



Governança para definição do Score de Crédito: a participação social como instrumento de adequação do sistema

Governance For Credit Score Definition: Social Participation As An Instrument Of System Adequacy

Maique Barbosa de Souza 

Universidade do Vale do Rio dos Sinos - UNISINOS

maique.b.souza@gmail.com

Conflito de interesses: nada a declarar. Financiamento: nada a declarar.

Histórico:

Submissão | Received: 22/03/2022

Aprovação | Accepted: 28/03/2022

Publicação | Published: 31/03/2022



Resumo

A adoção de sistemas de inteligência artificial para a definição do score do risco de crédito tornou-se uma situação cada vez mais comum. No entanto, a adoção de tais sistemas, preconiza que o sistema seja adequado à sociedade para a qual será utilizado. Dessa forma, a pesquisa reflete sobre a importância de se adotar equipes multidisciplinares para a construção de sistemas de inteligência artificial de análise de crédito a fim de prover tal adequação. O problema indagou se a adoção de profissionais de áreas diversificadas para a adequada implementação do sistema de inteligência artificial de análise de crédito, com vistas a incorporar particularidades da economia local, permitirá uma melhor adequação do risco assumido em cada operação. A investigação para responder ao problema voltou-se para situações onde a análise do risco não conseguiu captar particularidades dos mercados locais, gerando inadequação na análise do risco e expondo a instituição financeira a situações indesejadas. Como conclusão da pesquisa, observou-se que a implementação de sistemas de inteligência artificial para a análise de crédito expõe a instituição financeira a novos riscos, merecendo tal situação uma estrutura de governança apropriada e dotada de instrumentos que permitam a adequação do modelo à sociedade que busca definir o risco.

Palavras-chave: Risco, Análise de crédito, Inteligência artificial

Abstract

The adoption of artificial intelligence systems to define the credit risk score has become an increasingly common situation. However, the adoption of such systems recommends the system to be suitable for the society where it will be used. In this way, the research reflects the importance of adopting multidisciplinary teams for the construction of artificial intelligence systems for credit analysis in order to provide such adequacy. The research problem refers to whether the adoption of professionals from diversified areas for the proper implementation of the artificial intelligence system for credit analysis, with a view to incorporating particularities of the local economy, will allow for a better adjustment of the risk assumed in each operation. The investigation to answer the problem focused on situations where risk analysis failed to capture particularities of local markets, generating inadequacy in risk analysis and exposing the financial institution to unwanted situations. As a conclusion of the research, it was observed that the implementation of artificial intelligence systems for credit analysis exposes the financial institution to new risks, deserving such situation an appropriate governance structure endowed with instruments that allow the adaptation of the model to the society that seeks to define the risk.

Keywords: Risk, Credit analysis, Artificial intelligence

1. Introdução

A relação dos humanos com os sistemas de inteligência artificial está contribuindo para a construção de sistemas de gestão e análise de risco de crédito de forma que a capacidade preditiva alcança patamares inimagináveis de comportamento futuro. Este potencial promete muitos benefícios relacionados à redução de custos, aumento de eficiência e alcance de mercados até então não explorados (Comissão Europeia, 2019).

Por outro lado, a adoção de tais sistemas, sejam construídos internamente ou adquiridos de empresas especializadas, preconiza que o sistema seja adequado à sociedade para o qual será utilizado, sob pena de produzir resultados equivocados justamente por reproduzir comportamento desconectado da realidade social que pretende analisar. Ao mesmo tempo, os equívocos de análise operados pelo sistema acabam por incorporar riscos não corretamente mensurados na atuação da instituição em cada operação, uma vez que o *output* raramente é contestado.

Com base nesta constatação, o presente trabalho visa apresentar reflexões iniciais sobre a importância de se adotar equipes multidisciplinares para a construção de sistemas de inteligência artificial de análise de crédito a fim de prover tal adequação. O problema indagou se a adoção de profissionais

de áreas diversificadas para a adequada implementação do sistema de inteligência artificial de análise de crédito com vistas a incorporar particularidades da economia local, permitirá uma melhor adequação do risco assumido em cada operação.

