

## **ÁREA TEMÁTICA 6 FIN: FINANÇAS**

### **TÍTULO:**

**ANÁLISE DO *SCORE* DE CRÉDITO NO MERCADO BRASILEIRO À LUZ DA *BIG DATA* E DA NOVA LGPD**

## **RESUMO:**

O aumento, exponencial, da coleta de dados pessoais permitiram às empresas privadas e às entidades públicas a sua utilização, nas mais variadas finalidades, em uma escala sem precedentes. Os indivíduos são induzidos a ceder as suas informações, contribuindo na transferência e na livre circulação desses dados, como moeda de troca, para organizações nacionais e internacionais. De posse desses dados, empresas que operam com o Score de crédito conseguem angariar informações do histórico financeiro e, com isso, classificar as pessoas, através de rótulos, em “maus ou bons” pagadores. Neste contexto, o presente estudo propõe analisar como o sistema de Score de crédito pode ser impactado pelo uso de big data e pela nova LGPD, bem como sua influência em relação as empresas que operam com crédito e com os tomadores de crédito. Este trabalho foi desenvolvido com base em 411 respondentes utilizando a plataforma Google Forms para explorar essas relações. As regressões logísticas foram realizadas com o auxílio do software SPSS® com a metodologia Forward Conditional. Em relação a análise por meio do ponto de vista das empresas, foram utilizados quatro modelos inéditos que buscaram analisar as relações no uso do Score de crédito; o custo/benefício em sem usar o Score de crédito; a prática da LGPD no uso do Score de crédito; e as relações entre Score de Crédito, Big Data, LGPD e empréstimos/vendas. Em relação aos tomadores de crédito, foram utilizados dois modelos, também inéditos, que buscaram entender as relações, tanto do endividamento quanto da tomada de crédito. No estudo foi possível verificar a eficiência dos modelos. Apesar da complexidade inerente a cada conceito, é importante observar que estes relacionamentos são recentes, contudo, com a certeza de uma futura consolidação. Sendo assim, este trabalho pode contribuir e proporcionar um melhor entendimento acerca do sistema de Score de crédito.

## **Palavras-chave:**

*Big Data*, Empresas de crédito, LGPD, Score de Crédito, Tomador de crédito.

## **ABSTRACT:**

The exponential increase in the collection of personal data allowed private companies and public entities to use it, for the most varied purposes, on an unprecedented scale. Individuals are induced to give up their information, contributing to the transfer and free circulation of such data, as a bargaining chip, to national and international organizations. With this data, companies that operate with the credit Score can gather information from the financial history and, therefore, classify people, through labels, into “good or bad” payers. In this context, this study proposes to analyze how the credit Score system can be impacted using big data and the new LGPD, as well as its influence on companies that operate with credit and with credit borrowers. This work was developed based on 411 respondents using the Google Forms platform to explore these relationships. Logistic regressions were performed with the use of the software SPSS® with the Forward Conditional methodology. Regarding the analysis through the point of view of companies, four new models were used that sought to analyze the relationships in the use of credit Scores; the cost / benefit ratio without using the credit Score; the practice of LGPD in the use of credit Scores; and the relationship between Credit Score, Big Data, LGPD and loans / sales. In relation to borrowers, two models were used, also unprecedented, which sought to understand the relationships between indebtedness and borrowing. In the study it was possible to verify the efficiency of the models. Despite the complexity inherent to each concept, it is important to note that these relationships are recent, however, with the certainty of future consolidation. Therefore, this work can contribute and provide a better understanding of the credit Score system.

## **Keywords:**

Big Data, Credit Companies, LGPD, Credit Score, Credit Borrower

## 1. INTRODUÇÃO

De acordo com Simon (2013), não existem dúvidas que a sociedade está gerando e consumindo uma grande quantidade dos mais diferentes tipos de dados. Neste contexto, o grande desafio das organizações não está em receber dados para analisar, e sim em obter informações relevantes que auxiliem a tomada de decisões em meio ao enorme volume de dados disponíveis.

Observado por Akerkar (2014), as empresas que utilizam análises de *Big Data* devem estar atentas aos desafios oriundos do ciclo de vida dos dados: incertezas sobre os próprios dados, dificuldades em seu processamento e preocupações sobre a sua gestão. As incertezas circulam em torno de seu volume, veracidade, velocidade, variedade, valor, volatilidade e visualização. O processamento de dados inclui técnicas relacionadas a obtenção, armazenamento, limpeza e transformação dos dados existentes, selecionando o modelo correto de apresentação de resultados. Arruda (2019) comenta que nessas análises, as empresas certamente irão se deparar com dados pessoais, impelindo a aplicação de princípios básicos e legais com relação à privacidade.

Recentemente, no Brasil, entrou em vigor a LGPD (Lei Geral de Proteção de Dados – Nº 13.709/2018), fortemente influenciada pelo Regulamento Geral de Proteção de Dados da União Europeia<sup>1</sup>, sendo uma lei que regula as atividades de tratamentos de dados, alterando também os artigos 7º e 16 do Marco Civil da Internet (Lei Nº 12.965/2014). A legislação tem por fundamentação um conjunto de novos conceitos como, por exemplo, dados pessoais e dados sensíveis, que estabelecem as condições em que os dados pessoais deverão ser tratados.

