

Estado da publicação: O preprint não foi publicado em outro meio.

O detector que ficou cego - Criptoativos, Lavagem de dinheiro e a crítica de Lucas

Jose Carlos de Souza Santos

<https://doi.org/10.1590/SciELOPreprints.18334>

Submetido em: 2026-10-06

Postado em: 2026-10-07 (versão 1)

(AAAA-MM-DD)

O detector que ficou cego

Criptoativos, lavagem de dinheiro e a crítica de Lucas

The detector that went blind: crypto assets, money laundering, and the Lucas critique

José Carlos de Souza Santos¹

Universidade de São Paulo, Faculdade de Economia, Administração, Contabilidade e Atuária, Departamento de Economia, São Paulo, SP, Brasil

Fundação Instituto de Pesquisas Econômicas (Fipe), São Paulo, SP, Brasil

ORCID: <https://orcid.org/0000-0002-5680-0264>

Preprint, versão de outubro de 2026

Resumo. Este artigo treina um detector de transações ilícitas em bitcoin com a base pública Elliptic (203.769 transações em 49 períodos de cerca de duas semanas) e mostra que seu desempenho fora da amostra entra em colapso depois do fechamento de um grande mercado da *dark web*: a taxa de detecção cai de 86% para 2% de um período para o outro, e o retreinamento com os poucos dados posteriores ao choque não a recupera. O episódio, já registrado pelos autores da base, é interpretado à luz da crítica de Lucas (1976): um detector estimado com dados do passado resume o comportamento dos agentes sob determinado regime de repressão e deixa de valer quando a própria repressão altera esse comportamento. Discutem-se as implicações para a regulação brasileira de prevenção à lavagem de dinheiro, recentemente estendida às prestadoras de serviços de ativos virtuais: a necessidade de validação contínua dos sistemas de monitoramento, a avaliação período a período em lugar de médias agregadas, a complementaridade entre algoritmos e investigação, e o custo dos alarmes falsos.

Palavras-chave: lavagem de dinheiro; criptoativos; bitcoin; crítica de Lucas; aprendizado de máquina; regulação financeira.

Classificação JEL: G28; K42; C53; E42.

Abstract. *This paper trains a detector of illicit bitcoin transactions on the public Elliptic data set (203,769 transactions over 49 time steps of about two weeks each) and shows that its out-of-sample performance collapses after the shutdown of a major dark web marketplace: the detection rate falls from 86% to 2% from one time step to the next, and retraining on the few post-shock observations does not restore it. The episode, already noted by the authors of the data set, is read through the lens of the Lucas critique (1976): a detector estimated on past data summarizes how agents behaved under a given enforcement regime and breaks down when enforcement itself changes that behavior. The paper discusses the implications for Brazilian anti-money laundering regulation, recently extended to virtual asset service providers: continuous validation of monitoring systems, period-by-period rather than aggregate evaluation, the complementarity between algorithms and investigation, and the cost of false alarms.*

Keywords: money laundering; crypto assets; bitcoin; Lucas critique; machine learning; financial regulation.

1. Introdução

Treinei um detector de transações criminosas em bitcoin. Nos testes fora da amostra, ele identificou 86% das transações ilícitas, com pouquíssimos alarmes falsos. Então, de uma quinzena

¹Professor do Departamento de Economia da FEA-USP e pesquisador da Fipe. E-mail: jcdssan@usp.br.

para a outra, passou a identificar apenas 2% das atividades classificadas como criminosas. Nada mudou no algoritmo. Mudou o mundo que ele observava: segundo os autores da base de dados utilizada, naquele momento as autoridades derrubaram um grande mercado criminoso da internet, e o comportamento de quem usava bitcoin para fins ilícitos se reorganizou.