Como hipótese, afirma-se que a adoção de equipes multidisciplinares permitirá ao sistema melhor definir o risco, pois estará adequado à realidade social que se propõe a avaliar.

No que relaciona à metodologia de pesquisa, esta, se dará por meio de uma pesquisa qualitativa com abordagem crítica de pesquisas científicas e reportagens sobre a temática, baseada em livros, artigos e trabalhos acadêmicos, disponíveis online e encontrados no Portal de Periódicos da CAPES e no Google Acadêmico.

No primeiro capítulo trataremos de apresentar a revolução tecnológica ocorrida na gestão do risco de crédito e a relação da inteligência artificial com os novos riscos por ela ofertados. No segundo capítulo abordaremos os equívocos na análise de risco ocasionados por projeções sociais oriundas dos programadores, bem como a importância da incorporação de equipes multidisciplinares na construção de sistemas de análise de crédito para melhorar a definição do risco.

2. A gestão do risco de crédito no mundo 4.0

2.1 A revolução tecnológica na gestão do risco de crédito

A evolução tecnológica exerce influência sobre todos os setores da sociedade, e a gestão do

risco ligado a operações de crédito não fica alheio a estas transformações.

Nos primórdios, bastava que a instituição financeira adotasse medidas de adequação aos

regramentos, servindo tal como demonstrativo aos investidores de que o risco de crédito estava adequado, o que permitiu, inclusive, considerável evolução do sistema financeiro que precedeu a primeira revolução industrial, sendo esta possível justamente em razão dos financiamentos concedidos às fabricas (Ferguson, 2009, p. 54), criando condições para uma das maiores revoluções que a humanidade já experimentou.

Contemporaneamente, a influência tecnológica está impondo ao sistema bancário que este se remodele e incorpore sua própria revolução digital (Harreis, 2017), com a alteração de paradigma do modelo de negócio de bancos tradicionais para outros, baseado em plataformas digitais com notável expansão da relevância dada à tecnologia e aos sistemas informatizados.

Nesse sentido, o sistema bancário e a gestão do risco não se dá mais calcada em modelos baseados em percepções pessoais do gerente, mas com fundamento em modelos algoritmos de análise de dados, onde o gestor da instituição financeira exerce pouca influência no resultado do score de crédito apresentado. Tal situação impõe novos desafios aos bancos tradicionais que veem a expansão de *fintechs* em mercados antes dominado por poucas e grandes instituições. Estas financeiras baseadas em economia de plataforma estão crescendo e desafiando instituições tradicionais a se reinventar para a manutenção da competitividade. Como exemplo desse fenômeno, durante a pandemia de Covid-19 viu-se a criação e ascensão do G10 Bank, sendo este um banco digital criado em fevereiro de 2021 com capital inicial de R\$1,8 milhão, de iniciativa de um grupo de líderes empreendedores das 10 maiores favelas brasileiras que, com o objetivo de gerar impacto social e fomentar a economia para os moradores das comunidades, está criando

oportunidade de acesso ao crédito e consequentemente se inserindo rapidamente num mercado de cerca de 14 milhões de pessoas (Sayuri, 2021). Este público, ignorado por instituições financeiras tradicionais pelo histórico de score baixo, está sendo absorvido por *fintechs* que se utiliza de algoritmos de análise e cruzamento de dados capaz de melhor definir o risco de crédito na operação justamente em razão de estarem adequados à realidade do público apresentado.

A adoção de novas tecnologias tem permitido a incorporação de mais informações sobre o pretendente ao crédito, o que aproxima a instituição de uma análise do risco mais adequada e contribui para a incorporação de público antes considerado inapto para a concessão de crédito, frente o risco apresentado. Nesse sentido, a adequação de procedimentos internos em razão da adoção de novas tecnologias é fundamental para a competitividade, especialmente em mercados globalizados como o de crédito.

Assim, momentos de grande estresse na economia como o da pandemia de Covid-19, atuam por elevar o risco sistêmico, exigindo a incorporação de novas e adequadas tecnologias para a manutenção da capacidade preditiva do comportamento do consumidor.

