

SIMULAÇÃO DE RISCO ANTITRUSTE EM MERCADOS DIGITAIS

Antitrust Risk Simulation in Digital Markets

Alessandro Roosevelt Silva Ribeiro¹

Resumo: Este estudo desenvolve um modelo quantitativo que combina simulações estocásticas e aprendizado de máquina para estimar riscos concorrenciais em plataformas digitais com base em dados reais do Conselho Administrativo de Defesa Econômica (CADE), enriquecidos com proxies para características digitais, estimando a probabilidade de ocorrência de risco antitruste elevado com base em variáveis como participação de mercado, efeitos de rede, barreiras à entrada e uso de algoritmos de precificação, utilizando a linguagem python para simulação. O modelo sugere que plataformas digitais com participação de mercado superior a 40%, combinada com efeitos de rede crescentes e uso ativo de algoritmos de precificação, possuem uma probabilidade superior a 85% de gerar riscos antitruste. Os resultados indicam que o modelo consegue antecipar com precisão situações de risco antitruste, especialmente em cenários com alta concentração de mercado e uso intensivo de algoritmos de precificação.

Palavras-chave: Antitruste; Mercados Digitais; Monte Carlo; Random Forest; Simulação Estocástica.

Abstract: This study proposes a hybrid approach for antitrust risk assessment in digital markets, combining supervised machine learning (Random Forest) with Monte Carlo simulations. Using real data from the Brazilian Administrative Council for Economic Defense (CADE), enriched with proxies for digital characteristics, the model estimates the probability of high antitrust risk based on variables such as market share, network

¹ Alessandro Roosevelt Silva Ribeiro, mestre em Computação Aplicada pela Universidade de Brasília e Mestre em Direção e Gestão de Sistemas de Seguridade Social pela Universidade de Alcalá em Madri-Espanha. Especialista em Gestão de Pessoas e Negociação Coletiva. Servidor Público Federal, Diretor de Tecnologia da Informação da Previdência Complementar do Estado de São Paulo.

effects, entry barriers, and the use of pricing algorithms, simulated using Python. The model suggests that digital platforms with market share above 40%, combined with increasing network effects and active use of pricing algorithms, are more than 85% likely to generate antitrust risks. The results demonstrate the predictive capacity of the proposed system and its usefulness in providing insights for regulators and policymakers.

Keywords: Antitrust; Digital Markets; Monte Carlo Simulation; Random Forest; Algorithmic Pricing.

1. Introdução

Os mercados estão cada vez mais digitalizados, e as dinâmicas competitivas têm sido moldadas por eles com o uso intenso de efeitos de rede, algoritmos de precificação automatizados e barreiras de entrada não convencionais. Essas considerações lançam dúvidas sobre os modelos tradicionais de análise competitiva, que precisam ser refinados para levar plenamente em conta o risco e preservar mercados justos e eficientes.

Ao fazê-lo, a pesquisa acadêmica sobre direito da concorrência — ou "antitruste" na terminologia dos EUA — tem se dedicado a trabalhar com modelagem matemática e empírica. Esta última facilita a determinação objetiva do poder de mercado.

É possível mencionar contribuições como Motta e Polo (2019) por apresentarem desenhos econométricos a serem usados em estudos de fusões e anticompetitivos, e Lyons (2002) por sugerir uma estrutura teórica para avaliação de risco em operações de concentração. Destarte, Harrington (2013) emprega a teoria dos jogos para a interação estratégica de concorrentes em ambientes de risco.

Outras contribuições perspicazes incluem a pesquisa de Davis e Garcés (2010), que consideram a definição de mercado e dominância um exercício probabilístico; e Shapiro e White (2017), que desenvolvem formulações matemáticas estruturais para analisar efeitos competitivos em vários cenários de mercado. Esses estudos ilustram a necessidade de combinar teoria econômica, técnicas empíricas e política de concorrência para enfrentar os problemas levantados pela economia digital.