O episódio é uma ilustração quase didática de uma ideia que completa cinquenta anos em 2026: a crítica do célebre economista, ganhador do Prêmio Nobel de Economia, Robert E. Lucas, em artigo de 1976. Relações estimadas sob um regime de política econômica deixam de valer quando o regime muda, porque os agentes econômicos reagem à própria política. No presente artigo, a "política" é a repressão ao crime, e os agentes são os que lavam dinheiro. Um detector treinado com o passado é, no fundo, um modelo econométrico de comportamento, e está sujeito à mesma fragilidade.

Este artigo apresenta o exercício e discute o que ele sugere para a regulação da prevenção à lavagem de dinheiro no Brasil, que acaba de estender suas obrigações às empresas que negociam criptoativos. Antes, porém, é preciso apresentar ao leitor um lado da internet que muitos conhecem apenas de ouvir falar.

2. O outro lado da internet

A internet que usamos no dia a dia, a dos sites de notícias, dos bancos e das lojas, é apenas a camada mais visível da rede. Uma parte muito maior, às vezes chamada de **deep web**, é simplesmente o conteúdo que os buscadores não indexam: caixas de e-mail, áreas restritas de *internet banking*, bases de dados de empresas. Nada de misterioso nisso. Já a **dark web** é outra coisa: um conjunto de sites que só podem ser acessados com programas especiais, desenhados para esconder quem visita e quem hospeda.

O mais conhecido desses programas é o Tor, sigla de *The Onion Router*. O nome vem da técnica: a conexão do usuário é "empacotada" em camadas sucessivas de criptografia, como as de uma cebola, e atravessa vários servidores intermediários espalhados pelo mundo. Cada servidor conhece apenas o anterior e o seguinte, nenhum conhece ao mesmo tempo a origem e o destino. Os sites que funcionam dentro dessa rede têm endereços terminados em ".onion" e não abrem num navegador comum, como o Google Chrome ou o Microsoft Edge. A tecnologia nasceu de pesquisas financiadas pela Marinha americana nos anos 1990 e hoje é mantida por uma organização sem fins lucrativos. Serve a jornalistas, a fontes que precisam de sigilo e a dissidentes de regimes autoritários. Serve também, evidentemente, a criminosos.

Foi nesse ambiente que surgiram os mercados da **dark web**. O pioneiro foi o Silk Road, lançado em 2011. Funcionava como um site de comércio eletrônico qualquer, com vitrines de vendedores, sistema de avaliação por estrelas e até um serviço de custódia que retinha o pagamento até o comprador confirmar o recebimento. A diferença estava no catálogo de produtos e serviços oferecidos, dominado por drogas, e no meio de pagamento: bitcoin. O FBI fechou o site em outubro de 2013 e prendeu seu fundador. Vieram muitos sucessores. O maior deles, o AlphaBay, vendia também armas, dados de cartões de crédito roubados e documentos falsos, e foi derrubado

em julho de 2017 numa operação conjunta de autoridades americanas e europeias (U.S. Drug Enforcement Administration, 2017). O desfecho teve um toque de ironia: a polícia holandesa havia assumido secretamente o controle de um mercado concorrente, o Hansa, e passou semanas monitorando os usuários que migraram para lá depois do fechamento do AlphaBay.²

3. Pseudônimo não é anonimato

Por que pagamento em bitcoin? Porque dispensa bancos. Uma transferência em bitcoin vai de um endereço a outro sem que nenhuma instituição precise conhecer os titulares. Os endereços são longas sequências de letras e números, sem nome associado.

Mas há um detalhe que muitos criminosos subestimaram. Todas as transações ficam registradas, para sempre, num livro-razão público, o *blockchain*, que qualquer pessoa pode consultar. O bitcoin não é anônimo, é pseudoanônimo: não se sabe quem é o dono de cada endereço, mas se sabe exatamente quanto passou de um endereço para outro, e quando ocorreu a transferência. Basta ligar um único endereço a uma pessoa, o que acontece, por exemplo, quando ela troca bitcoins por reais numa corretora que exige identificação, para que todo o histórico se ilumine retroativamente. Há ironia também aqui: quem escolhe o bitcoin para esconder dinheiro escolhe o meio de pagamento mais vigiado do mundo, só que vigiado por quem ainda não sabe quem é quem.

