produtos como um obstáculo a formação de conluio. Isso porque diferentes características nos produtos podem intensificar o impacto da assimetria informacional no mercado (Ivaldi et al, 2001). Uma discussão mais aprofundada sobre o papel da diferenciação de produtos na estabilidade do conluio pode ser encontrada no trabalho de Stigler (1964).

3.7 Assimetria de Custos

Um fator que pode levar a assimetria de custos é a inovação. De acordo com um estudo produzido pela OCDE (2017), mercados com características altamente inovadoras reduzem tanto o valor presente dos acordos colusivos quanto a capacidade das firmas menos inovadoras de retaliar desvios de comportamento. Desta forma, as firmas capazes de desenvolverem processos de produção mais eficientes e diferenciar seus produtos irão reduzir seus custos e gerar assimetria no mercado.

A presença de assimetria de custos em um mercado tem diversas implicações imediatas. A primeira está relacionada a política de preços. Quando o custo produtivo de uma firma é menor que o das demais participantes do mercado, é evidente que o nível desejável para os seus preços esteja abaixo dos passíveis de serem praticados pelos concorrentes. Esta diferença entre o nível de preços ótimo cria um grande obstáculo que dificulta a efetivação de acordos e

consequentemente impossibilita a coordenação. Uma possível solução para este impasse comumente discutida é o repasse de fatias de mercado para as empresas que incorrem em menores custos. Embora teoricamente solucione o problema, é altamente improvável que tal tipo de coordenação ocorra sem nenhum tipo de comunicação explícita e mesmo que ocorra, a sustentabilidade do acordo ainda é uma incógnita. (Ivaldi et al, 2001).

O estudo de Mason, Phillips e Nowell (1992) demonstra experimentalmente que em um duopólio com firmas de funções custo semelhantes há maior facilidade para cooperação mútua. Quando há assimetria de custos o conluio se torna mais difícil de se concretizar porque a empresa mais eficiente está em uma situação onde tem muitos incentivos para desviar do nível de preços colusivo, tudo isso enquanto incorre a punições mais brandas por este tipo de comportamento.

Quadro 1 - Impacto dos aspectos da estrutura de mercado na formação de conluio

Fator relevante	Tipo de impacto na possibilidade de conluio
Número de firmas	+/-
Barreiras de entrada	+/-
Comunicação	+
Interação	+
Transparência	+
Diferenciação de produtos	-
Assimetria de custos	-

Fonte: Elaboração do autor / OCDE (2017)

O quadro acima sintetiza os elementos da estrutura de mercado e os seus correspondentes impactos na formação de conluio. É importante pontuar que tanto quanto a estrutura de mercado afeta o impacto da implementação dos algoritmos, a relação inversa ocorre simultaneamente, portanto, a natureza do impacto pode variar de mercado para mercado.

Por fim, compreender profundamente o funcionamento de um mercado é igualmente importante a necessidade de entender o funcionamento dos algoritmos de precificação.

4. REVISÃO DA LITERATURA

Dado que o presente trabalho busca compreender o impacto da implementação de algoritmos nos mercados, nesta seção serão apresentados os principais artigos que serviram de referência para alcançar tal objetivo. Os estudos realizados por Calvano et al. (2020) e por Hettich (2021) servirão como base, em vista que simulam ambientes onde algoritmos são implementados e analisam suas implicações. O primeiro utiliza o algoritmo de aprendizado por reforço, Q-learning, para simular a interação entre agentes econômicos e o ambiente de mercado. Já o segundo, propõe uma ampliação do método, usando as bases do trabalho de Calvano, aplicando a Deep Q-network e por fim, comparando os métodos. Por outro lado, as preocupações relacionadas a política antitruste levantadas por Calvano *et al.* (2019) e Ezrachi e Stucke (2020) são úteis para apoiar as discussões em relação as implicações práticas do uso de algoritmos e serão apresentadas nesta seção.

4.1 Referencial teórico

O método Q-learning foi inicialmente proposto por Watkins (1989), onde é apresentada uma abordagem computacional para modelar o aprendizado com base na experiência passada, desta forma, o propósito do agente é otimizar seu comportamento visando um payoff maior no longo prazo. Esta ênfase em períodos mais longos ocorre pois no curto e médio prazo o algoritmo enfrenta um trade off entre explorar novas ações e fazer uso das já armazenadas na memória, afinal, uma ação que gerou payoff elevado não garante que esta seja a melhor ação dentre todas as possíveis (Barto & Sutton). Este tipo de algoritmo lida com processos de decisão de Markov finitos (sigla em inglês, MDP), que de acordo com Barto & Sutton (2018), é uma forma matematicamente idealizada do aprendizado por reforço que permite a formulação de algumas declarações teóricas precisas.

Waltman & Kaymak (2008) utilizaram o Q-learning para modelar o comportamento de firmas em um jogo repetido, com base no oligopólio de Cournot. Neste estudo os autores demonstram através de simulações computacionais que firmas geram conluio em um duopólio de Cournot, embora não atinjam o maior payoff possível. Este resultado é bastante comum. Outro ponto relevante foi a observação de um grau significativo de conluio para um número de firmas maior que dois. Este resultado vai contra experimentos que apontam para um comportamento próximo do equilíbrio de Nash.

Ezrachi e Stucke (2020) indicam que a constante expansão do comércio online, concomitante a ascensão da ciência de dados abre um leque de possibilidades para a utilização de algoritmos de precificação e conseqüentemente facilitam a formação de conluíus tácitos. As leis antitruste que já apresentam limitações para enfrentar os carteis, tendem a enfrentar um obstáculo ainda maior ao enfrentar os algoritmos de precificação.