Nesse contexto, a Lei Geral de Proteção de Dados - LGPD, terá enorme repercussão na forma com que empresas tratam e compartilham as informações de seus clientes, pois foi elaborada com propósitos bem definidos: instituir limites, fixar princípios e estabelecer parâmetros de conformidade para que o relacionamento entre as empresas e os clientes seja o mais transparente e seguro possível.

Essa grande quantidade de informações pessoais que circulam no mundo digital e as contínuas e rápidas mudanças tecnológicas, pelas quais as sociedades modernas atravessam, fazem com que as empresas acabem por se submeter ao uso dos dados, como moeda de troca. Lançando mão desses dados, conseguem angariar informações do histórico financeiro e, com isso, classificar, imputando rótulos, como “maus ou bons” pagadores, conforme aponta Khashman (2011). Os “maus pagadores” com *Scores* baixos, teriam dificuldades na hora da concessão de crédito, e aqueles que são ditos como “bons pagadores” alçariam maiores *Scores* obtendo maior credibilidade na hora de buscar por recursos financeiros. Todo o histórico fica registrado em um sistema de classificação de crédito, conhecido como Cadastro Positivo<sup>2</sup>.

Mesmo parecendo um cadastro inofensivo, feito para auxiliar a redução do risco para as empresas que disponibilizam crédito, até que ponto o *credit Score*, por meio de seus algoritmos de tratamento de dados, rotulando os tomadores de crédito, estará apto a aplicar o direito de revisão dessas decisões automatizadas? Esse cadastro,

---

<sup>1</sup> *General Data Protection Regulation*; GDPR ou RGPD – conjunto de normas de proteção à privacidade criado pela União Europeia (UE) desde o dia 25 de maio de 2018.

<sup>2</sup> Reúne informações sobre como têm sido pagos os compromissos relacionados à contratação de crédito – empréstimos, financiamentos e crediários, por exemplo. Passam a constar no histórico do CPF os totais financiados, quantidades e valores das parcelas, bem como o comportamento e a pontualidade de pagamento demonstrados pelo consumidor.

cuja base de dados é objeto de tratamento, poderia provocar dificuldades para a obtenção de crédito para aqueles que, porventura, já estiveram classificados como “maus pagadores”? O *credit Score* realmente teria transparência frente ao titular dos dados?

Visando encontrar respostas acerca das perguntas supracitadas, o presente artigo propõe realizar uma análise sobre como o sistema de *Score* de crédito pode ser impactado pelo uso de *big data* e pela nova LGPD, bem como sua influência em relação as empresas que operam com crédito e com os tomadores de crédito.

## 2. REFERENCIAL TEÓRICO

### 2.1. *Score* de crédito

Chiavenato (2004), afirma que a maior parte da supervivência social depende de uma certa interação social do ser humano, na qual surgem as compras de bens e imóveis, prestações de serviços, entretenimentos, relações sociais e interações com o poder público. Segundo Mucelin (2018), a relação de consumo é evidente e direta, sendo que um indivíduo fornece algo e a outra pessoa compra e/ou aproveita por motivo de necessidade pessoal. E, em grande parte dessas transações, essa outra pessoa não dispõe de grande quantidade monetária para efetuar a aquisição, carecendo de crédito.

O termo *Score* de crédito, de acordo com Yang (2007), refere-se à aplicação de meio matemático, em sua vertente probabilística, para avaliar e pontuar o indivíduo consumidor que por assim deseja obter o crédito (empréstimo), levando em conta as suas características pessoais e profissionais, resultando em um sistema de pontuação, que recebe também os nomes de “*credit scoring*”<sup>3</sup> ou “*behavior scoring*”.

O’Neil (2016) enfatiza que nesta era marcada pela *internet* e *big data* deve-se questionar quais serão os impactos que estes modelos de classificação e pontuação de crédito atuarão nos indivíduos tomadores de crédito e em toda uma sociedade nos próximos anos. Em princípio, os algoritmos utilizados pelas empresas de *Score* de crédito apresentam vantagens e utilidades para os indivíduos, no entanto, por serem regidos com critérios pouco conhecidos, podem trazer à tona impactos negativos à sociedade, gerando uma desigualdade e tornando-se um tipo de instrumento de controle social (Pasquale, 2016).

O’Neil (2016) critica que nesta sociedade “algorítmica”, os impactos relacionados e causados por estes modelos matemáticos de *Score* não podem ser considerados ferramentas neutras. A autora menciona que estes modelos estão orientados pela visão arraigada de quem os criou, ou seja, muitos preconceitos podem ter sido reforçados por critérios subjetivos. Essas aplicações matemáticas empoderam a economia de dados, já que estes algoritmos são segredos poderosos que visam gerar lucros a algumas empresas e estão salvaguardados pela Lei N<sup>o</sup>12.414/2011, em conjunto com a LCP N<sup>o</sup>166/2019, que disciplina a formação e consulta a banco de dados com informações de adimplemento, de pessoas naturais ou de pessoas jurídicas, para formação de histórico de crédito, cujas fórmulas matemáticas e seus modelos estatísticos não precisam ser divulgados.