Outro exemplo de mercado bancário interno que passa por sua própria revolução é o de Moçambique, onde instituições financeiras estrangeiras estão levando ao país toda a tecnologia já utilizada na Europa e em outros grandes centros, permitindo uma melhor adequação da análise de risco e ampliação da capacidade de expansão do mercado. Situações assim promovem verdadeiras revoluções na gestão do risco, proporcionando às instituições uma atuação mais competitiva no cenário interno e internacional. Conforme referido por Vanda Aurora Carvalho dos Santos:

[...] foram os bancos estrangeiros que trouxeram para o país toda a tecnologia existente relativamente ao crédito. Com o mercado de crédito num momento favorável, mas com níveis de risco ainda em patamares elevados, as instituições financeiras valorizam a gestão do risco de crédito, procurando novas ferramentas para avaliarem os clientes. As técnicas de avaliação de risco e de comportamento de crédito aplicadas são instrumentos importantes para os bancos ampliarem os ativos em crédito (Santos, 2020, p. 33).

Dessa forma, a revolução tecnológica experimentada pelo mercado financeiro altera as estruturas tradicionais e impõe a necessidade de adequação nos procedimentos internos a fim da manutenção do risco sistêmico controlado, ao mesmo tempo em que contribui para a elevação da competitividade em um mercado especialmente acirrado como o de crédito.

2.2 A inteligência artificial e os novos riscos incorporados

A inclusão de novos sistemas de inteligência artificial na dinâmica de definição do risco de crédito permite à instituição financeira a redução de custos de transação e de assimetria informacional, o que contribui para gerar a impressão de que se alcançou a eficiência necessária à manutenção do risco sistêmico controlado. Ao mesmo tempo, tais sistemas também atuam por elevar o risco já suportado na atuação da instituição no mercado. Esta elevação do risco é observada quando a instituição financeira não é capaz de compreender o funcionamento interno do sistema e, assim, acaba por assumir risco não pretendido. Esta situação, a despeito de parecer incomum, ocorre em diversas oportunidades, especialmente em sistemas

que buscam fazer análise preditiva do comportamento, ocasião em que a correlação das informações e a atribuição de valor às variáveis depende de fatores que não são facilmente compreendidos.

Assim, o risco operacional entendido como aquele correspondente à probabilidade de ocorrência de impactos negativos nos resultados devido a falhas na análise efetuada no processamento das operações ou devido a fraudes, acaba sendo potencializado por outro que permeia todas as atividades da instituição, oriundo da adoção de sistemas de inteligência artificial que podem induzir o tomador de decisão em erro em razão de resultados equivocados na análise e definição do risco em cada operação. Dessa forma, “a inovação tecnológica tem sido uma grande preocupação que influencia este risco” (Saunders, 2008) e pode esconder desajustes de análise que tendem a gerar prejuízos à instituição, além de elevação do risco sistêmico.

Importante referir que a inteligência artificial é sempre apresentada como um instrumento com capacidade superior e quase infalível, o que resulta na utilização do viés de confirmação pelo tomador de decisão (Lidén, 2018). Este processo ocorre justamente em razão da ausência de conhecimento sobre o funcionamento do sistema que leva o ser humano a crêr que o output exarado pelo sistema é incontestável. Importante característica que contribui para este fenômeno é aspecto de caixa preta (Pasquale, 2015) comum nos algoritmos de inteligência artificial que impedem o conhecimento sobre o processo interno operado, afastando o tomador de decisão da máxima eficiência esperada. Por outro lado, inúmeros erros têm sido observados, sendo estes mais comuns do que se esperava. Ao buscar retratar a realidade complexa das relações humana por meio de fórmulas matemáticas, os algoritmos de

inteligência artificial vêm demonstrando erros e tendências que comprometem o objetivo de sua implementação (O'neil, 2016), revelando a necessidade de um acompanhamento constante em sua utilização diária. Lembra-se que os sistemas atuam em termos probabilísticos e não determinísticos (Entsminger, 2018, p. 72), e que por serem construídos por humanos carregam consigo toda a carga humana de vieses e heurísticas de pensamentos, o que demonstra que estão sujeitos a erros e preconceitos (Future of Life Institute, 2017) em suas bases.