Em um artigo publicado em 2019, Calvano *et al.*, apontam algumas perguntas cruciais para aproximar o debate em torno dos algoritmos de precificação de questões econômicas. Dentre elas, destacamos “Algoritmos podem formar conluio?”, “O conluio entre algoritmos é mais comum do que entre humanos?” e “Existem diferenças entre eles?”. Com base nas respostas a estas perguntas os autores trazem três possíveis cenários. Para o caso otimista, onde todas respostas são negativas, não existe a necessidade de os órgãos reguladores modificarem suas práticas. Já para o caso de respostas afirmativas, surgem duas possibilidades, primeiro é possível realizar intervenções *ex ante*, ou seja, promover testes com os algoritmos antes dos mesmos entrarem no mercado. A outra possibilidade diz respeito a intervenções *ex post*, considerando que alterações na legislação antitruste sejam implementadas.

Katz e Sallet (2018) argumentam que os órgãos reguladores devem utilizar uma abordagem multimercado para tratar de empresas que utilizam plataformas multilaterais em vista que a alta gama de produtos negociados através da plataforma inviabiliza a análise simplista com a hipótese de mercado único.

Os estudos de Calvano *et al.* (2020) abordaram de maneira experimental a relação entre a inteligência artificial, a formação de preços através de algoritmos e o conluio. Foi realizada uma simulação do comportamento de algoritmos criados através da inteligência artificial tendo como base um modelo oligopolista com repetida competição de preços. O primeiro ponto abordado diz respeito ao funcionamento do Q-learning, que é um algoritmo de ‘reinforcement learning’ e funciona através da adaptação das decisões com base na experiência passada. Esta forma de comportamento pode ser enquadrada na teoria dos jogos e modelada através dos jogos repetidos. O resultado alcançado neste trabalho indica que algoritmos de aprendizagem inteligente como o Q-learning aprendem sistematicamente a formar conluio, gerando preços acima do nível competitivo sem nenhum tipo de comunicação entre os agentes.

Concomitante ao reinforcement learning, o ‘deep learning’ é também utilizado, através da arquitetura das Redes Neurais Artificiais (RNAs). O deep learning é uma modalidade de aprendizado dentro da área de machine learning que capta características e encontra padrões, fazendo uso de diversas camadas no processamento de dados. Um dos principais benefícios de aplicar o deep learning vem da possibilidade de interações entre diversos agentes, fato que

aperfeiçoa a tomada de decisão do mesmo frente a um cenário desconhecido. O estudo realizado por Tampuu *et al.* (2017) mostra como a possível implementação de um algoritmo capaz de utilizar este sofisticado processo de aprendizado pode (sem interferência humana *ex post*) levar a uma transição de um cenário competitivo para um cenário cooperativo.

Fazendo uso do ambiente de mercado de competição sequencial de Bertrand utilizado por Calvano *et al.* (2020), o trabalho realizado por Hettich (2021) incorpora o deep learning ao algoritmo Q-learning, no que é chamado de Deep Q-Network (DQN), visando uma abordagem mais próxima dos mercados reais. Durante a simulação os algoritmos DQN competem uns com os outros através deste algoritmo que é um aprimoramento do Q-learning utilizando uma função de aproximação através da Deep Neuronal Network (DNN). A grande vantagem observada na Deep Q-Network é que o conluio ocorre significativamente mais rápido, sendo assim, é mais adequado para a compreensão de mercados como o comércio eletrônico. Este algoritmo também permite o experimento em oligopólios mais amplos, demonstrando a correlação negativa entre o aumento do número de agentes e o nível de conluio.

4.2 Referencial empírico

Chen *et al.* (2016) investigam o comportamento dos algoritmos na plataforma online da Amazon. Neste estudo é analisado empiricamente as estratégias de preço dos vendedores que implementaram a precificação por algoritmos. Os resultados indicam que vendedores que adotam algoritmos encontram mais sucesso nas vendas, recebendo consequentemente maior feedback dos consumidores. Seus produtos aparecem com maior frequência nas cestas de compras mesmo quando eles não oferecem o menor preço. O maior sucesso dos vendedores que utilizam algoritmos frente aos que não usam tal tecnologia pode sinalizar uma tendência a completa automação da precificação. O impacto dessas distorções ainda não pode ser completamente compreendido e cria novos desafios para a pesquisa futura.

Assad *et al.* (2020) busca captar o impacto da adoção de algoritmos com base em inteligência artificial na formação dos preços para o mercado de combustível da Alemanha. Esta análise foi possível em vista que os algoritmos se tornaram amplamente disponíveis no mercado durante o ano de 2017, assim, analisando as quebras estruturais no período 2016-2018 foi possível observar quais pontos de venda adotaram o uso de algoritmos, possibilitando então a investigação dos efeitos causados por tal inovação no mercado. Foi encontrado um aumento médio de 9% nos preços quando comparado com o período pré-adoção dos algoritmos. Este

resultado é consistente com a preocupação referente aos possíveis danos causados pela adoção em massa de algoritmos de precificação.

Wieting e Sapi (2021) analisam a precificação por algoritmos no Bol.com, que é uma plataforma de vendas online semelhante a Amazon, sendo a maior do ramo na Holanda e Bélgica. Neste trabalho os autores observam que a competição entre dois vendedores utilizando algoritmos para a precificação resulta em preços particularmente elevados, mas com o número de competidores aumentando suficientemente é possível uma competição acirrada. Também foi observado que o uso de algoritmos pode reduzir o preço em um mercado monopolista. Estes resultados demonstram precisamente os possíveis benefícios e malefícios do uso de algoritmos. Por um lado, pode levar ao aumento indiscriminado de preços enquanto por outro pode gerar inúmeros ganhos de eficiência. Cabe aos agentes reguladores fazerem a balança pender para o lado benéfico.