#### 2.1.1. Modelos de *Score* de crédito no Brasil

---

<sup>3</sup> Expressão numérica baseada em uma análise de nível dos arquivos de crédito de uma pessoa, para representar a capacidade creditícia de um indivíduo.

Atualmente, existem quatro birôs autorizados pelo Banco Central que aplicam o *Score* de crédito nos indivíduos: o SPC Brasil, o Serasa *Experian*, o Boa Vista e o Quod. Cada um deles possui a própria fórmula para elaborar a nota, além de convênios com diversas redes de lojas, instituições financeiras e prestadoras de serviços.

O SPC (Serviço de Proteção ao Crédito) é de responsabilidade da SPC Brasil, fundado em 1955 e constituindo o primeiro serviço com a finalidade de garantir a proteção de crédito no país. A estrutura de banco de dados é constituída pelas CDL (Câmaras de Dirigentes Lojistas) de todo o território nacional, armazenando dados e acumulando informações sobre todos os consumidores junto ao comércio.

A empresa Boa Vista Serviços administra, desde 2010, o SCPC (Serviço Central de Proteção ao Crédito). O novo banco de dados foi criado devido a instituições financeiras não estarem satisfeitas com o antigo serviço (SPC). Esta cisão resultou no consórcio da Associação Comercial de São Paulo (ACSP), do fundo brasileiro de investimentos TMG Capital, do Clube Diretores Lojistas do Rio de Janeiro, da Associação Comercial do Paraná e da Câmara de Dirigentes Lojistas de Porto Alegre. (Boavista, 2020)

A Quod nasceu da união dos cinco maiores bancos em atuação no país, com o intuito de impulsionar o Cadastro Positivo no Brasil. Por ser uma empresa nativa em *Big Data* e inteligência artificial, a plataforma criada é capaz de produzir correlações e análises setenta e cinco vezes mais rápido do que a concorrência, com garantia de segurança das informações. (Quod, 2020)

Conforme verificado nas páginas oficiais dos birôs de crédito, a classificação do *Score* de crédito se dá de maneira semelhante, diferindo apenas em como o *Score* é formulado, visto que diferentes birôs apresentam diferentes resultados. Sua classificação é baseada na pontuação do Cadastro Positivo, variando entre 0 e 1000 pontos.

Esse *Score* de crédito, através do Cadastro Positivo, cuja inclusão é automática, é elaborado por meio de inúmeras informações cadastrais públicas existentes, tanto positivas quanto negativas, tais como: pagamentos, investimentos, protestos, pendências bancárias, ações judiciais e informações de dados sensíveis como: endereço, idade, sexo. Essa métrica é utilizada pelos órgãos de proteção de crédito para auxiliar as instituições financeiras a traçarem um perfil de risco dos tomadores de recursos e oferecem as oportunidades de crédito mais adequadas. Cada um desses múltiplos dados são analisados de forma peculiar e particular por cada instituição. Os *Scorecards* incluem bases comportamentais<sup>4</sup>, com base nos pagamentos, características de empréstimo, dados financeiros, demografia, a disponibilidade de dados do *bureau*<sup>5</sup> de crédito e a natureza do tipo de negócio (Dean Caire, 2004).

A aprovação de crédito é uma decisão das empresas e não dos birôs de crédito, na qual as empresas avaliam a sua pontuação como parte do processo da liberação de crédito. No mercado brasileiro, a pontuação do *Score* é dividida em três faixas:

- *Score* entre 701 e 1.000 pontos: baixo risco de inadimplência;
- *Score* entre 301 e 700 pontos: médio risco de inadimplência; e
- *Score* entre 0 e 300 pontos: alto risco de inadimplência.

---

<sup>4</sup> Modelos comportamentais que preveem a probabilidade de inadimplência.

<sup>5</sup> Serviço de informações de crédito, que utiliza informações de adimplência e inadimplência de pessoas físicas ou jurídicas para fins de decisão sobre crédito.

Com isso surge o seguinte questionamento: esses modelos matemáticos são utilizados, de forma transparente e justa, no Brasil como sistemas para concessão ou negação de crédito? Diante de alguns indivíduos tomadores de recursos que não obtiveram seus créditos aprovados e das inúmeras ações judiciais, o Superior Tribunal de Justiça “deu nascimento” aos temas 710 e 915.

A tese firmada pelo Superior Tribunal de Justiça é a de que, na avaliação de risco do crédito, há de ser respeitado os limites determinados pelo sistema de proteção ao consumidor no sentido da tutela da privacidade e na máxima transparência nas relações de negócios, conforme a previsão do Código de Defesa do Consumidor e da Lei Nº12.414/2011.