Dáí surgiu uma indústria de análise de *blockchain*, formada por empresas que rastreiam o caminho do dinheiro e vendem esse serviço a corretoras, bancos e autoridades. Lavar dinheiro em criptoativos, nesse contexto, significa embaralhar o caminho: fracionar valores, fazê-los passar por dezenas de endereços intermediários, misturá-los com dinheiro alheio. Detectar lavagem significa reconhecer esses padrões. A escala não é desprezível. Foley, Karlsen e Putniņš (2019) estimaram que, entre 2009 e abril de 2017, cerca de um quarto dos usuários e quase metade das transações em bitcoin estavam associados a atividades ilegais, proporções que chegavam a ser bem maiores antes do uso legal se popularizar, a partir de 2016.

4. A base de dados

Em 2019, uma dessas empresas, a Elliptic, tornou pública, com pesquisadores do laboratório MIT-IBM Watson AI Lab, uma base de transações reais de bitcoin preparada para pesquisa (Weber et al., 2019). São 203.769 transações e 234.355 ligações entre elas (o dinheiro que sai de uma transação e entra em outra), distribuídas em 49 períodos com intervalos de cerca de duas semanas. Cada transação é descrita por 166 atributos numéricos, deliberadamente anonimizados: sabe-se que alguns atributos dizem respeito à própria transação e outros à vizinhança dela na rede, mas não o que cada um mede.

²Os autores da base de dados usada neste artigo não identificam o mercado fechado no período 43. A associação com o AlphaBay, frequente entre os que trabalham com a base de dados aqui utilizada, é compatível com a cronologia, mas não foi confirmada.

Cada transação traz também um rótulo, atribuído pela empresa com base na natureza das entidades envolvidas. São 4.545 transações ilícitas (2,23% do total), ligadas a golpes, programas maliciosos, pirâmides financeiras, organizações terroristas e mercados da **dark web**; 42.019 lícitas (20,62%), ligadas a corretoras, carteiras e serviços legítimos; e 157.205 sem classificação (77,15%). As datas não foram divulgadas, também para preservar o anonimato. Os autores registram apenas que, no período 43, ocorreu o fechamento de um grande mercado da **dark web**.

5. O experimento

Reproduzi, neste artigo, o desenho usado pelos autores da base. O detector é treinado com as transações rotuladas dos períodos 1 a 34 (cerca de 70% da amostra) e testado nos períodos 35 a 49, que ele nunca viu. O algoritmo escolhido é a floresta aleatória (em inglês, random forest), proposta por Breiman (2001) e amplamente usada na detecção de fraudes.

A peça básica da floresta é a árvore de decisão, um roteiro de perguntas de sim ou não, parecido com o que um analista de crédito experiente segue ao examinar um pedido de empréstimo: a renda do cliente é maior que certo valor? Se for, ele tem dívidas em atraso? Se não for, tem garantias a oferecer? Cada pergunta divide as transações em dois grupos, e o computador escolhe, a cada passo, a pergunta que melhor separa as ilícitas das lícitas nos dados de treino, algo como "o atributo 12 é maior que 0,3?". Ao fim do roteiro, cada transação recebe a classificação predominante no grupo em que caiu. Uma única árvore, porém, tende a decorar as particularidades da amostra de treino e erra muito diante de casos novos. A floresta corrige esse defeito construindo centenas de árvores, cada uma a partir de um sorteio diferente das transações e dos atributos, de modo que as árvores saem diferentes entre si. A classificação final sai por "votação": se a maioria das árvores considera a transação ilícita, ela é sinalizada. É o mesmo princípio de se consultar vários especialistas independentes em vez de um só, na expectativa de que os erros individuais se compensem.³

Duas medidas resumem o desempenho. A *taxa de detecção* é a proporção das transações ilícitas que o detector sinaliza. A *precisão* é a proporção das transações sinalizadas que são de fato ilícitas; quando ela é baixa, o detector gera muitos alarmes falsos. A Tabela 1 e a Figura 1 apresentam os resultados.