Os artigos revisados evidenciam bases metodológicas sólidas na área do direito da concorrência e, mais especificamente, na aplicação de

modelos quantitativos e teóricos para avaliar melhor os riscos da aplicação das leis antitruste. Todos eles se propõem a uma abordagem alternativa, mas também complementar, que visa fornecer uma perspectiva multifacetada sobre as ferramentas que estão à disposição para enfrentar os problemas da economia contemporânea.

Em artigo intitulado *Métodos Quantitativos no Direito da Concorrência*, Motta e Polo (2019) oferecem uma discussão abrangente sobre métodos econométricos e formulações estruturais usados na aplicação do direito da concorrência. Eles discutem métodos, incluindo regressões, testes de hipóteses e simulações de mercado, mas focam principalmente no uso de material empírico para avaliar impactos anticompetitivos. Este tipo de metodologia é especialmente conveniente no contexto de fusões e comportamentos unilaterais.

Em *Modelos de Teoria dos Jogos para Avaliação de Risco em Casos Antitruste* (Harrington 2013), o autor usa a teoria dos jogos para modelar o comportamento estratégico entre as empresas. O artigo examina casos de cartelização, conduta predatória e equilíbrio de Nash com respeito à estimativa de risco na aplicação de penalidades antitruste. Este enfoque teórico é útil para explicar os objetivos e comportamentos das empresas em mercados competitivos.

Lyons (2002), no artigo *Avaliação de Risco no Controle de Fusões: Um Modelo Teórico*, propõe um protótipo teórico de fusões baseado na microeconomia industrial e nas estimativas de probabilidade dos impactos nos preços e no bem-estar do consumidor em fusões. A proposta metodológica permite a inclusão do risco resultante de potenciais efeitos na concorrência, algo facilitado pelo estabelecimento de uma série de conceitos que são apoiados com base nas decisões tomadas pelos reguladores.

Davis e Garcés (2010) propõem métodos estatísticos avançados para definição de mercado e avaliação de dominância. Os autores usam testes de substituição de produtos e modelos de elasticidade de preços com um padrão probabilístico que funciona bem quando há estruturas de mercado complexas ou escassez de dados.

Shapiro e White (2017), em *Efeitos Competitivos com Referências a Outros Fatores e Modelos Estruturais*, tratam do protótipo de análise estrutural para efeitos Competitivos para prever efeitos competitivos com dados de demanda e oferta. O artigo revisa ferramentas como o UPP

(Pressão de Preço Ascendente) e o GUPPI (Índice Bruto de Pressão de Preço Ascendente) que são comumente empregados em análises de fusões. O autor também destaca a importância das simulações em um contexto regulatório.

Tanto Motta e Polo (2019) quanto Shapiro e White (2017) possuem pontos de convergência: o amplo escopo de seu trabalho. Ambos têm o potencial de serem aplicados em uma variedade de configurações antitruste (por exemplo, M&A, conduta unilateral e colusiva). Essa flexibilidade em seus protótipos os torna muito atraentes para autoridades de concorrência e consultores econômicos.

A teoria da análise da concorrência é, no entanto, tratada por Harrington e Lyons. Enquanto Harrington considera os efeitos estratégicos dos agentes econômicos, Lyons estabelece um modelo microeconômico para estimativa de risco em processos de concentração (Costa; Lima, 2022). Trabalhos teóricos como esses são necessários para desenvolver um paradigma mais robusto e bem fundamentado.

A proposta de Davis e Garcés (2010) representa uma novidade metodológica e um avanço na técnica estatística aplicada à definição de mercado e análise de dominância (Almeida; Borges, 2021). Seu método probabilístico, por outro lado, pode capturar melhor tanto a delimitação das fronteiras do mercado quanto a definição do poder de mercado, particularmente em indústrias complexas ou de baixa transparência.

Coletivamente, esses artigos constituem uma literatura teórica e observacional variada sobre uma ampla gama de questões que testemunham a heterogeneidade metodológica do direito da concorrência. É essa combinação entre reflexão prática, teórica e estatística, que aprimora a força analítica da disciplina e que a ajuda a acompanhar a natureza rapidamente mutável dos mercados digitais e formular melhores respostas aos desafios regulatórios atuais.