Os erros de análise, portanto, não são incomuns e justamente em razão da importância que o crédito assume na sociedade contemporânea, sendo fator constitutivo da noção de pertencimento (Berquó, 2013), é que autoridades internacionais, como o Parlamento Europeu, vêm estabelecendo regulações (Parlamento Europeu, 2017) no sentido de se reconhecer a transparência como princípio orientador dos sistemas de inteligência artificial, especialmente a fim de que seja possível fundamentar a decisão automatizada que possa ter um impacto substancial sobre a vida de uma ou mais pessoas, inclusive com os passos e as informações utilizadas para a tomada de decisão. No mesmo sentido, Dierle Nunes e Ana Luiza Marques referem que “[...] é essencial que se tenha um elevado grau de transparência algorítmica, a fim de possibilitar que os afetados pelo modelo saibam o que determina o resultado alcançado pelo sistema de IA” (Nunes & Marques, 2018, p. 421).

Considerando esta dificuldade de compreensão dos resultados exarados pelo sistema, o *Financial Stability Board* (FSB), órgão constituído para coordenar em nível internacional o trabalho das autoridades financeiras nacionais e dos organismos internacionais que estabelecem normas para desenvolver e promover a implementação de estruturas regulatórias, de supervisão e outras políticas do setor financeiro refere, em estudo de 2017, que:

[...] o uso de algoritmos complexos pode resultar em falta de transparência para os consumidores. [...] Esses algoritmos podem classificar um mutuário de uma minoria étnica com maior risco de inadimplência porque mutuários semelhantes tradicionalmente recebem condições de empréstimo menos favoráveis² (Financial Stability Board, 2017).

Assim, é possível observar uma atuação do sistema dissonante daquela esperada, onde, em vez de reduzir o risco à instituição financeira na operação de crédito, acaba por elevá-lo em razão de apresentar resultado do score que não representa a realidade. Dessa forma, algumas medidas para a observação e correção destes erros devem ser adotadas, a fim de proporcionar melhor comunicação com o pretendente ao crédito, bem como a correta definição do risco em cada operação.

² No original “[...] the use of complex algorithms could result in a lack of transparency to consumers. This ‘black box’ aspect of machine learning algorithms may in turn raise concerns. When using machine learning to assign credit scores make credit decisions, it is generally more difficult to provide consumers, auditors, and supervisors with an explanation of a credit score and resulting credit decision if challenged. Additionally, some argue that the use of new alternative data sources, such as online behaviour or non-traditional financial information, could introduce

bias into the credit decision. Specifically, consumer advocacy groups point out that machine learning tools can yield combinations of borrower characteristics that simply predict race or gender, factors that fair lending laws prohibit considering in many jurisdictions. These algorithms might rate a borrower from an ethnic minority at higher risk of default because similar borrowers have traditionally been given less favourable loan conditions.” Tradução nossa. (FSB, 2017).

3. Governança na construção de IA do sistema como primeiro passo na correta definição do risco

3.1 Os equívocos na análise de risco ocasionados por projeções dos programadores

Os programadores exercem papel crucial na construção dos sistemas de inteligência artificial. Estes atuam como projetores da realidade que será observada e avaliada pelo sistema ao mesmo tempo em que fazem parte deste mesmo contexto social. Ao atribuírem valores às variáveis do sistema, estarão definindo o próprio futuro da instituição financeira, pois isto definirá quem será o cliente bom e o ruim para a concessão de crédito. Nesse sentido, a relação entre as instruções de entrada e o resultado exarado pode sofrer influência direta de valores inseridos nos códigos de programação, ainda que de forma inconsciente pelos desenvolvedores do sistema. Dessa forma, se aqueles que participam da construção do sistema de inteligência artificial “[...] não forem cuidadosos, o processo poderá resultar em decisões desproporcionalmente adversas concentradas dentro de grupos desfavorecidos de forma que se parecem muito com discriminação”³ (Barocas & Selbst, p. 673).