Quanto aos trabalhos focados na regulação de algoritmos de precificação, estes são muito mais abundantes quando comparados a estudos empíricos que observam a existência do conluio tácito nos mercados. Beneke e Mackenrodt (2020) realizam um estudo tendo como base a lei da União Europeia que regula as práticas colusivas, sugerindo “remédios” para lidar com eventuais ocorrências de conluio tácito em que o aparato legal não esteja preparado para enfrentar. De acordo com a exposição dos autores, a lei antitruste europeia considera como prática colusiva que efetivamente viola a lei os acordos, as decisões por associação entre firmas e as práticas concertadas. Dentro destes três conceitos, nenhum engloba o conluio tácito alcançado pelos algoritmos de precificação, isso porque todos exigem a ocorrência de comunicação em algum grau. Os autores ainda discutem como a implementação de algoritmos altera o debate clássico em relação ao conluio tácito e mostram que as análises clássicas mais poderosas foram alcançadas pela teoria dos jogos e o modelo de Bertrand (que tem como variável estratégica o preço). Em conclusão, é indicado que as autoridades coíbam práticas capazes de alterar a estrutura dos mercados de forma negativa e conseqüentemente facilitar o conluio. Exemplos destas práticas são fusões que resultem em diminuição nociva de concorrentes no mercado.

O trabalho de Assad et al. (2021) reúne os autores envolvidos no estudo de Calvano et al. (2020) e Assad et al. (2020) em um arranjo interessante para então discutir o que há de mais novo em relação aos algoritmos de precificação, conluio tácito e lei antitruste. Suas conclusões sugerem que as autoridades devem buscar constantemente compreender o ambiente de mercado em que os algoritmos estão inseridos e também a estrutura dos softwares utilizados. Esta compreensão passa por estudar os diferentes tipos de algoritmos e como se dá sua interação e

processo de tomada de decisão. Estes fatores são essenciais e impactam significativamente no comportamento dos algoritmos. Outra abordagem é ter acesso aos dados utilizados no processo de treinamento do algoritmo, assim, os agentes reguladores podem perceber o design por trás da tomada de decisão e também fazer experimentos que demonstram como o comportamento é afetado em diferentes tipos de ambientes de mercado. Por último, é enfatizado o estágio embrionário dos estudos acadêmicos e práticos sobre a relação entre algoritmos e conluio, e a necessidade de pesquisa futura.

5. ALGORITMOS

Compreender o funcionamento dos algoritmos é o ponto chave para estudar os desdobramentos econômicos da sua implementação nos mercados. Nesta seção passaremos por uma explanação de dois métodos baseados no aprendizado por reforço e que foram aplicados por economistas. Primeiro, o método Q-learning, inicialmente desenvolvido por Watkins (1989) e posteriormente aplicado por Calvano et al. (2020) para simular a interação entre os agentes e um ambiente de mercado baseado na competição de preços. O segundo, um aprimoramento do método Q-learning aplicado por Hettich (2021) com o objetivo de analisar a interação agente-mercado em um ambiente mais sofisticado e com maior agilidade no processo de aprendizado. Este método é conhecido como Deep Q-network e aplica elementos das redes neurais artificiais em sua estrutura.

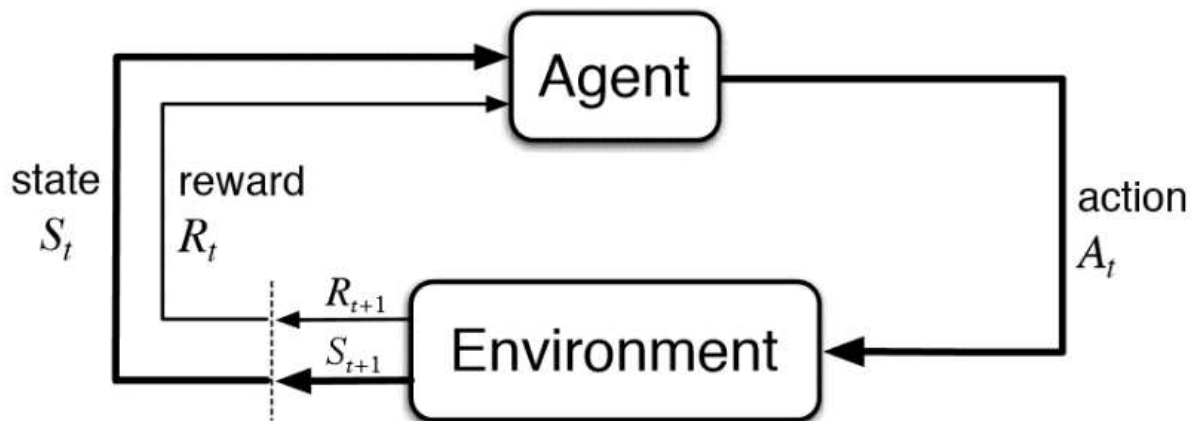
5.1 Q-learning

Alguns dos elementos básicos que fazem parte do escopo do aprendizado por reforço já foram citados anteriormente neste trabalho. Neste ponto, iremos listar todos os elementos relevantes e apresentar as definições para cada um deles. Para tal objetivo, usaremos as definições utilizadas por Habib (2019).

- Agente: Os agentes são as entidades responsáveis pela tomada de decisão.
- Ambiente de mercado (optei por traduzir “environment” como ambiente de mercado visando uma maior acurácia no significado da tradução): O ambiente de mercado é o mundo onde o agente opera. Quando ele realiza uma ação, recebe um estado e uma recompensa (ou penalidade) como output do ambiente.

- Estado: O estado é o lugar onde o agente se encontra no ambiente de mercado. Tudo que é necessário saber sobre o ambiente é armazenado no estado e esta informação pode ser representada através de um vetor contendo as variáveis relevantes.
- Ação: A ação é o próximo movimento escolhido pelo agente.
- Recompensa: A recompensa é o retorno obtido pelo agente após realizar uma ação no ambiente de mercado. Pode ser positiva ou negativa.
- Estratégia (ou política): A estratégia consiste em um mapeamento dos estados junto com suas ações. Pode ser considerada o cérebro do agente.