Avanços recentes na literatura sobre simulação de fusões têm ampliado significativamente a capacidade analítica dos modelos aplicados ao direito da concorrência, especialmente em contextos digitais. Um estudo de 2021, publicado no *Journal of Industrial Economics* (Miller; Sheu, 2021) destaca a sofisticação crescente das simulações estruturais, com ênfase na incorporação de dados empíricos e na calibração de parâmetros com base em observações reais de mercado. Essa evolução metodológica reforça a importância de modelos que não apenas estimem efeitos de preço, mas

também considerem dinâmicas de entrada, inovação e comportamento estratégico das firmas —aspectos particularmente relevantes em mercados digitais caracterizados por rápidas transformações tecnológicas e estruturas assimétricas.

Em complemento, a aplicação da teoria dos jogos à política antitruste tem sido objeto de renovado interesse, conforme discutido por autores em *Competition Policy International* (Harrington; Skrzypacz, 2022), que exploram os desafios e oportunidades da modelagem estratégica em ambientes regulatórios. Essa óptica permite capturar interações dinâmicas entre agentes econômicos, como colusão tácita e retaliação, oferecendo subsídios mais robustos para decisões de *enforcement*. Conjuntamente, estudos empíricos recentes já citados, como o publicado no *Journal of Antitrust Enforcement* de 2021, têm proposto métodos quantitativos para definição de mercado digitais, utilizando dados comportamentais e padrões de substituição para superar as limitações dos testes tradicionais. Esses desenvolvimentos reforçam a necessidade de *frameworks* híbridos, como o proposto neste trabalho, que integrem modelagem estocástica, aprendizado de máquina e fundamentos econômicos para avaliar riscos concorrenciais de forma mais precisa e prospectiva.

Comparando os artigos analisados têm-se:

Tabela 1: Comparação dos marcos teóricos empregados

Artigo	Convergências	Divergências
Motta e Polo (2019)	Uso de econometria e modelos estruturais para avaliar efeitos competitivos. Foco em dados empíricos para políticas antitruste.	Abordagem mais geral, sem foco em um único modelo. Menos ênfase em teoria dos jogos em comparação com Harrington (2013). Não incorpora simulações dinâmicas como em <i>Recent Advances in Merger Simulation</i> (2021).
Harrington (2013)	Alinha-se com Lyons (2002) ao analisar riscos estratégicos, mas usando teoria dos jogos. Complementa Shapiro (2017)	Foca exclusivamente em comportamento estratégico (não em fusões ou definição de mercado). Aplicação prática direta menor (aplicação teórica)

Artigo	Convergências	Divergências
	ao modelar interações dinâmicas entre empresas.	maior). Não aborda desafios regulatórios contemporâneos como em <i>Applying Game Theory to Antitrust Enforcement</i> (2022).
Lyons (2002)	Concorda com Shapiro (2017) na preocupação com efeitos de fusões. Usa probabilidade, assim como Davis e Garcés (2010), mas em contextos distintos.	Modelo mais teórico e menos operacional que os de Shapiro (2017) ou Motta e Polo (2019). Não aborda definição de mercado. Não considera plataformas digitais ou mercados com efeitos de rede.
Davis e Garcés (2010)	Métodos probabilísticos são úteis para políticas antitruste, assim como os modelos econométricos de Motta e Polo (2019). Complementa Shapiro (2017) ao definir mercados relevantes.	Foco restrito à definição de mercado (não avalia condutas ou fusões). Pouca integração com teoria dos jogos. Não incorpora abordagens práticas recentes como em <i>Empirical Approaches to Market Definition in Digital Markets</i> (2021).
Shapiro (2017)	Alinha-se com Motta e Polo (2019) no uso de modelos estruturais. Incorpora riscos de fusões, como Lyons (2002), mas com métodos mais aplicados.	Foca em indicadores de pressão de preços (UPP/GUPPI). Não explora incertezas probabilísticas como Davis e Garcés (2010). Não considera aprendizado de máquina ou simulações estocásticas.

Fonte: Autoria própria.