Tabela 1. Desempenho fora da amostra antes e depois do período 43

Modelo e períodos	Ilícitas no teste	Detectadas	Alarmes falsos	Taxa de detecção	Precisão
Floresta aleatória, treino 1 a 34					
Teste 35 a 42	914	782	29	85,6%	96,4%
Teste 43 a 49	169	3	36	1,8%	7,7%


³Foram usadas 100 árvores, na biblioteca scikit-learn (Python). A cada pergunta de cada árvore (o que os manuais chamam de "divisão", pois ela separa as transações em dois grupos), o computador escolhe a melhor entre 50 atributos sorteados dos 165 disponíveis, que são os 166 da base menos o indicador de período. Os resultados estão em linha com os relatados por Weber et al. (2019). O código está disponível com o autor.

Modelo e períodos	Ilícitas no teste	Detectadas	Alarmes falsos	Taxa de detecção	Precisão
Regressão logística, treino 1 a 34					
Teste 35 a 42	914	677	902	74,1%	42,9%
Teste 43 a 49	169	26	816	15,4%	3,1%
Floresta aleatória retreinada com dados pós-choque					
Treino 1 a 42, teste 43 a 49	169	4	7	2,4%	36,4%
Treino 1 a 45, teste 46 a 49	116	2	0	1,7%	100%

Fonte: Elliptic Data Set (Weber et al., 2019). Elaboração própria. Apenas transações rotuladas.

Até o período 42, o detector funciona muito bem. Das 914 transações ilícitas, identifica 782 e dispara apenas 29 alarmes falsos em mais de 9 mil transações lícitas. A partir do período 43, das 169 transações ilícitas identifica apenas 3, e os alarmes que dispara são, em sua maioria, falsos. Não se trata de uma degradação gradual, como seria de esperar de um modelo que envelhece: é uma ruptura, visível no Painel B da Figura 1.

Figura 1. Transações ilícitas e acerto do detector por período



Fonte: Elliptic Data Set (Weber et al., 2019). Elaboração própria.

Um detalhe merece atenção. Se o desempenho fosse medido pela média de todo o período de teste, como é comum nos trabalhos da área, a taxa de detecção seria de 72%, um resultado respeitável. A média esconde o colapso. Quem avaliasse o sistema apenas pelo número agregado concluiria que ele funciona.

A regressão logística, um modelo alternativo de detecção de fraudes, mais simples, serve de contraste. Já em tempos normais ela é bem pior: para cada transação ilícita que encontra, dispara mais de um alarme falso. Depois do período 43 continua cega, e os alarmes falsos se multiplicam. A floresta aleatória não cega por ser sofisticada demais; qualquer detector treinado com o passado sofre o mesmo destino.

6. Por que o detector ficou cego

O Painel A da Figura 1 dá a primeira pista. O número de transações ilícitas rotuladas cai de 239 no período 42 para algo em torno de 20 nos períodos seguintes. Há, portanto, menos crime a detectar, o que é boa notícia. Mas o problema está no crime que sobrou: o detector não encontra nem esse pouco. O que restou é diferente do que havia antes. Fechado o principal mercado, os agentes mudaram de canal, de hábitos e de caminhos para o dinheiro, e os padrões que o modelo aprendeu a reconhecer deixaram de aparecer. Não seria a primeira adaptação desse tipo. Foley, Karlsen e Putniņš (2019) mostram que, quando o próprio AlphaBay passou a aceitar o Monero, criptomoeda desenhada para ser mais opaca que o bitcoin, em agosto de 2016, as transações ilícitas em bitcoin caíram em cerca de 90 mil por dia, de um total de aproximadamente 217 mil.