Figura 1 - Sistema de interações do algoritmo Q-learning



Fonte: BARTO e SUTTON (2018)

A figura 1 mostra o design básico para o funcionamento do Q-learning. O agente define um preço (ação) com base em uma política (estratégia). Através da ação tomada, o agente interage com o ambiente de mercado, que é representado, no caso da competição de preços, pelo modelo de Bertrand. Como retorno, o agente recebe uma recompensa em decorrência das vendas e um novo estado. A partir deste ponto, o processo é reiniciado, com o agente armazenando a recompensa correspondente a ação tomada e o novo estado na matriz Q.

O Q-learning opera através do aprendizado com base na experiência passada, desta forma, tende a realizar as ações que apresentam maior probabilidade de sucesso. Isso viabiliza a construção de uma estratégia ótima sem nenhum conhecimento a priori sobre o ambiente de mercado.

Seguindo o trabalho de Watkins (1989) e a síntese do mesmo realizada por Calvano *et al.* (2020) temos que o Q-learning foi desenvolvido originalmente para tratar de processos de decisão de Markov finitos. Assim, em cada período t um agente observa uma variável de estado $s_t \in S$, em seguida escolhe uma ação $a_t \in A$ e recebe uma recompensa π_t . Então, o algoritmo

prossegue para o próximo estado no período $t + 1$, seguindo a distribuição de probabilidade $F(\pi_t, s_{t+1} | s_t, a_t)$. De forma geral, esta função nos diz que a probabilidade relativa à escolha da próxima ação depende da recompensa, do estado e da ação selecionada no período anterior.

O problema a ser resolvido gira em torno de maximizar o valor presente esperado no longo prazo. Podemos representar tal problema através da equação abaixo:

$$(1) \quad E \left[\sum_{t=0}^{\infty} \delta^t \pi_t \right],$$

onde δ^t é o fator de desconto e costuma ser fixado em 0.95, valor propositalmente elevado para possibilitar a manutenção do conluio, em vista que é consistente com a teoria econômica que um maior fator de desconto indica maior estabilidade na prática colusiva (Bruttel, 2009). Aqui a noção de longo prazo é particularmente importante, em vista que no curto e médio prazo o algoritmo enfrenta um trade-off entre escolher as melhores ações já conhecidas e experimentar novas.

No aprendizado por reforço o problema do tomador de decisões é normalmente tratado com a equação de Bellman, proposta originalmente por Bellman (1954). Esta função calcula o valor de um estado através da decomposição da equação (1) em dois subproblemas, o cálculo da recompensa imediata e do valor futuro aplicado o desconto. Podemos observar esta decomposição logo abaixo:

$$(2) \quad V(s) = \max\{ E[\pi | s, a] + \delta E[V(s_{t+1}) | s, a] \}.$$

Para calcular o valor do estado com a equação acima é necessário conhecer os valores de cada ação e também as probabilidades de transição entre elas, portanto, é muito mais conveniente fazer uso da identidade $V(s) = \max_a Q(s, a)$, transformando assim a equação acima na função valor de ação. Isso simplifica substancialmente o esforço matemático necessário para realizar tal tarefa em vista que basta calcular os valores Q e o agente escolhe entre o mais elevado, eliminando a necessidade de estimar as probabilidades. A nova equação é representada da seguinte maneira:

$$(3) \quad Q(s, a) = E(\pi | s, a) + \delta E[\max_a Q(s_{t+1}, a_{t+1} | s, a)].$$

A equação acima pode também ser representada na forma matricial $|S| \times |A|$ pois S e A são finitos ($a \in A, s \in S$). Esta matriz é comumente chamada de matriz Q e sua versão inicial é por todos valores iguais a 0. Ela é alimentada pelos resultados provenientes da interação entre o agente e o ambiente de mercado.

A seguir, temos a equação responsável por atualizar cada célula da matriz Q . O valor $Q_{t+1}(s, a)$ representa o valor Q no próximo período e é calculado através da combinação convexa ($1 - \alpha + \alpha = 1$) do valor Q no período anterior e da recompensa no período t somada a ao valor descontado do estado no período $t + 1$.

$$(4) \quad Q_{t+1}(s, a) = (1 - \alpha)Q_t(s, a) + \alpha[\pi_t + \delta \max_{a \in A} Q_t(s_{t+1}, a)].$$

O ambiente simulado proposto é estocástico, portanto, cada ação possui um peso probabilístico. Sabendo disto, é possível perceber que o agente precisa explorar todas as possibilidades para ser capaz de escolher a ação que resulte na recompensa ótima. Por isso, é importante definir o modo de exploração (exploration) e o modo de aproveitamento (exploitation). No primeiro, o algoritmo opta por explorar o ambiente de mercado e descobrir novas recompensas através de novas ações, já no segundo, o algoritmo faz uso da memória para realizar ações que resultaram anteriormente em melhores recompensas. Na prática, Calvano et al. (2020) opta pela redução gradual da taxa de exploração para que o algoritmo possa com o passar de o tempo optar pela ação que maximiza seu retorno com cada vez maior probabilidade. A fórmula abaixo representa matematicamente esta redução gradual da taxa de exploração:

$$(5) \quad \varepsilon_t = e^{-\beta t}$$

Onde ε é a taxa de exploração e β é um parâmetro que está diretamente atrelado ao período t . Quanto maior o valor do parâmetro, mais rápido o modo de exploração será descartado em detrimento do modo de aproveitamento. Em conclusão, o algoritmo permanece no modo de exploração com uma probabilidade igual a ε e entra no modo de aproveitamento com uma probabilidade igual a $1 - \varepsilon$. De acordo com esta política de exploração, enquanto $t \rightarrow \infty$, a probabilidade de adotar a política ótima ε -greedy tende a 1. Resumindo, nos períodos finais deste tipo de simulação, o algoritmo opta sempre pela ação que gera maior recompensa.