Assim, no processo de preenchimento e lacuna das variáveis, o programador faz uma escolha, com o objetivo de permitir à máquina que ela alcance a abstração necessária para que possa encontrar na situação analisada parâmetros que correspondam àqueles já informados. Sendo assim, se não for observado

determinados cuidados, os sistemas de inteligência artificial, quando do processo de análise interna, poderão herdar características alicerçadas em vieses ou preconceitos oriundos da visão de mundo dos programadores, o que invariavelmente produzirá decisões equivocadas, que atuam por estabelecer o risco para a instituição financeira deslocado da realidade.

Outra situação de apresentação de risco que não corresponde à realidade que pode ser atribuído à inteligência artificial se dá quando da adoção de modelos de sistemas baseados em redes neurais, ocasião em que muitas vezes nem mesmo os programadores conseguem explicar os resultados. As redes neurais atuam como num sistema de feedback que pode alterar até mesmo as informações iniciais, adquirindo, assim, o sistema, certo grau de autonomia em relação às instruções iniciais. Neste caso, quando da definição do score de risco, se a análise categorizar o pretendente ao crédito conforme determinados preconceitos presentes na concepção social do programador, estará elevando o risco para a instituição financeira que poderá tomar decisões equivocadas, e terá sua carteira de crédito desencaixada do risco esperado (BCBS, 2004).

Alguns exemplos de preconceitos históricos incorporados ao sistema pelos humanos podem ser observados em estudos que apontam que ainda que façam parte da elite econômica com alta renda, os negros nos EUA

³ No original “[...] are not careful, the process can result in disproportionately adverse outcomes concentrated within

historically disadvantaged groups in ways that look a lot like discrimination”. Tradução nossa. (BAROCAS e SELBST, p. 673).

recebem menos informações para acesso ao crédito, além de taxas de juros mais altas quando comparados a pretendentes brancos (Ross & Yinger, 2002). Ocasão idêntica é observada com hispânicos que chegam a ter 82% mais chances de rejeições para o crédito quando comparados a brancos com características semelhantes (Pager & Shepherd, 2008).

Situações como estas merecem atenção, pois produzem erros na definição do risco que pode ocasionar prejuízos financeiros e com potencial de desestabilizar todo o sistema financeiro, ante a massiva adoção de algoritmos para a definição do score de risco de crédito. Algumas medidas, no entanto, podem ser adotadas para mitigar tal equívoco, sendo uma delas a adoção de equipes multidisciplinares na construção do sistema, situação que abordaremos no tópico a seguir.

3.2 A incorporação de equipes multidisciplinares na construção de sistemas de análise de crédito para melhor definição do risco

Consoante observado, alguns fatores podem gerar risco inadequado à instituição financeira quando da definição do score de risco de crédito. No entanto, uma medida que pode servir para a mitigação de tais riscos é aquela capaz de aproximar o sistema do público que se pretende que seja definido o risco. Neste processo de aproximação, entende-se que sistemas projetados e construídos somente por profissionais da computação não é capaz de absorver as particularidades sociais e corretamente definir o risco em cada operação. Assim, situações pontuais, específicas da cultura local em que o sistema será implementado podem ser relevantes e devem ser consideradas e incorporadas no sistema desde sua concepção para corretamente definir

a pontuação de crédito e, assim, constatar o verdadeiro risco assumido para que seja possível a extração do máximo de eficiência de cada operação.

Situação exemplificativa deste problema é aquela relacionada a pagamentos em dinheiro, onde o consumidor não contribui para informar o sistema de análise de crédito e, conseqüentemente, acaba por possuir risco desconectado da realidade pela ausência de informações relevantes. Em razão do pagamento não ser captado pelo sistema de gestão do risco e definição do score, acaba não contribuindo para a elevação da nota e conseqüente redução do risco, situação esta, que pode atuar como desestímulo à tomada de crédito pelo pretendente em razão de seu elevado custo. Também, para a instituição financeira o risco é deslocado, pois terá em sua carteira pessoas que não representam a realidade do risco assumido nas operações de crédito.