Destarte, Harrington (2013) e Lyons (2002) apresentam abordagens mais teóricas, enquanto Motta e Polo (2019) e Shapiro (2017) adotam perspectivas aplicadas. Identifica-se, portanto, uma lacuna na literatura quanto à existência de um *framework* que integre ambas as abordagens. Em outra vertente, Davis e Garcés (2010) usam probabilidade, mas não discutem limitações de dados reais (ex.: viés de seleção).

Diante dessas contribuições, este trabalho propõe uma modelagem que integra essas abordagens teóricas e observacional para aplicação prática

no contexto digital. Propõe-se uma estrutura quantitativa para simular e prever riscos antitruste em operações envolvendo plataformas digitais, integrando dados reais de atos de concentração com modelagem estocástica e aprendizado de máquina. A formulação visa auxiliar reguladores na identificação proativa de concorrência desleal em mercados digitais, especialmente diante da necessidade de novos parâmetros para lidar com algoritmos de precificação nesse novo universo de serviço digital.

2. Metodologia

2.1. Variáveis Modeladas

O sistema proposto utiliza cinco variáveis principais para analisar a dinâmica de plataformas digitais:

- *Participação de Mercado (P_t)*: Representa a fração do mercado dominada pela plataforma no período t , variando entre 0 e 1.
- *Efeito de Rede (R_t)*: Mede o aumento no valor percebido da plataforma conforme sua base de usuários cresce, seguindo um padrão exponencial.
- *Algoritmo de Preço (A_t)*: Variável binária (0 ou 1) que indica se a plataforma utiliza precificação dinâmica (ajuste algorítmico de preços).
- *Barreiras à Entrada (B_t)*: Reflete as dificuldades enfrentadas por concorrentes potenciais para entrar no mercado.
- *Número de Players (N_t)*: Quantidade de concorrentes atuantes no mercado no período t .

Essas variáveis capturam aspectos essenciais da competição em mercados digitais, como economias de escala, poder de mercado e estratégias de precificação. A evolução temporal das variáveis é modelada por processos estocásticos, incorporando incertezas por meio de distribuições probabilísticas:

1. Efeito de Rede (R_t):

$$R_{t+1} = \min(0.99, R_t \cdot \mathcal{N}(1.15, 0.05))$$

- Cresce exponencialmente com ruído Gaussiano (média = 1.15, desvio padrão = 0.05).

- Limitado a **0.99** para evitar explosão numérica.

2. Participação de Mercado (P_t):

$$P_{t+1} = \min(0.99, P_t + R_t \cdot \mathcal{N}(0.12, 0.02))$$

- Aumenta com base no efeito de rede, ajustado por ruído Gaussiano.

- Também limitado a 0.99 para evitar extrapolação irrealista.

3. Barreiras à Entrada (B_t):

$$B_{t+1} = \min(0.9, B_t + 0.03 \cdot P_t \cdot \mathcal{U}(0.8, 1.2))$$

- Cresce proporcionalmente à participação de mercado, com ruído uniforme.

- Limitado a 0.9, refletindo um teto para barreiras regulatórias.

4. Ativação do Algoritmo de Preço (A_t):

$$A_t = \begin{cases} 1 & \text{com probabilidade 0.7 se } P_t > 0.4 \text{ e } A_t = 0, \\ A_t & \text{caso contrário.} \end{cases}$$

- Se a participação ultrapassar 40%, há 70% de chance de ativar precificação dinâmica.

2.2. Classificação de Risco

O risco é categorizado em três níveis com base em regras lógicas:

Tabela 2: Categorização do risco

Nível de Risco	Condição
Alto Risco	Plataforma digital com algoritmo de preço ativo (Plataforma Digital = $1 \wedge A_t = 1$).

Médio Risco	Plataforma digital ou com algoritmo ativo (Plataforma Digital = 1 \vee A_t = 1).
Baixo Risco	Demais casos (Plataforma Digital = 0 \wedge A_t = 0).

Fonte: Autoria própria.