A escolha por tal política se justifica em dois pontos, tanto pela simplicidade do método quanto por ser amplamente utilizado para casos onde é necessário explorar novas ações ao mesmo tempo que se busca uma política ótima (Barto e Sutton, 2018).

5.1.1 Modelo de Bertrand

O modelo de competição sequencial de Bertrand utilizado na construção do ambiente de mercado durante a simulação feita por Calvano *et al.* (2020) é considerado um modelo canônico para estudar o conluio. Ele capta alguns fatores importantes como a diferenciação horizontal e vertical. O seu design apresenta um jogo infinitamente repetido no qual as firmas competem simultaneamente via preço e suas decisões são condicionadas pelas decisões passadas. O fato de a competição ocorrer via preço neste modelo o faz adequado em se tratando de algoritmos, isso pois os mercados mais propícios a adotar esta tecnologia, como o das plataformas de comércio online, tem como variável estratégica os preços.

O custo marginal é constante para fins de simplificação, existem n produtos diferentes e um produto externo a_0 . Em cada período t a demanda pelo bem $i = 1, 2, \dots, n$ é dada pela equação abaixo:

$$(6) \quad q_{i,t} = \frac{e^{\frac{a_i - p_{i,t}}{\mu}}}{\sum_{j=1}^n e^{\frac{a_j - p_{j,t}}{\mu}} + e^{\frac{a_0}{\mu}}}$$

Os parâmetros a_i e a_j são responsáveis por representar a diferenciação vertical enquanto μ capta a diferenciação horizontal. Cada produto é fornecido por uma firma, portanto, n é também o número de firmas no mercado. Por último, o payoff é dado por $\pi_{i,t} = (p_{i,t} - c_i)q_{i,t}$, onde c_i é o custo marginal. É possível observar que quando $\mu = 0$ não há diferenciação de produtos, portanto, este é o caso dos substitutos perfeitos.

Ao adotar um modelo de repetições infinitas surge um problema que é preciso tratar sem mais demoras. Seu caráter infinito impossibilita que o modelo seja considerado como estacionário. Isso ocorre porque o histórico de ações ficará cada vez maior com o decorrer das interações fazendo com que o número de estados se expanda, forçando mudanças na política. Para manter o caráter estacionário do modelo é preciso limitar o tamanho da matriz Q , que é responsável por armazenar as ações tomadas no passado. Com essa medida a estacionariedade exigida pelo método Q-learning é satisfeita pelo modelo.

5.1.2 Resultados

Os resultados encontrados por Calvano et al. (2020) são consistentes com as expectativas. Quando a simulação é realizada com a memória sendo igual a 0, os agentes adotam preços próximos do nível competitivo. Isso ocorre, pois, sem armazenar as ações anteriores, é impossível a existência de um mecanismo de punição, assim, a jogada ótima de cada firma é o preço competitivo. Já com a presença da memória, foi observado que em cerca de 95% dos casos os desvios do nível de preço colusivo foram respondidos com punição. Esta penalidade ocorre na forma de uma guerra de preços que gradualmente faz com que os agentes retornem ao seu comportamento anterior.

Para o caso da entrada de firmas no mercado durante a simulação, o equilíbrio colusivo foi mais fortemente abalado, embora o cenário ainda esteja distante do equilíbrio competitivo. Neste caso foi observada uma queda nos lucros médios, punições mais brandas frente aos desvios o que conseqüentemente aumentou o incentivo para reduções de preço.

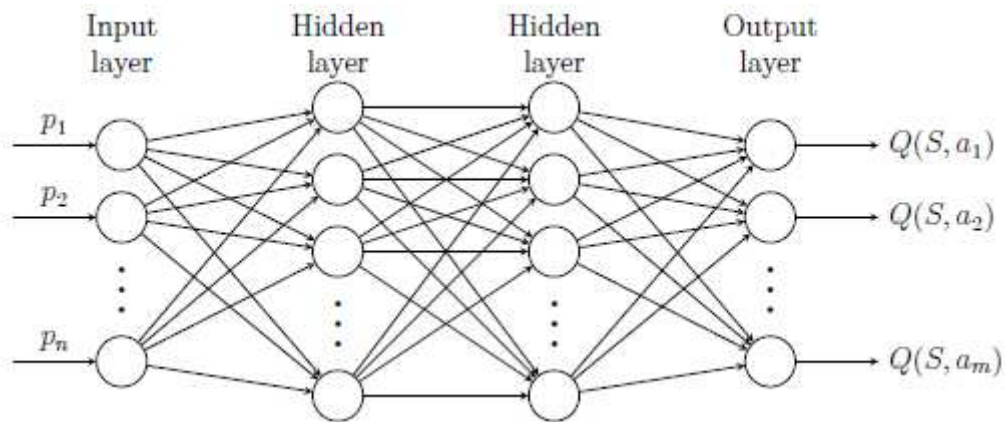
Ao contrário dos fatores já observados que de forma geral caminharam em direção ao esperado, a variação na diferenciação horizontal produziu resultados incertos: ao mesmo tempo que os produtos são mais homogêneos e o ganho por reduzir preços aumenta, também a punição pelo desvio pode ser mais intensa.

5.2 Deep Q-Network

O Deep Q-Network é um método que incorpora as Redes Neurais Artificiais ao Q-learning. A ideia geral é que a matriz Q calculada pela equação (3) seja substituída por uma rede neural que fica responsável por estimar os valores Q.