É exatamente o argumento de Lucas. Um modelo econométrico estimado com dados de um regime de política econômica contém, embutidas nos parâmetros, as reações dos agentes àquele regime. Quando a política muda, as reações mudam, e os parâmetros estimados passam a descrever um mundo que não existe mais. Um detector de lavagem é um modelo desse tipo: seus parâmetros resumem como os criminosos se comportavam sob determinado nível e forma de repressão. A repressão bem-sucedida, ao mudar o comportamento dos criminosos, invalida o instrumento que ajudou a combatê-los. Há parentesco também com a lei de Goodhart (1975): quando uma regularidade passa a ser usada para controle, ela tende a deixar de valer, porque os controlados se ajustam a ela.

Seria natural supor que bastasse retreinar o detector com os dados novos. A última parte da Tabela 1 mostra que não. Mesmo incluindo no treino os períodos 43 a 45, o modelo identifica 2 das 116 transações ilícitas dos períodos seguintes. O novo regime ainda não tem história suficiente para ser aprendido: são poucas dezenas de exemplos diante de milhares do regime anterior, e o algoritmo continua reconhecendo o mundo antigo. Aprender leva tempo, e, nesse intervalo, o detector não detecta. Os próprios autores da base já haviam registrado o colapso. O retreinamento ingênuo com poucos rótulos pós-choque não foi suficiente para gerar um novo detector eficiente. A literatura posterior registra melhorias com novas características e métodos de representação, mas isso não equivale a demonstrar que o problema de mudança de regime tenha sido definitivamente resolvido.

O episódio aqui relatado não testa a crítica de Lucas em seu sentido econométrico mais estrito, mas oferece uma boa aplicação de sua intuição: a intervenção altera o comportamento dos agentes e, com isso, desestabiliza a relação histórica usada pelo modelo.

O leitor com experiência em mercado financeiro reconhecerá o fenômeno. Modelos de risco estimados em períodos de calmaria costumam falhar exatamente quando mais se precisa deles, nas crises, porque a crise é um regime diferente, com correlações e comportamentos que a amostra não continha. A correlação dos retornos dos ativos de uma carteira, normalmente baixa em períodos normais, se aproxima de +1 nas crises, quando mais se precisa da diversificação de risco. O detector de lavagem de dinheiro é um modelo de risco como outro qualquer, e a mudança de regime aqui foi provocada pela própria autoridade.

7. O que isso diz à regulação

O Brasil tipifica o crime de lavagem de dinheiro desde a Lei nº 9.613, de 1998, que obriga bancos e outras instituições a identificar seus clientes e a comunicar operações suspeitas ao Conselho de Controle de Atividades Financeiras (COAF). A Lei nº 14.478, de 2022, incluiu as prestadoras de serviços de ativos virtuais no âmbito das disposições aplicáveis à prevenção e ao combate à lavagem de dinheiro. O Decreto nº 11.563, de 2023, atribuiu ao Banco Central competência para regular, autorizar e supervisionar essas prestadoras. Em 10 de novembro de 2025, o Banco Central editou as Resoluções BCB nº 519, 520 e 521, que estruturaram o regime de autorização, funcionamento e integração dessas entidades ao arcabouço financeiro e cambial brasileiro, em vigor, em sua maior parte, desde 2 de fevereiro de 2026. As corretoras de criptoativos passam a ter, portanto, deveres semelhantes aos dos bancos, e o monitoramento automatizado de transações será parte central do seu cumprimento. O exercício sugere quatro cuidados.

O primeiro é que nenhum sistema de detecção deve ser tratado como certificado de uma vez por todas. Um sistema que funcionou bem no passado pode estar cego hoje, e cego justamente depois de uma ação bem-sucedida das autoridades, quando os criminosos se reorganizam. A supervisão deveria exigir das instituições testes contínuos de desempenho, com atenção especial aos períodos que se seguem a operações policiais relevantes, mudanças regulatórias ou novos produtos.