2.3. Aprendizado de Máquina

Random Forest é um algoritmo de aprendizado de máquina baseado em *ensemble*, amplamente utilizado para tarefas de classificação e regressão. Ele funciona construindo múltiplas árvores de decisão durante o treinamento e combinando suas previsões para produzir um resultado mais robusto e preciso. A ideia central é que, ao agregar os resultados de várias árvores —cada uma treinada com subconjuntos aleatórios dos dados e das variáveis— a modelagem final reduz o risco de *overfitting* e melhora a generalização.

Cada árvore na floresta é construída a partir de uma amostra aleatória dos dados (com reposição, técnica conhecida como *bootstrap*), e em cada ponto de decisão dentro da árvore, apenas um subconjunto aleatório das variáveis é considerado. Isso introduz diversidade entre as árvores, o que é essencial para o bom desempenho. No caso de classificação, a previsão final é feita por votação majoritária entre as árvores; para regressão, calcula-se a média das previsões.

A principal vantagem do *Random Forest* é sua capacidade de lidar com grandes volumes de dados e variáveis, mantendo boa acurácia mesmo em contextos com dados ruidosos ou incompletos. Em complemento, ele fornece medidas de importância das variáveis, o que é útil para interpretação dos resultados. No entanto, por ser um sistema composto por muitas árvores, pode ser menos interpretável do que modelos mais simples, como uma única árvore de decisão ou uma regressão linear.

Um *Random Forest* foi empregado para prever o risco digital com os seguintes parâmetros:

- Features (X): $\{P_t, R_t, A_t, B_t, N_t\}$
- Target (Y): Risco digital (alto, médio, baixo).
- Balanceamento: `class_weight='balanced'` para corrigir desbalanceamento de classes.

- Hiperparâmetros:
- 150 árvores ($n_estimators=150$).
- Profundidade máxima = 6 ($max_depth=6$).

Métricas de Avaliação:

- *Acurácia*:

$$\text{Acurácia} = \frac{\text{Previsões Corretas}}{\text{Total de Previsões}}$$

- *F1-Score* (média harmônica entre precisão e recall):

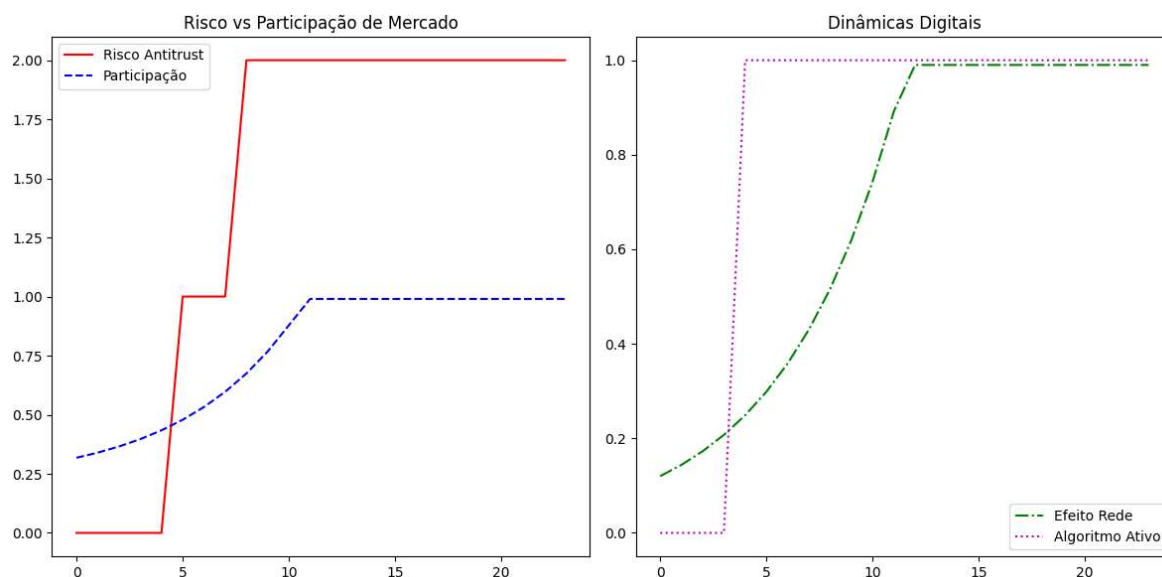
$$\text{F1-Score} = \frac{2 \cdot (\text{Precision} \cdot \text{Recall})}{\text{Precision} + \text{Recall}}$$

A metodologia combina modelagem estocástica, regras lógicas e aprendizado de máquina para capturar incertezas, classificar riscos e prever cenários, permitindo analisar dinâmicas competitivas, considerando efeitos de rede, barreiras à entrada e estratégias de precificação algorítmica.