De acordo com Sewak (2019), a rede neural é uma tecnologia de aprendizado por reforço inspirada no córtex visual humano e na forma que o mesmo funciona para processar imagens que os olhos captam. A figura 2 dá um panorama geral para uma RNA padrão. O input caracteriza os preços adotados por cada agente no período $t - 1$ e sua quantidade indica o número de jogadores na simulação.

Figura 2 - Arquitetura da Q-network



Fonte: HETTICH (2021)

Enquanto o método Q-learning atualiza sua matriz Q uma célula por vez, com uma velocidade de aprendizado limitada, o DQN utiliza uma função de aproximação com pesos θ para estimar os valores $Q(s, a, \theta)$. Observando a figura 2, as setas que conectam a camada de entrada (input layer) a camada escondida (hidden layer) são identificadas como os pesos. De forma geral a camada escondida ou oculta recebe os dados de entrada ponderados pelo peso θ e aplica uma função de ativação que comumente assume a forma de uma função logística. Em teoria uma camada escondida com um número suficiente de unidades pode aproximar qualquer função contínua, embora uma DQN com mais de uma camada demonstre uma melhor performance (Mnih et al, 2015; Barto e Sutton, 2018).

Segundo Hettich (2021) o DQN tem duas grandes vantagens. A primeira, é que agora uma célula da matriz é atualizada juntamente com todas as células vizinhas por generalização. A segunda é a eliminação da restrição de tamanho da matriz Q. Como já discutido anteriormente, de acordo com o avanço da simulação, a matriz Q resultante do método Q-learning vai se tornando cada vez maior e consumindo cada vez mais memória. Agora, com a função de aproximação os pesos θ serão atualizados para melhor estimar os valores Q ao invés de diretamente calculá-los. Estas melhorias são significativas porque, em se tratando de ambientes com milhares de interações diárias, como é o caso do varejo online, o aprendizado mais acelerado e dinâmico pode ser uma melhor representação do mercado real.

Ao colocar em números a maior velocidade de aprendizado, Hettich (2021) compara o tempo necessário para o DQN encontrar uma política ótima frente ao tempo exigido pelo Q-learning. A simulação de Calvano et al. (2020), em tempo real, levaria cerca de 3 anos e meio

para convergir em direção a política ótima em uma plataforma de comércio eletrônico capaz de modificar os preços cerca de 30 vezes durante o dia. Já o DQN realizaria o mesmo feito em cerca de um mês.

6. POLÍTICA ANTITRUSTE

No Brasil, a política antitruste faz parte da jurisdição do Conselho Administrativo de Defesa Econômica, que ao ser comparado a órgãos correspondentes em países como os Estados Unidos, foi instituído em um período mais recente, tendo sido criado no ano de 1962 e institucionalizado em 1994. No ano de 2012 foi efetivada a Lei 12.529/11, que modernizou a lei antitruste no Brasil. De acordo com o artigo 36 da mesma, condutas que podem ser consideradas violações da lei antitruste incluem: I) limitar, falsear ou de qualquer forma prejudicar a livre concorrência; II) aumentar arbitrariamente os lucros; III) dominar mercado relevante de bens ou serviços; ou IV) exercer o poder de mercado de forma abusiva.

O papel do CADE gira em torno de garantir que os algoritmos implementados visem apenas o aprimoramento da eficiência, não sendo capazes de adotar práticas colusivas. De forma geral, surgem duas alternativas para a estratégia de regulação. A primeira está relacionada a inspeção dos algoritmos antes mesmo de entrarem no mercado, para que possam ser investigados quanto a sua estrutura. Tal medida é naturalmente custosa e pode ser considerada uma solução drástica, em vista que a ocorrência do conluio tácito autônomo através de algoritmos pode exigir que uma série de critérios sejam satisfeitos. A outra alternativa, que pelo menos inicialmente parece mais adequada, é a investigação de práticas suspeitas. Desta forma, o CADE observaria a estrutura do algoritmo após já ter sido empregado. Para viabilizar este tipo de medida, seria necessário mudanças na lei antitruste.

Para verificar os mercados passíveis de produzir resultados nocivos a competição saudável é possível basear-se em estudos que buscaram por quebras estruturais nos mercados que adotaram algoritmos, como foi o caso do trabalho feito por Assad et al. (2020). Este que teve como alvo o mercado de gasolina da Alemanha. O único obstáculo aqui seria a disponibilidade de amplos dados sobre as empresas. De qualquer forma, para que seja feita uma regulação eficiente é essencial que o CADE tenha agentes capazes de compreender o funcionamento dos algoritmos.

Outro ponto importante é como o órgão regulador utiliza sua influência e visibilidade para divulgar e incentivar a discussão pelo país. Neste sentido, o CADE convidou uma

pesquisadora da Universidade de Haifa para um debate com o tema “Cartel mediante o uso de algoritmos” que fez parte da Semana Nacional de Combate a Cartéis (SNCC) no ano de 2020. Foram discutidas as condições em que os algoritmos atuam para coordenar preços e como podem facilitar acordos entre concorrentes. O evento visa o compartilhamento de experiências e técnicas bem como o fortalecimento de ações contra a prática anticompetitiva. A atenção com temas relacionados aos algoritmos foi e é importante, de forma que gera incentivos para mais estudos relacionados.

6.1 Projeto Cérebro

O Projeto Cérebro é uma ferramenta construída pelo CADE que utiliza o aprendizado de máquina para auxiliar a autarquia na detecção de cartéis. A criação da ferramenta foi iniciada em 2013 e para sua construção o CADE contou com um especialista em tecnologia da informação, um em estatística e um em ciência de dados. Tendo acesso a dados fornecidos pelo Ministério da Economia, o Cérebro é utilizado para analisar dados relacionados a licitações e busca identificar indícios de comportamentos colusivos.