Em situações assim podem ser incluídos pessoas jovens, imigrantes e até mesmo a população inteira de países em que a tecnologia não se encontra em estágio avançado. Podemos observar como exemplo da influência da cultura local na construção do score de crédito, o que ocorre nos Estados Unidos, onde somente no ano de 2006, cerca de 54 milhões de cidadãos não possuíam dados suficientes para a completa definição do score de crédito (Turner, 2006), em razão de optarem por meios alternativos de pagamento como o dinheiro. Esta situação toma especial relevância e deve ser concebida pelo sistema de inteligência artificial de análise de crédito desde sua origem para que dali se extraia a maior eficiência na medida em que em países menos desenvolvidos a situação tende a ser mais acentuada, pois a população muitas vezes não tem acesso a mecanismos modernos de pagamento, sendo que, quando muito,

possuem conta corrente. O Brasil não passa ao largo deste problema, pois possui situação parecida como demonstrou a pesquisa de 2019 do Instituto Locomotiva, onde cerca de 45 milhões de brasileiros não possuíam conta bancária, número este que equivale a um terço da população acima de 16 anos, sendo que este grupo movimentava aproximadamente R\$817 bilhões por ano (Meiros, 2019). Importante salientar que esta situação não torna o pretendente ao crédito ruim, mas apenas gera pouca visibilidade para a instituição financeira, pois seus sistemas não estão preparados para corretamente definir o risco apresentado, fazendo com que haja uma desconformidade entre o risco apresentado e o real. Assim, a instituição acaba perdendo a oportunidade de contratar e obter o resultado positivo da operação em razão do erro apresentado pelo sistema. Um estudo (The Nielsen Company, 2016) apresentado pela empresa Nielsen no ano de 2016 demonstrou que na Índia aproximadamente 83% da população - ou seja, mais de um bilhão de pessoas - adota o sistema de pagamento mediante entrega. O mesmo estudo revela que este tipo de pagamento também é bastante comum em países como Colômbia (57%), Polônia (57%), Tailândia (56%), Emirados Árabes Unidos (68%), Arábia Saudita (59%), Nigéria (76%), Filipinas (73%), e Rússia (70%). Da mesma forma no Brasil, em estudo divulgado em 2018 pelo Banco Central, pode-se verificar que aproximadamente 96% dos brasileiros utilizam dinheiro em espécie para pagar alguma despesa ou fazer compras. O mesmo estudo demonstra que 60% da população adota o dinheiro como forma de pagamento mais utilizada (Banco Central do Brasil, 2018). Assim, os dados destas operações acabam não sendo considerados para a definição do score de crédito justamente pela dificuldade dos sistemas de captarem tais informações, o que demonstra a relevância da

participação de profissionais de outras áreas do conhecimento para que a referida situação possa ser corretamente absorvida quando da concepção do sistema de inteligência artificial a fim de alcançar sua real definição do score de risco de crédito.

Lembra-se que a principal virtude da correta pontuação de crédito é sua capacidade preditiva, ou seja, seu potencial de atuar como ferramenta de apoio à decisão ao demonstrar o risco adequado de um pretendente ao crédito, merecendo destaque informações financeiras, especialmente quando estas não são incorporadas ao sistema. Dessa forma, profissionais como sociólogos, historiadores, profissionais do direito, geólogos e psicólogos, entre outros, podem contribuir na construção dos parâmetros a serem informados à inteligência artificial, a fim de proporcionar uma aproximação do sistema ao público objeto de análise, bem como melhor absorver as peculiaridades locais tão significativas para a verdadeira representação do risco de crédito.