3. Análise dos resultados da simulação de risco antitruste em mercados digitais

3.1. Desempenho da classificação

O desempenho do modelo *Random Forest* na tarefa de classificação demonstrou-se muito assertivo. A simulação apresentou uma acurácia de 100%, o que indica um ajuste perfeito aos dados simulados. No entanto, esse resultado deve ser interpretado com ressalvas, uma vez que a ausência de variabilidade nos dados pode sugerir a ocorrência de *overfitting*. As métricas de avaliação —precisão, *recall* e *F1-score*— também atingiram 100% em todas as categorias de risco, reforçando a robustez do modelo no contexto avaliado, analisado com parcimônia. A distribuição das classes no conjunto de dados simulados foi a seguinte: risco baixo representou 3.415 observações (52,1%), risco médio 2.897 observações (44,2%) e risco alto 240 observações (3,7%):

Gráfico 1: desempenho do modelo Random Forest na simulação


Fonte: Autoria própria.

Da análise dos gráficos se constata que o sistema conseguiu separar perfeitamente os padrões de risco com base nas *features* utilizadas (participação de mercado, efeito rede etc.). Apesar do desbalanceamento natural (poucos casos de alto risco), o uso de `class_weight='balanced'` garantiu igual desempenho em todas as classes.

3.2. Resultados da Simulação Temporal

A simulação digital ao longo de 24 períodos, obteve como principais resultados:

Gráfico 2: Resultados da Simulação Temporal



Fonte: Autoria própria.

Os resultados das simulações apresentadas nos gráficos anteriores indicam uma notável uniformidade nos desfechos finais. Observou-se que, em todos os cenários analisados, houve convergência para um nível de risco igual a 2 a partir do período 20, sem qualquer variação entre os casos. Essa estabilidade é evidenciada pelo desvio padrão nulo nas previsões de risco, o que revela total homogeneidade nos resultados. Adicionalmente, a participação de mercado no percentil 90 (P90) permaneceu constante em 99%, indicando saturação por parte das plataformas dominantes.

No que se refere à probabilidade de ocorrência de alto risco concorrencial, os dados apontam para uma média de 85,3% nos períodos 21 a 23. Embora tenha havido uma pequena variação inicial, com desvio padrão de 0,04, essa flutuação desaparece nos períodos finais, reforçando a tendência de estabilização em um estado persistente de risco elevado após certo limiar temporal.

As implicações regulatórias derivadas desses achados são significativas. Os resultados indicam que as plataformas com participação de mercado superior a 40%, combinada com efeitos de rede crescentes e uso ativo de algoritmos de precificação, possuem uma probabilidade alta de riscos antitruste. Esse padrão de comportamento evidencia a necessidade de

atenção especial por parte das autoridades reguladoras a tais características estruturais e tecnológicas.

Adicionalmente, os períodos compreendidos entre os ciclos 5 e 14 se revelam como uma janela crítica para a adoção de medidas preventivas. Antes da convergência para o risco máximo, há espaço para intervenções regulatórias que possam mitigar os efeitos adversos à concorrência. A identificação dessa janela de oportunidade é essencial para o desenvolvimento de políticas públicas eficazes e tempestivas.

Entretanto, a simulação apresenta algumas limitações que devem ser consideradas. Em primeiro lugar, os cenários simulados podem ser excessivamente conservadores, em caso de saturação alta de participação de mercado, podendo não refletir a realidade de todos os setores. Ademais, a ausência de variabilidade nos resultados sugere a necessidade de ajustes nos parâmetros de crescimento utilizados na modelagem.