O segundo é que esse desempenho deve ser medido período a período, e não por médias longas. Como se viu, a média do período de teste sugere um sistema razoável; os números por quinzena revelam um sistema que parou de funcionar. Relatórios de conformidade baseados em indicadores agregados podem dar uma segurança e conforto que, de fato, não existem.

O terceiro é que o algoritmo não substitui a inteligência humana nem a cooperação entre autoridades. É significativo que o golpe mais eficaz contra os mercados da **dark web**, a operação que derrubou o AlphaBay e monitorou o Hansa, tenha sido obra de investigação policial e cooperação internacional, não de um modelo estatístico. Os detectores são bons em reconhecer o crime que já conhecem; reconhecer o crime novo continua sendo tarefa de gente.

O quarto diz respeito aos alarmes falsos, e é talvez o mais econômico dos quatro. Quando o detector perde a capacidade de distinguir atividades lícitas das criminosas, a tentação é torná-lo mais sensível, e a regressão logística mostra o resultado: centenas de alarmes falsos para cada

punhado de acertos. Se a regulação punir com rigor a falha de detecção, mas não o excesso de comunicações, as instituições terão incentivo para comunicar tudo, e o COAF receberá uma avalanche de registros em que os casos relevantes se perdem entre os falsos. Um sistema de prevenção que gera ruído em excesso também é, a seu modo, um detector cego.

8. Limitações e conclusão

O exercício tem limitações que o leitor deve conhecer. Os atributos são anonimizados, de modo que não se pode dizer quais características das transações mudaram depois do período 43. Os rótulos “lícito” e “ilícito” vêm de critérios da própria Elliptic, não de decisões judiciais. As datas e o mercado fechado não foram revelados, e a identificação com o AlphaBay é provável, mas não confirmada. O período coberto é curto, a base trata apenas do bitcoin, e o número de transações ilícitas depois do choque é pequeno, o que recomenda cautela com os percentuais.

Nenhuma dessas limitações, porém, afeta o ponto central. O detector não ficou cego por deficiência técnica; ficou cego porque o mundo que ele observava mudou, e mudou em reação à própria repressão que ele deveria apoiar. Cinquenta anos depois, a crítica de Lucas continua a valer em terrenos que o autor dificilmente imaginaria. Para quem desenha a regulação dos criptoativos, a lição é que o combate à lavagem de dinheiro precisa ser tratado como um jogo entre agentes que se adaptam, e não como um problema de engenharia resolvido de uma vez por todas.

Declarações

Contribuição de autoria. José Carlos de Souza Santos é o único autor e responde pela concepção do estudo, pela análise, pela interpretação dos resultados e pela redação e revisão do texto.

Conflito de interesses. O autor declara não haver conflito de interesses.

Financiamento. Esta pesquisa não recebeu financiamento específico de agências públicas, comerciais ou sem fins lucrativos.

Disponibilidade de dados. Os dados utilizados são públicos e compõem o Elliptic Data Set (Weber et al., 2019), disponível em <https://www.kaggle.com/datasets/ellipticco/elliptic-data-set>. O código que reproduz os resultados está disponível com o autor, mediante solicitação.

Uso de inteligência artificial. O autor utilizou o assistente de inteligência artificial Claude (Anthropic) como apoio para programar e executar o exercício empírico em Python e para redigir e revisar o texto. O autor conferiu os resultados, reviu todo o conteúdo e assume integral responsabilidade por ele.

Referências

Banco Central do Brasil. Resolução BCB nº 519, de 10 de novembro de 2025. Disciplina os processos de autorização para funcionamento das sociedades prestadoras de serviços de ativos virtuais, entre outras instituições.