Além da preservação no que tange a privacidade das informações, caso o indivíduo consumidor requeira esclarecimentos sobre os critérios utilizados, a instituição não poderá negar-se a informar. Contudo, como ressaltou Cavalcanti (2018), o consumidor não terá direito a saber a metodologia do cálculo, qual a sua fórmula matemática e os dados estatísticos utilizados para pontuação do “*credit scoring*”. Isso porque a fórmula é fruto de estudos e investimentos, constituindo assim segredo da atividade empresarial. Esse sigilo advém do direito ao sigilo empresarial, previsto na parte final do art. 5º, IV, da lei Nº 12.414/2011.

Cabe salientar que o indivíduo consumidor não precisa autorizar a utilização desse sistema para buscar seu crédito perante as instituições devidamente autorizadas, ainda assim, uma vez que utilizado o critério, desponta para o indivíduo consumidor o acesso as informações que foram utilizadas, bem como dados econômicos, valores pessoais, histórico de compras, dentre outros.

Como consultado no STJ (2014), o Ministro Paulo Sanseverino aponta que a conduta desrespeitosa da instituição que analisa o crédito, desfavorecendo o consumidor, configura abuso de direito (art.187 do Código Civil - Também comete ato ilícito o titular de um direito que, ao exercê-lo, excede manifestamente os limites impostos pelo seu fim econômico ou social, pela boa-fé ou pelos bons costumes), ensejando a sua responsabilidade objetiva e solidária com o consulente, ou seja, pessoa natural ou jurídica que acesse as informações contidas em banco de dados para a finalidade permitida pela Lei do Cadastro Positivo.

## **2.2. Big Data**

Varian (2006), economista-chefe do Google e professor emérito da Universidade da Califórnia em Berkeley, nos faz refletir que os dados valem muito, sendo considerados o ouro da atualidade e um dos assuntos mais amplamente difundidos na ciência, na prática e notoriamente presente em mais de 70% dos artigos acadêmicos (Pospiech e Felden, 2013). Esses dados, devido a capacidade de serem preditivos e prescritivos, podem colocar uma determinada organização em vantagem competitiva, através da capacidade de antever situações e com isso dispor de decisões mais assertivas.

De acordo com Cooney (2012), seja na ciência, TI, na administração ou na prática, quando se trata de *Big Data*, grandes expectativas se engendram nas possibilidades em armazenamento, processamento e análise de dados, em especial nas indústrias com uso intensivo de dados como no entretenimento, nas telecomunicações, na saúde, nas engenharias, nos serviços financeiros, entre outros. Os dados que compõem a *Big Data* são oriundos de variadas fontes, não

apresentando uma estrutura definida, portanto não seria compatível armazená-la em sistemas de banco de dados padrões, como o SGBDR<sup>6</sup>.

Logo, os cientistas notaram que esses bancos não suportariam essa imensa massa de dados não estruturados e desenvolveram um modelo de programação (*MapReduce*<sup>7</sup>, criado pela *Google*) que permitisse processar essa enorme quantidade de dados. Subsequentemente, foi desenvolvido o *Hadoop* (que é uma implementação do *MapReduce*), sendo, atualmente, o tipo de processamento mais utilizado por empresas que trabalham com a *Big Data*.

### **2.2.1. Big Data como mecanismo de mudança no Score de crédito**

Sob o ponto de vista da Analytics10 (2020), a *Big Data* na área financeira é um setor com altas expectativas, posto que as instituições financeiras criam perfis dos clientes tomadores de crédito para uma melhor individualização de preços, ofertas de produtos e uma melhor avaliação do alcance da credibilidade.

As soluções tecnológicas que alcançam robustas bases de dados tornam-se o foco de investimento dessas instituições, referenciando o conceito de *Big Data*, na qual o gerenciamento e armazenamento não podem ser feitas por meios computacionais tradicionais, conforme dito por Manyika *et al.* (2011). Sendo assim, a sua utilização para mensurar o *Score* de crédito também é aplicada. Logo, os indivíduos que possuírem uma boa pontuação no *Score* de crédito poderão obter acesso à empregos, moradias, serviços essenciais, obtenção de crédito em bancos, entre outros.

Segundo Hurley e Adebayo (2017), o advento da *Big Data* como forma de tratamento de dados para aferir o *Score* de crédito dos indivíduos trouxe uma certa preocupação para os tomadores de crédito, devido às incertezas de como são feitas essas “pontuações” e se teriam a capacidade de contestação caso eles fossem imprecisos, tendenciosos ou injustos ao efetuar uma avaliação de uma determinada pessoa.

### **2.3. LGPD (Lei Geral de Proteção de Dados)**

De acordo com o estudo de Filho (2013), o advento das tecnologias da informação, a partir das décadas de 60 e 70, foi fator responsável pela origem da legislação nessa área. O autor infere que o aumento do poder de controle e de processamento de dados desencadeou uma demanda por legislação específica para a regulação da coleta e manuseio dessas informações pessoais.

Os avanços tecnológicos trouxeram uma intensa geração de fluxo de negócios, inúmeras trocas de informações e, em consequência, mudaram o cenário dos negócios digitais, que atravessaram transformações ao que se refere à proteção de dados. O que antes era comum, como inúmeras empresas vendendo banco de dados (perfis de clientes), atualmente com a então promulgada LGPD, conhecida como a Lei Geral de Proteção de Dados Nº13.709/2018, traz em seu bojo aspectos visando o *compliance* da lei no que tange o assunto da preservação dos direitos dos cidadãos sobre seus dados, sob a pena de incorrer em responsabilidade.