Assim, a incorporação de profissionais de outras áreas do saber na concepção dos sistemas de inteligência artificial para a definição do score de risco, permite à instituição financeira mitigar este tipo de risco com a aproximação do sistema à realidade social que pretende analisar, o que tende à uma melhora na definição do risco. Por seu turno, a correta definição do risco permitirá à instituição a apropriação de valor ainda não incorporado pelos equívocos do sistema com a absorção de mercados subavaliados sem a necessidade de assunção de risco maior, além de ter seu risco devidamente mensurado em cada situação. Isto contribui para a instituição, mas agrega valor especialmente ao sistema financeiro, uma vez que gera estabilidade e segurança a todos os envolvidos.

4. Considerações Finais

A evolução tecnológica impõe a necessidade de adoção de sistemas de inteligência artificial que sejam capazes de contribuir no processo de tomada de definição para a concessão de crédito. Nesse sentido, a delegação da análise e definição do risco para estes sistemas merece atenção especial, pois definem o futuro da própria instituição financeira.

A despeito da redução de tempo, custos e assimetria informacional proporcionada pela inteligência artificial, a adoção de tais sistemas, sejam construídos internamente ou adquiridos de empresas especializadas, tem demonstrado equívocos de análise na definição do score de risco, em razão da inadequação para a sociedade que pretende analisar.

Dessa forma, a pesquisa buscou apresentar reflexões iniciais sobre a importância de se adotar equipes multidisciplinares para a incorporação de sistemas de inteligência artificial de análise de crédito. O problema questionou se a adoção de profissionais de áreas diversificadas para a adequada implementação do sistema de inteligência

artificial de análise de crédito com vistas a incorporar particularidades da economia local, permitirá uma melhor adequação do risco assumido em cada operação.

Assim, a partir da metodologia que orientou a pesquisa, observou-se que ao incorporar profissionais como psicólogos, historiadores, sociólogos, entre outros, há uma tendência de aproximação das características definidas como relevantes dentro do sistema àquelas apresentadas pela sociedade analisada. Dessa forma, as variáveis tendem a se aproximar do comportamento esperado pelo consumidor, apresentando uma definição de risco mais fiel à realidade de cada operação.

Dentro desse contexto, se observou que a adequação interna com tais procedimentos melhora o risco assumido pela instituição financeira, agregando-lhe competitividade e proporcionando a incorporação de mercados até então subavaliados. Outrossim, estas medidas também contribuem para todo o sistema financeiro, uma vez que atuam por reduzir o risco sistêmico.

BIBLIOGRAFIA

- Barocas, S. & Selbst, A. (2016). *Big Data's Disparate Impact*. California Law Review, 2016. Recuperado de https://papers.ssrn.com/sol3/papers.cfm?abstract_id=2477899.
- Banco Central do Brasil. (2018). *O brasileiro e sua relação com o dinheiro*. Banco Central do Brasil. Recuperado de https://www.bcb.gov.br/content/cedulasemoedas/pesquisabrasileirodinheiro/Apresentacao_brasileiro_relacao_dinheiro_2018.pdf.
- BCBS. (2004). *Basel II: International Convergence of Capital Measurement and Capital Standards: a Revised Framework*. Basel Committee on Banking Supervision. Basileia. Recuperado de <https://www.bis.org/publ/bcbs107.htm>.
- Berquó, A. (2013). *O crédito na sociedade de consumo*. (Tese de Doutorado). Programa de Pós-Graduação em Sociologia da Universidade Federal da Paraíba.
- Comissão Europeia. (2019). *Excelência e confiança na inteligência artificial*. Recuperado de https://ec.europa.eu/info/strategy/priorities-2019-2024/europe-fit-digital-age/excellence-trust-artificial-intelligence_pt#benefcios-da-inteligencia-artificial.
- Entsminger, J., Esposito, M., Tse, T. & Goh, D. (2018). *What Governments need to understand about ethical AI*. The European Business Review September. Recuperado de <https://www.europeanbusinessreview.com/what-governments-need-to-understand-about-ethical-ai/>
- Ferguson, N. (2009). *A ascensão do dinheiro: a história financeira do mundo; tradução Cordelia Magalhães*. São Paulo: Editora Planeta do Brasil.
- Future of Life Institute. (2020). *What makes people happy?* Recuperado de <https://www.youtube.com/watch?v=z1N96In7GUc>.
- Financial Stability Board. (2017). *Artificial intelligence and machine learning in financial services - Market developments and financial stability implications*. Recuperado de <https://www.fsb.org/2017/11/artificial-intelligence-and-machine-learning-in-financial-service/>.
- Harreis, H. (2017). *The future of risk management in the digital era*. Mckynsey & Company, 2017. Recuperado de <https://www.mckinsey.com/business-functions/risk/our-insights/the-future-of-risk-management-in-the-digital-era>.
- Lidén, M. (2018). *Confirmation Bias in Criminal Cases*. [Doctoral Thesis]. Uppsala University, SE-75120 Uppsala, Sweden. Recuperado de <http://uu.diva-portal.org/smash/record.jsf?pid=diva2%3A1237959&dswid=686>.