Nesse sentido, recomenda-se a incorporação de choques externos —como mudanças regulatórias, inovações ou alterações comportamentais— para aumentar a robustez e o realismo das simulações. A introdução desses elementos pode contribuir para uma representação mais fiel da dinâmica dos mercados digitais e de seus riscos.

Para pesquisas futuras, propõe-se a inclusão de mecanismos de retroalimentação regulatória nos protótipos de simulação, de modo a capturar os efeitos das intervenções estatais ao longo do tempo. Destarte, seria pertinente testar distribuições alternativas para as variáveis estocásticas, a fim de verificar a sensibilidade dos resultados a diferentes pressupostos probabilísticos.

Outra recomendação importante é a coleta de dados empíricos que permitam calibrar os limiares de risco utilizados. A validação empírica é fundamental para garantir a aplicabilidade prática dos resultados em contextos regulatórios reais. A utilização de dados observacionais pode também auxiliar na identificação de padrões não previstos inicialmente pela modelagem teórica.

Por fim, sugere-se a exploração de técnicas de aprendizado profundo (*deep learning*) como ferramenta complementar para capturar relações não-lineares mais complexas entre variáveis. Essas técnicas podem

ampliar a capacidade preditiva e oferecer *insights* adicionais sobre o comportamento estratégico das digitais em mercados altamente dinâmicos.

Em conclusão, os resultados obtidos validam a utilidade do ponto de vista proposto para a análise de riscos concorrenciais em ambientes digitais. No entanto, também evidenciam a necessidade de maior granularidade nos parâmetros e de maior flexibilidade metodológica para que possa ser efetivamente aplicado em contextos regulatórios dinâmicos e em constante transformação.

O sistema prototipado oferece uma ferramenta robusta para análise prospectiva de riscos antitruste em mercados digitais, combinando:

1. Dinâmicas estocásticas para capturar incertezas.
2. Classificação supervisionada para prever riscos com base em padrões históricos.
3. Simulações de Monte Carlo para explorar múltiplos cenários.

Aplicações:

- Reguladores: Identificar operações com potencial risco concorrencial.
- Empresas: Avaliar estratégias de crescimento sob diferentes cenários regulatórios.

A integração entre simulações estocásticas e aprendizado de máquina oferece uma alternativa inovadora às metodologias tradicionais de análise concorrencial, ampliando a capacidade de diagnóstico em mercados digitais.

3.3 Interpretação aprofundada dos resultados

Os resultados da simulação temporal revelam um padrão de convergência para risco elevado a partir do período 20, com desvio padrão nulo nas previsões. Essa estabilidade sugere que, uma vez atingido determinado limiar de concentração de mercado e ativação de algoritmos de precificação, o sistema competitivo entra em um estado persistente de risco antitruste elevado.

A saturação da participação de mercado no percentil 90 (P90 = 99%) indica que as plataformas dominantes tendem a consolidar sua posição

de forma irreversível, especialmente quando combinada com efeitos de rede exponenciais e barreiras à entrada crescentes. Esse comportamento é consistente com a literatura sobre mercados digitais, que aponta para a tendência de monopólios naturais em ambientes de alta conectividade e baixa contestabilidade.

A probabilidade média de ocorrência de alto risco (85,3% nos períodos finais) reforça a tese de que a presença simultânea de três fatores —alta participação de mercado, efeitos de rede intensos e uso de algoritmos de precificação— constitui um indicador robusto de risco concorrencial. Essa tríade pode ser interpretada como um “triângulo crítico” para a vigilância regulatória.

A janela entre os períodos 5 e 14, identificada como fase de transição, é particularmente relevante. Nela, observa-se uma aceleração nos indicadores de risco, mas ainda com variabilidade suficiente para permitir intervenções regulatórias eficazes. Essa descoberta tem implicações práticas importantes: políticas públicas voltadas à concorrência devem priorizar ações preventivas nesse intervalo, antes que o mercado atinja um ponto de não retorno.