---

<sup>6</sup> Sistema Gerenciador de Banco de Dados Relacional – onde os dados são representados por meio de tabelas, com inúmeras linhas e colunas.

<sup>7</sup> Modelo de programação desenhado para processar grandes volumes de dados em paralelo, dividindo o trabalho em um conjunto de tarefas independentes.

Considerando este cenário, Bulos (2014) abarcou uma definição muito precisa a respeito dos direitos, consubstanciando ao fato de perfazer um conjunto de normas que promovesse uma convivência harmoniosa entre os indivíduos da sociedade, dando importância as suas condições pessoais individuais, ou seja, o respeito e o consentimento com o trato dos seus dados. Cabe ressaltar que, nos moldes de Mendes e Branco (2017), os direitos fundamentais possuem grande relevância em um contexto social, pois é através deles que há o reconhecimento que o indivíduo tem direitos em relação ao Estado, bem como seus respectivos deveres.

Inúmeras empresas lucram com os dados dos indivíduos, utilizando indevidamente e vazando-os, como, por exemplo, em 2015 o escândalo envolvendo a *Cambridge Analytica* e o *Facebook*, na qual a empresa obteve acesso aos dados coletados de um aplicativo (*thisisyourdigitalife*<sup>8</sup>) da referida rede social, e de antemão sabia seus nomes, profissões, endereços, preferências, seus interesses políticos e sua rede de contatos, ou seja, foram expostos sem ao menos ter conhecimento disso. De posse dessa gama de dados, a empresa traçou perfis, na qual sugeria que tipo de propaganda seria mais eficaz para persuadir uma pessoa em particular e influenciar na eleição da presidência de Donald Trump.

Gomes (2019), nesse contexto, identificou em seus estudos que, visando a privacidade, adveio a Lei Geral de Proteção de Dados, na qual regras foram implementadas, tanto para pessoas físicas quanto as jurídicas, para legislar sobre a segurança e a privacidade de dados, regulamentando e fiscalizando o modo como as empresas coletam, armazenam e utilizam os dados que foram coletados. Para sua criação, a maior inspiração veio da GDPR (*General Data Protection Regulation*). (Marinho, 2019).

### **2.3.1. Score de crédito à luz da nova LGPD**

Oliva e Viégas (2019) retratam que o Superior Tribunal de Justiça, embora reconheça que o *Credit Score* não constitua especificamente um banco de dados, fomenta que seja duvidoso que os dados estatísticos que constituam a fórmula dependam dos dados pessoais para se tornarem operantes e, em consequência disso, não se possa evitar a análise da origem e qualidade dos dados alimentados por esse sistema à luz da LGPD.

Cortazio (2019) complementa que, mesmo diante dessas técnicas e modelos no que diz respeito ao tratamento com os dados pessoais, a Lei Geral de Proteção de Dados veio para fortalecer na proteção do indivíduo tomador de crédito, imputando deveres e assegurando o *compliance* da lei, permitindo o acesso livre sobre a forma de tratamento de dados pelo sistema *credit scoring*, conforme o art. 6º, IV da LGPD.

O art. 9º da LGPD comenta que o titular dos dados possui direito de acessar seus dados, que deverão ser disponibilizados de forma clara e objetiva, abarcando, entre outros aspectos, a finalidade específica do tratamento, a identificação do controlador e as informações de contato do controlador. (Oliva e Viégas, 2019)

Bessa (2011) menciona que, ao deter o conhecimento dos dados do tomador de crédito, se possua uma finalidade de segurança para a financeira de acordo com o grau de confiança no indivíduo envolvido. Esse sentido de confiança envolvido está diretamente atrelado as informações que se detém sobre ele, assim sendo, quanto menor o conhecimento envolvido, maior seria o risco de crédito e quanto mais

---

<sup>8</sup> Tradução (essa é sua vida digital), aplicativo disponibilizado na rede social do *Facebook* para recolhimento de dados pessoais.

informações reunidas sobre determinada pessoa, melhor as instituições financeiras poderiam dispor de taxas mais vantajosas.

### 2.3.2. Principais estudos relacionados

Sendo a LGPD uma lei recente, estudos anteriores que relacionem, na mesma pesquisa, *Big Data* e *Score* de Crédito com a primeira são pouco recorrentes. Contudo, estudos relacionando *Big Data* e *Score* ou LGPD e *Score* já se mostram relevantes. Abaixo, um compêndio dos principais estudos acerca dos três principais pilares, *Big Data*, *Score* de Crédito e LGPD, que embasam esta pesquisa.

Goulart (2016), em seu trabalho, correlaciona *Score* de crédito e *Big Data*, perfazendo uma reflexão em direção a uma concepção renovada dos arquivos de consumo<sup>9</sup>. O autor inicia o estudo com o relato das insuficiências da teoria tradicional dos arquivos de consumo frente às novas tecnologias de processamento dados.