Na emenda de apropriação de despesa enviada à Câmara para o custeio do Projeto Cérebro temos a seguinte justificativa:

O projeto cérebro visa identificar possíveis formações de cartéis. Por meio da transposição de diversos bancos de dados o software consegue reconhecer a probabilidade de colusão entre as empresas em processos licitatórios. O software já está em uso no CADE para auxiliar na identificação de possíveis cartéis e auxiliará, desta forma, outros órgãos federais, Estados e Municípios com a mesma finalidade. Conseqüentemente, com a inibição em relação a formação dos cartéis, a concorrência entre as empresas seria mais justa e o preço dos bens e serviços adquiridos por meio de compras públicas seriam melhores, proporcionando uma escolha licitatória imparcial, e por conseguinte, proporcionaria maior segurança jurídica aos administradores. (Emenda de apropriação de despesa para o Projeto Cérebro, 2020).

O uso da ferramenta foi efetivado em 2018 e as informações extraídas da mesma podem ser usadas em conjunto a denúncias para garantir que a legislação antitruste seja cumprida. É também um

indicativo das capacidades do CADE, que em caso de necessidade pode adotar práticas semelhantes para monitorar o uso de algoritmos nos mercados.

7. CONSIDERAÇÕES FINAIS

Este trabalho buscou analisar o impacto da implementação de algoritmos de precificação com base na inteligência artificial e aprendizado por reforço nos mercados. Este objetivo se justifica tanto por ser um tema relativamente recente e que precisa ser melhor estudado quanto por ser necessária a produção de mais trabalhos que abordem o tema em português. Para alcançar tal objetivo foi inicialmente discutido como os resultados da implementação de algoritmos variam com base na estrutura do mercado ao qual é empregado. Dentre estes elementos temos o número de firmas, barreiras à entrada, comunicação, frequência da interação entre os agentes, transparência, diferenciação de produtos e assimetria de custos. Posteriormente, foi abordado o algoritmo Q-learning implementado por Calvano et al. (2020) e um aprimoramento do mesmo que utiliza o Deep Q-network e é aplicado por Hettich (2021). Esta discussão foi feita na seção 5 e busca dar uma visão geral de como funciona um algoritmo de aprendizado por reforço tanto na perspectiva matemática quanto na econômica. Por último foram tratadas as implicações para a política antitruste e os possíveis caminhos para lidar com a emergente utilização de algoritmos.

Com base na estrutura dos algoritmos de aprendizado por reforço como o Q-learning e o Deep Q-network, as evidências indicam que é possível a coordenação entre algoritmos sem nenhum tipo de comunicação entre os mesmos, resultado que é classificado como conluio tácito, portanto, a implementação de algoritmos pode desafiar as autoridades antitruste de duas principais formas. Em primeiro lugar, podem afetar o funcionamento dos mercados de formas diferentes do observado na literatura tradicional. E em segundo lugar, podem gerar resultados de mercado nocivos semelhantes aos observados nos cartéis.

Do ponto de vista da aplicação da lei antitruste, os agentes reguladores precisam identificar quando o resultado da aplicação do algoritmo culmina em aumento da eficiência no mercado e quando esta aplicação resulta em preços supra competitivos. São sugeridas duas principais formas de abordagem, *ex ante* e *ex post*, sendo preferida a última em vista que se mostra uma abordagem moderada dada as condições específicas necessárias para o surgimento de conluio tácito entre algoritmos.

Para pesquisas futuras é importante que sejam feitos estudos aprofundados tendo como foco a estrutura dos algoritmos e seu processo de tomada de decisão. Isso é necessário pois com o processo de criação de novos algoritmos cada vez mais sofisticados se torna essencial a compreensão dos mesmos para que então o impacto da sua implementação possa ser mensurado. E claro, as agências reguladoras devem acompanhar de muito perto o desenrolar destes acontecimentos.

8. REFERÊNCIAS

ASSAD, Stephanie *et al.*, **Algorithmic Pricing and Competition: Empirical Evidence from the German Retail Gasoline Market**. CESifo Working Paper, n. 8521, 2020.

ASSAD, Stephanie *et al.* **Autonomous algorithmic collusion: Economic research and policy implications**. Oxford Review of Economic Policy, n. 37, p. 459-478, 2021.

ANGNER, Erik e LOEWENSTEIN, George F., **Behavioral Economics**. Handbook of the Philosophy of Science, Uskali Mäki ed., 641-690, 2007. Amsterdam: Elsevier, 2012.

BAGWELL, Kyle e WOLINSKY, Asher. **Game theory and industrial organization**. Handbook of Game Theory with Economic Applications, n. 3, p. 1851-1895, 2002.

BARFIELD, Woodrow. PAGALLO, Ugo. **Research Handbook on the Law of Artificial Intelligence**. Reino Unido: Edward Elgar Publishing, 2018.

BARTO, Andrew G. e SUTTON, Richard S. **Reinforcement Learning: An introduction**. Cambridge: The MIT Press, 2018.

BELLEFLAMME, Paul e PEITZ, Martin. **Industrial Organization Markets and Strategies**. New York, Cambridge University Press, 2010.

BELLMAN, Richard. **The Theory of Dynamic Programming**. Bulletin of the American Mathematical Society, n. 60, p. 503-515, 1954.

BENEKE, Francisco e MACKENRODT, Mark-Oliver. **Remedies for algorithmic tacit collusion**. Journal of Antitrust Enforcement, n. 9, p. 152-176, 2020. Disponível em: <https://doi.org/10.1093/jaenfo/jnaa040>

BRUTTEL, Lisa V. **The Critical Discount Factor as a measure for cartel stability?**. Journal of Economics. n. 2, p. 113-136, 2009.

CALVANO, Emilio *et al.* **Artificial Intelligence, Algorithmic Pricing, and Collusion.** American Economic Review, vol. 110, n. 10, p. 3267-97, 2020. Disponível em: <http://dx.doi.org/10.2139/ssrn.3304991>.