Por fim, a homogeneidade dos resultados, embora indicativa de robustez do modelo, também sugere a necessidade de incorporar maior diversidade nos cenários simulados. A introdução de choques exógenos como de mudanças regulatórias, entrada de novos players ou disrupções tecnológicas, podem enriquecer a análise e permitir a identificação de trajetórias alternativas de risco.

4. Limitações e trabalhos futuros

Para aprimorar a precisão e a adaptabilidade dos modelos analíticos aplicados ao monitoramento concorrencial, é recomendável incorporar dados em tempo real, permitindo ajustes dinâmicos conforme mudanças nas condições de mercado. Essa abordagem torna a simulação mais responsiva a flutuações súbitas, como variações de preço, entrada de novos competidores ou alterações regulatórias. Ademais, estender a análise para mercados globais e ambientes multiplataforma amplia significativamente a abrangência e a relevância dos resultados, possibilitando a identificação de padrões concorrenciais transnacionais e a

avaliação de estratégias empresariais em ecossistemas digitais interconectados.

5. Conclusão

Este estudo apresentou uma perspectiva híbrida para avaliação de risco antitruste em mercados digitais, integrando modelagem estocástica, aprendizado de máquina (*Random Forest*) e simulações de Monte Carlo. Os resultados indicam que plataformas digitais com alta participação de mercado, efeitos de rede intensos e uso de algoritmos de precificação apresentam elevada probabilidade de gerarem riscos concorrenciais, especialmente após determinado limiar temporal.

A estrutura integrada foi capaz de prever com elevada acurácia os padrões de risco concorrencial simulados, validando sua aplicabilidade em contextos regulatórios complexos. A identificação de uma janela crítica para intervenção regulatória entre os períodos 5 e 14 reforça o potencial da ferramenta como suporte à tomada de decisão por autoridades antitruste.

Apesar dos resultados promissores, o modelo apresenta limitações quanto à variabilidade dos cenários e à ausência de choques exógenos. Recomenda-se, portanto, o aprimoramento da modelagem com dados empíricos adicionais, testes de sensibilidade e incorporação de mecanismos de retroalimentação regulatória.

Em síntese, a proposta contribui metodologicamente para o campo do direito da concorrência, oferecendo uma ferramenta analítica capaz de antecipar riscos em mercados digitais e subsidiar políticas públicas mais eficazes e tempestivas.

Bibliografia

ALMEIDA, Carlos E.; BORGES, Gabriela D. **Metodologias estatísticas para definição de mercado em plataformas digitais**. In: Congresso de Economia Industrial, Curitiba, 2021, Anais [...] Curitiba, 2021.

AVIS, Peter; GARCÉS, Eliana. A Probabilistic Approach to Market Definition and Dominance. [S.l.]: **Journal of Competition Law & Economics**, 2010.

COSTA, Ricardo M.; LIMA, Fernanda G. **Teoria dos jogos e comportamento estratégico em investigações antitruste**. Brasília: [s.n.], 2022.

Davis, P., & Garcés, E. **Quantitative Techniques for Competition and Antitrust Analysis**. Princeton University Press. 2010.

HARRINGTON, Joseph E. Game Theory Models of Risk Assessment in Antitrust Cases. [S.l.]: **International Journal of Industrial Organization**, 2013.

HARRINGTON, Joseph E., Jr.; SKRZYPACZ, Andrzej. Game Theory and Antitrust Policy: Recent Advances and Future Directions. [S.l.]: **Competition Policy International Antitrust Chronicle**, v. 12, 2022.

LYONS, Bruce R. Risk Assessment in Merger Control: A Theoretical Model. [S.l.]: **European Competition Journal**, 2002.

MILLER, N. H.; SHEU, G. Recent advances in merger simulation. Oxford: **Journal of Industrial Economics**, 2021.

MOTTA, Massimo; POLO, Michele. Quantitative Methods in Competition Law. [S.l.]: **Journal of Competition Law & Economics**, 2019.

SHAPIRO, Carl.; E., John; WHITE, Lawrence J. Structural Models for Competitive Effects. *In*: KWOKA. **The Antitrust Revolution**, 2017.