Este artigo encontra semelhança ao estudo de Nogueira (2020), retratando aspectos acerca de *Big Data*, LGPD e *Credit Score*, confrontando tratamento de dados com o poder que o indivíduo tomador de crédito possui sobre seus próprios dados e o direito que lhe é assegurado em revisar as decisões automatizadas. Relaciona, também, as dificuldades para a obtenção de crédito daqueles que estão classificados como “maus pagadores”, bem como as dificuldades de transição entre as categorias.

Diferentemente da pesquisa desenvolvida por Nogueira (2020), cuja essência dogmática, através de uma corrente teórica, traz o debate para o crescimento das diferenças sociais e econômicas que surgem devido a categorização do indivíduo, este trabalho tenta equilibrar a parte conceitual com a parte empírica, de modo a comparar as concepções teóricas com as observações do cotidiano dos atores<sup>10</sup> envolvidos, de forma a responder à pergunta de pesquisa proposta.

## 3. METODOLOGIA E BASE DE DADOS

Este trabalho tem a intenção de estudar os aspectos dos lojistas/empresas e dos tomadores de crédito. Para isso, foi realizado um questionário, por meio de um formulário *Google Forms*, para armazenar informações e constituir uma base de dados composta por 411 respondentes.

Para a verificação dos lojistas/empresas, serão propostos quatro modelos inéditos, desenvolvidos pelos autores neste estudo, que buscam analisar as relações no uso do *Score* de crédito, o custo/benefício em sem usar o *Score* de crédito, a prática da LGPD no uso do *Score* de crédito, e as relações entre *Score* de Crédito, *Big Data*, LGPD e empréstimos/vendas.

No modelo 1 (uso de *Score* pelo ponto de vista da empresa) são utilizadas as variáveis independentes tais quais a agilidade a ser percebida pelo empresa na utilização do *Score*, a assertividade em relação ao uso do *Score* de crédito em relação ao empréstimo ou parcelamento que, porventura, foi liberado, a segurança que a empresa deduz na utilização do *Score* de crédito, a credibilidade que a empresa percebe em relação ao *Score* de crédito, a facilidade de utilização do crédito e o preço pago pelo serviço de *Score* de crédito, como pode ser visto na equação 1.

---

<sup>9</sup> Têm como única função orientar os fornecedores de produtos e serviços no que se refere à concessão de crédito no mercado de consumo, de forma que os respectivos associados mensurem os riscos envolvendo tal atividade. Como por exemplo: SPC, SERASA, CCF, CADIN etc.

<sup>10</sup> No contexto da *Big Data*, LGPD e *Score* de crédito, os atores são: empresários, lojistas e consumidores.

$$Y_{Uso\ Score\ Cred} = \alpha + \beta_1 Agilidade + \beta_2 Assertividade + \beta_3 Seguran\c{c}a + \beta_4 Credibilidade + \beta_5 Facilidade + \beta_6 Pre\c{c}o\ do\ Servi\c{c}o + \varepsilon \quad Eq. (1)$$

No modelo 2 (custo/benefício observado pela empresa), as variáveis independentes são o valor pago por parte da empresa para uso do *Score* de crédito, o treinamento dos funcionários que a empresa deve fornecer, o aumento ou a redução da inadimplência que possa ter ocorrido na empresa e o aumento ou redução da venda parcelada, como observado na equação 2.

$$Y_{Custo\ x\ Benef} = \alpha + \beta_1 Valor\ Pago + \beta_2 Treinamento + \beta_3 Aumt\ Inadm + \beta_4 Red\ Inadm + \beta_5 Aumt\ Vend\ Parcel + \beta_6 Red\ Vend\ Parcel + \varepsilon \quad Eq. (2)$$

O modelo 3 (prática da LGPD com relação dos dados cadastrados) utiliza como variáveis independentes a segurança dos dados cadastrados, o treinamento de funcionários, o investimento na segurança dos dados e os do vazamento de dados, como representado na equação 3.

$$Y_{Pr\c{a}tica\ LGPD} = \alpha + \beta_1 Seg\ Dados\ Cad + \beta_2 Treinamento\ Func + \beta_3 Invest\ Seg\ Dados + \beta_4 Vazamento\ de\ Dados + \varepsilon \quad Eq. (3)$$

No modelo 4 (influência do *Score* comparando com o uso de *Big Data* e LGPD) as variáveis independentes são, respectivamente, o aumento e/ou redução da inadimplência, o aumento e/ou redução da venda parcelada, como pode ser visto na equação 4.

$$Y_{Score\ Cred} = \alpha + \beta_1 Big\ Data + \beta_2 LGPD + \beta_3 Aumt\ Inadm + \beta_4 Red\ Inadm + \beta_5 Aumt\ Vend\ Parcel + \beta_6 Red\ Vend\ Parcel + \varepsilon \quad Eq. (4)$$

Após a análise para com as empresas, na verificação dos tomadores de crédito serão utilizados dois modelos, também desenvolvidos pelos autores, de forma inédita, neste trabalho, que são as relações, tanto no endividamento quanto na tomada de crédito, analisados sobre a ótica do endividamento e da tomada de crédito.