CALVANO, Emilio *et al.* **Algorithmic Pricing: What Implications for Competition Policy?** Review of Industrial Organization, n. 55, p. 155-171, 2019.

CHEN, Le *et al.* **An Empirical Analysis of Algorithmic Pricing on Amazon Marketplace.** Em: **WWW '16: Proceedings of the 25th International Conference on World Wide Web**, 2016. Montreal, Quebec, Canada: International World Wide Web Conferences Steering Committee, p 1339–1349.

ENGEL, Christoph. **Tacit Collusion – The Neglected Experimental Evidence.** MPI Collective Goods Preprint, n. 4, 2015. Disponível em: <http://dx.doi.org/10.2139/ssrn.2567152>.

EZRACHI, Ariel e STUCKE, Maurice E. **Virtual Competition: The Promise and Perils of the Algorithm-driven Economy.** Londres, Inglaterra. 2016.

EZRACHI, Ariel e STUCKE, Maurice E. **Sustainable and Unchallenged Algorithmic Tacit Collusion.** Northwestern Journal of Technology and Intellectual Property, vol. 17, n. 2, p. 218-259, 2020.

HETTICH, Matthias. **Algorithmic Collusion: Insights from Deep Learning.** Center for Quantitative Economics Working Papers, n. 9421, 2021. Disponível em: <https://ssrn.com/abstract=3785966>.

IVALDI, Marc *et al.* European Commission. **The Economics of Tacit Collusion.** Toulouse, 2003.

KATZ, Michael e SALLET, Jonathan. **Multisided Platforms and Antitrust Enforcement.** The Yale Law Journal, vol. 127, p. 2142, 2018.

KLEIN, Timo. **Autonomous Algorithmic Collusion: Q-Learning Under Sequential Pricing**. Amsterdam Law School Research Paper. n. 2018-15, 2019. Disponível em <https://ssrn.com/abstract=3195812>.

KÜHN, Kai-Uwe. **Fighting collusion by regulating communication between firms**. Economic Policy, n. 32, p. 169-204, 2001.

LEDVINA, Andrew e SIRCAR, Ronnie. **Dynamic Bertrand and Cournot Competition: Asymptotic and Computational Analysis of Product Differentiation**. Risk and Decision Analysis, vol. 3, no. 3, 149-165. 2012.

MASON, Charles F., PHILLIPS, Owen R. e NOWELL, Clifford. **Duopoly Behavior in Asymmetric Markets: an experimental evaluation**. Review of Economics and Statistics, n. 4, p. 662-670, 1992.

MEYLAHN, Janusz e DEN BOER, Arnoud. **Learning to Collude in a Pricing Duopoly**, 2020. Disponível em: <https://ssrn.com/abstract=3741385>.

MNIH, Volodymyr *et al.* **Human-Level Control through Deep Reinforcement Learning**. Nature, n. 518, p. 529–533, 2015. Disponível em: <https://doi.org/10.1038/nature14236>.

RAB, Suzanne. **Artificial intelligence, algorithms and antitrust**. Competition Law Journal, n. 18, p. 141-150, 2019.

OECD, **Algorithms and Collusion: Competition Policy in the Digital Age**, 2017.

SCHWALBE, Ulrich. **Algorithms, Machine Learning, and Collusion**, Journal of Competition Law & Economics, n. 14, p. 568–607, 2018. Disponível em: <https://doi.org/10.1093/joclec/nhz004>.

STIGLER, George J. **A Theory of Oligopoly**. Journal of Political Economy, n. 1, 1964. Disponível em: <https://doi.org/10.1086/258853>.

TAMPUU, Ardi *et al.*, **Multiagent cooperation and competition with deep reinforcement learning**. PLoS ONE 12 (4), 2017. Disponível em: <https://doi.org/10.1371/journal.pone.0172395>

TIROLE, Jean. **The Theory of Industrial Organization**. The MIT Press, 1988.

TREMBLAY, Victor J e TREMBLAY, Carol H. **New Perspectives on Industrial Organization: With Contributions from Behavioral Economics and Game Theory**. Nova York: Springer, 2012.

TUCKER, C. **Digital Data, Platforms and the Usual [Antitrust] Suspects: Network Effects, Switching Costs, Essential Facility**. Review of Industrial Organization, n. 54, p. 683–694, 2019.

VARIAN, Hal, **Artificial Intelligence, Economics, and Industrial Organization**. National Bureau of Economic Research, Working Paper n. 24839, 2018.

WALTMAN, Ludo e KAYMAK, Uzay. **Q-Learning Agents in a Cournot Oligopoly Model**. Journal of Economic Dynamics and Control, vol. 10, n. 10, p. 3275–93, 2008.

WATKINS, Christopher J.C.H. **Learning from delayed rewards**. Universidade de Cambridge, Inglaterra, 1989.

WATKINS, Christopher J.C.H. e DAYAN, P. **Q-learning**. Machine Learning, n. 8, p. 279–292, 1992.

WIETING, Marcel e SAPI, Geza. **Algorithms in the Marketplace: An Empirical Analysis of Automated Pricing in E-Commerce**. NET Institute Working Paper, n. 21-06, 2021. Disponível em: <http://dx.doi.org/10.2139/ssrn.3945137>.

ZARZUR, Cristianne *et al.* **Use of Pricing Algorithms and Antitrust Enforcement in Brazil**. Instituto Brasileiro de Estudos de Concorrência, Consumo e Comércio Internacional (IBRAC), The Future of Antitrust, p. 207-213, 2020.

ZHOU, Nan *et al.* **Algorithmic Collusion in Cournot Duopoly Market:** Evidence from Experimental Economics. ArXiv, 1802.08061. Fevereiro, 2018.