BIBLIOGRAFIA

- Meireles, R. (2018). Um em cada três brasileiros não tem conta em banco, mostra pesquisa Locomotiva. Recuperado de <https://www.ilocomotiva.com.br/single-post/2019/09/24/um-em-cada-tr%C3%AAs-brasileiros-n%C3%A3o-tem-conta-em-banco-mostra-pesquisa-locomotiva>.
- Nunes, D. & Marques, A. (2018). Inteligência Artificial e Direito Processual: vieses algorítmicos e os riscos de atribuição de função decisória às máquinas. *Revista dos Tribunais online. Revista de Processo*, vol. 285, 421–447.
- O’neil, C. (2016). *Weapons of Math Destruction: How Big Data Increases Inequality and Threatens Democracy*. New York: Crow.
- Pager, D. & Shepherd, H. (2008). *The Sociology of Discrimination: Racial Discrimination in Employment, Housing, Credit, and Consumer Markets*. Annual Review of Sociology. Princeton University Library. New Jersey. Recuperado de 10.1146/annurev.soc.33.040406.131740.
- Parlamento Europeu. (2017). *Resolução do Parlamento Europeu*, de 16 de fevereiro de 2017, que contém recomendações à Comissão sobre disposições de Direito Civil sobre Robótica (2015/2103(INL)). Princípios éticos. Recuperado de https://www.europarl.europa.eu/doceo/document/TA-8-2017-0051_PT.html#title1.
- Pasquale, F. (2015). *The black box society: The Secret Algorithms That Control Money and Information* Harvard University Press, 2015.
- Ross, S. & Yinger, J. (2002). *The Color of Credit: Mortgage Discrimination, Research Methodology, and Fair-lending Enforcement*. Cambridge. The MIT Press.
- Santos, V. (2020). *Gestão De Risco De Crédito Bancário - Caso Do Banco Comercial E De Investimentos (BCI, S. A)*. [Master Thesis]. Instituto Universitário de Lisboa. Recuperado de <https://repositorio.iscte-iul.pt/handle/10071/22452>.
- Saunders, A. (2008). *Financial Institutions management: a risk management approach*. 6ª Ed. McGraw-Hill/Irwin, 2008. Recuperado de http://www.bulentsenver.com/FIN5477/Financial_Institutions_Management_AntonySaunders_TextBook.pdf.
- Sayuri, J. (2021). O que é o G10 Bank. E qual é seu papel na pandemia. *Nexo Jornal*, 2021. Recuperado de <https://www.nexojornal.com.br/expresso/2021/02/05/O-que-%C3%A9-o-G10-Bank.-E-qual-%C3%A9-seu-papel-na-pandemia>.

BIBLIOGRAFIA

- The Nielsen Company. (2016). Estudo Global: Comércio Conectado. Recuperado de <https://www.nielsen.com/br/pt/insights/report/2016/estudo-global-comercio-conectado-2/#>.
- Turner, M. (2006). *Give Credit Where Credit Is Due: Increasing Access to Affordable Mainstream Credit Using Alternative Data*. Political and Economic Research Council and The Brookings Institution Urban Markets Initiative. Recuperado de https://www.perc.net/wp-content/uploads/2013/09/alt_data.pdf