O modelo 5 (o que pode potencializar o endividamento do tomador de crédito), busca avaliar o que estaria aumentando nesse endividamento. As variáveis independentes são a facilidade de crédito, parcelamento de contas, aumento salarial, quantidade de cartões de crédito, quantidade de contas bancárias, quantidade de dívidas ativas e se o nome não está negativado junto aos birôs de crédito.

$$Y_{Endividamento} = \alpha + \beta_1 Fac\ de\ Cred + \beta_2 Parcel\ de\ Cont + \beta_3 Aum\ Sal + \beta_4 Qnt\ Cart\ de\ Cred + \beta_5 Qnt\ Conta\ Banc + \beta_6 Qnt\ Divida\ Ativa + \beta_7 Nome\ Limpo + \varepsilon \quad Eq. (5)$$

No modelo 6 (influência na tomada de crédito), tem como variáveis independentes o conhecimento que o tomador de crédito possui sobre o que é *Score* de crédito, o entendimento acerca do cálculo do *Score* de crédito, não se confundindo com o entendimento da metodologia específica, haja vista que o algoritmo está salvaguardado pelo segredo comercial, se há confiança nas empresas, ou seja, se ela é idônea, se há confiança na segurança dos dados pelos das empresas, a facilidade de obtenção de crédito, os valores parcelados e a consulta no Serasa/SPC.

$$Y_{Tomada\ de\ Cred} = \alpha + \beta_1\ Conhec\ Score\ Cred + \beta_2\ Entend\ Calc\ Score\ Cred + \beta_3\ Conf\ Empresa + \beta_4\ Conf\ Seg\ Dados + \beta_5\ Fac\ de\ Cred + \beta_6\ Valores\ Parcel + \beta_7\ Consulta\ Serasa/SPC + \varepsilon \quad Eq. (6)$$

Para o desenvolvimento dos modelos propostos neste estudo, foram utilizadas regressões binárias (*logit*). Para a análise dos dados coletados, será utilizada a metodologia quantitativa, cujas análises econométricas por meio das regressões foram desenvolvidas por meio do *software* estatístico SPSS®, nas quais as variáveis dependentes categóricas tiveram assinaladas como categoria de referência o valor *não*, transformado em valor numérico zero. O método empregado é o *Forward Stepwise (Conditional)*, em que as comparações são feitas entre vários modelos completos e um único modelo reduzido, no qual a inclusão das variáveis é a de menor consumo computacional. (Charnet *et al.*, 1999)

#### 4. RESULTADOS

Para os lojistas/empresas que possuem somente dívidas contraídas pela pessoa jurídica, conforme a tabela 1, apenas os modelos 1 e 3 apresentaram variáveis dependentes com coeficientes estatisticamente significativos. Para o modelo 1, sob o prisma do que parece ser ruim, na percepção dos que usam ou não *Score* de crédito, a etapa 1, com variável independente Credibilidade, tornou a regressão válida, tendo um qui-quadrado de valor 8,799, igual ao valor do bloco sem as preditoras, e Sig (0,003) < 0,05, com R<sup>2</sup> Nagelkerke de 18,8% e Verossimilhança com 68,895. Ainda no modelo 1, para etapa 2, na qual a variável independente Agilidade foi inserida, formando par com a variável independente Credibilidade, o qui-quadrado apresentou valor 8,530, em comparação à etapa anterior, juntamente com o valor Sig (0,003) < 0,05, R<sup>2</sup> Nagelkerke com 34,5% de explicação e Verossimilhança de 60,364 para as variáveis independentes. Entretanto, os valores de significância dos coeficientes na etapa 2 foram superiores a 5%. Já no modelo 3, do ponto de vista daquilo que possa inibir o uso da LGPD, a variável independente Investimento na Segurança dos Dados validou a regressão, tendo um qui-quadrado de valor 4,976, em comparação ao bloco sem covariáveis, com Sig (0,026) < 0,05, R<sup>2</sup> Nagelkerke com 10,8% e Verossimilhança de 74,905 para a variável independente.

**Tabela 1:** Lojistas/empresas que possuem somente dívidas contraídas pela pessoa jurídica.

<b>Coefficientes do Modelo 1</b>					
$Y_{Uso\ Score\ Cred} = \alpha + \beta_1\ Agilidade + \beta_2\ Assertividade + \beta_3\ Seguran\ca + \beta_4\ Credibilidade + \beta_5\ Facilidade + \beta_6\ Pre\c{o\ do\ Servi\c{o} + \varepsilon$					
<b>Método Forward</b>	<b>Variáveis</b>	<b>B</b>	<b>Sig.</b>	<b>95% C.I. Exp(B)</b>	
				<b>Inf.</b>	<b>Sup.</b>
Etapa 1	Credibilidade	-2,721**	0,015	0,007	0,594
Etapa 2	Agilidade	39,724	0,998	0,000	.
	Credibilidade	-21,323	0,999		
<b>Coefficientes do Modelo 3</b>					
$Y_{Prática\ LGPD} = \alpha + \beta_1\ Seg\ Dados\ Cad + \beta_2\ Treinamento\ Func + \beta_3\ Invest\ Seg\ Dados + \beta_4\ Vazamento\ de\ Dados + \varepsilon$					
<b>Método Forward</b>	<b>Variáveis</b>	<b>B</b>	<b>Sig.</b>	<b>95% C.I. Exp(B)</b>	
				<b>Inf.</b>	<b>Sup.</b>
Etapa 1	Invest_Seg_Dados	-1,617**	0,048	0,040	0,988

\*p<0.10; \*\*p<0.05 e \*\*\*p<0.01

Fonte: Elaborado pelos autores.