Banco Central do Brasil. Resolução BCB nº 520, de 10 de novembro de 2025. Dispõe sobre a constituição e o funcionamento das sociedades prestadoras de serviços de ativos virtuais e sobre a prestação desses serviços por outras instituições autorizadas.

Banco Central do Brasil. Resolução BCB nº 521, de 10 de novembro de 2025. Altera a regulamentação do mercado de câmbio e de capitais internacionais para incluir a prestação de serviços de ativos virtuais.

Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5-32.

Brasil. Lei nº 9.613, de 3 de março de 1998. Dispõe sobre os crimes de "lavagem" ou ocultação de bens, direitos e valores.

Brasil. Lei nº 14.478, de 21 de dezembro de 2022. Dispõe sobre diretrizes a serem observadas na prestação de serviços de ativos virtuais.

Brasil. Decreto nº 11.563, de 13 de junho de 2023. Regulamenta a Lei nº 14.478, de 21 de dezembro de 2022, para estabelecer competências ao Banco Central do Brasil.

Foley, S.; Karlsen, J. R.; Putniņš, T. J. (2019). Sex, drugs, and bitcoin: how much illegal activity is financed through cryptocurrencies? *Review of Financial Studies*, 32(5), 1798-1853.

Goodhart, C. A. E. (1975). Problems of monetary management: the U.K. experience. *Papers in Monetary Economics*, v. 1. Reserve Bank of Australia.

Lucas, R. E. (1976). Econometric policy evaluation: a critique. *Carnegie-Rochester Conference Series on Public Policy*, 1, 19-46.

U.S. Drug Enforcement Administration (2017). AlphaBay, the largest online "dark market", shut down. Comunicado de imprensa, 20 de julho de 2017.

Weber, M.; Domeniconi, G.; Chen, J.; Weidele, D. K. I.; Bellei, C.; Robinson, T.; Leiserson, C. E. (2019). Anti-money laundering in bitcoin: experimenting with graph convolutional networks for financial forensics. *KDD Workshop on Anomaly Detection in Finance*. arXiv:1908.02591.

Este preprint foi submetido sob as seguintes condições:

- Os autores declaram que os necessários Termos de Consentimento Livre e Esclarecido de participantes ou pacientes na pesquisa foram obtidos e estão descritos no manuscrito, quando aplicável.
- Os autores declaram que a elaboração do manuscrito seguiu as normas éticas de comunicação científica.
- Os autores declaram que estão cientes que são os únicos responsáveis pelo conteúdo do preprint e que o depósito no SciELO Preprints não significa nenhum compromisso de parte do SciELO, exceto sua preservação e disseminação.
- Os autores declaram que os dados, aplicativos e outros conteúdos subjacentes ao manuscrito estão referenciados.
- O manuscrito depositado está no formato PDF.
- Os autores declaram que a pesquisa que deu origem ao manuscrito seguiu as boas práticas éticas e que as necessárias aprovações de comitês de ética de pesquisa, quando aplicável, estão descritas no manuscrito.
- Os autores declaram que uma vez que um manuscrito é postado no servidor SciELO Preprints, o mesmo só poderá ser retirado mediante pedido à Secretaria Editorial do SciELO Preprints, que afixará um aviso de retratação no seu lugar.
- Os autores concordam que o manuscrito aprovado será disponibilizado sob licença [Creative Commons CC-BY](#).
- O autor submissor declara que as contribuições de todos os autores e declaração de conflito de interesses estão incluídas de maneira explícita e em seções específicas do manuscrito.
- Os autores declaram que o manuscrito não foi depositado e/ou disponibilizado previamente em outro servidor de preprints ou publicado em um periódico.
- Caso o manuscrito esteja em processo de avaliação ou sendo preparado para publicação mas ainda não publicado por um periódico, os autores declaram que receberam autorização do periódico para realizar este depósito.
- O autor submissor declara que todos os autores do manuscrito concordam com a submissão ao SciELO Preprints.