Nos demais modelos (2 e 4) referentes aos lojistas/empresas que possuem somente dívidas contraídas pela pessoa jurídica, pode ser visto na tabela 2 que nenhuma variável dependente obteve coeficientes com influência significativa.

**Tabela 2:** Lojistas/empresas que possuem somente dívidas contraídas pela pessoa jurídica.

<b>Coeficientes do Modelo 2</b>					
$Y_{Custo \times Benf} = \alpha + \beta_1 Valor \ Pago + \beta_2 Treinamento + \beta_3 Aumt \ Inadm + \beta_4 Red \ Inadm + \beta_5 Aumt \ Vend \ Parcel + \beta_6 Red \ Vend \ Parcel + \varepsilon$					
Método Forward	Variáveis	B	Sig.	95% C.I. Exp(B)	
				Inf.	Sup.
Etapa 1	Red_Inadm	24,247	0,997	0,000	.
Etapa 2	Red_Inadm	37,907	0,995	0,000	.
	Aumt_Vend_Parcel	37,005	0,996	0,000	.
Etapa 3	Valor_Pago	36,154	0,998	0,000	.
	Red_Inadm	39,323	0,997	0,000	.
	Aumt_Vend_Parcel	2,315	1,000	0,000	.
Etapa 4	Valor_Pago	38,505	0,997	0,000	.
	Red_Inadm	40,779	0,996	0,000	.
<b>Coeficientes do Modelo 4</b>					
$Y_{Score \ Cred} = \alpha + \beta_1 Big \ Data + \beta_2 LGPD + \beta_3 Aumt \ Inadm + \beta_4 Red \ Inadm + \beta_5 Aumt \ Vend \ Parcel + \beta_6 Red \ Vend \ Parcel + \varepsilon$					
Método Forward	Variáveis	B	Sig.	95% C.I. Exp(B)	
				Inf.	Sup.
Etapa 1	Red_Inadm	24,247	0,997	0,000	.
Etapa 2	Red_Inadm	37,907	0,995	0,000	.
	Aumt_Vend_Parcel	37,005	0,996	0,000	.

**Fonte:** Elaborado pelos autores.

Para os lojistas/empresas que possuem dívidas contraídas pelas pessoas jurídica e física concomitantemente, apesar de existir interação entre a variável dependente com as variáveis independentes nos modelos 1 e 3, nenhuma variável dependente obteve coeficientes com influência significativa, conforme a tabela 3.

**Tabela 3:** Lojistas/empresas que possuem dívidas contraídas pelas pessoas jurídica e física

<b>Coeficientes do Modelo 1</b>					
$Y_{Usa \ Score \ Cred} = \alpha + \beta_1 Agilidade + \beta_2 Assertividade + \beta_3 Seguran\c{c}a + \beta_4 Credibilidade + \beta_5 Facilidade + \beta_6 Pre\c{c}o \ do \ Servi\c{c}o + \varepsilon$					
Método Forward	Variáveis	B	Sig.	95% C.I. Exp(B)	
				Inf.	Sup.
Etapa 1	Assertividade	-22,239	0,999	0,000	.
<b>Coeficientes do Modelo 3</b>					
$Y_{Prática \ LGPD} = \alpha + \beta_1 Seg \ Dados \ Cad + \beta_2 Treinamento \ Func + \beta_3 Invest \ Seg \ Dados + \beta_4 Vazamento \ de \ Dados + \varepsilon$					
Método Forward	Variáveis	B	Sig.	95% C.I. Exp(B)	
				Inf.	Sup.
Etapa 1	Red_Inadm	24,247	0,997	0,000	.
Etapa 2	Red_Inadm	37,907	0,995	0,000	.
	Aumt_Vend_Parcel	37,005	0,996	0,000	.
Etapa 3	Valor_Pago	36,154	0,998	0,000	.
	Red_Inadm	39,323	0,997	0,000	.
	Aumt_Vend_Parcel	2,315	1,000	0,000	.

**Fonte:** Elaborado pelos autores.

Os modelos 2 e 4, referentes aos lojistas/empresas que possuem dívidas contraídas pelas pessoas jurídica e física concomitantemente, não obtiveram resultados de interação entre a variável dependente com as variáveis independentes.

Para os tomadores de crédito que possuem apenas dívidas contraídas por pessoa física, apesar de existir interação entre a variável dependente com as variáveis independentes nos modelos 5 e 6, nenhuma variável independente obteve coeficientes com influência significativa, conforme a tabela 4.

**Tabela 4:** Tomadores de crédito que possuem apenas dívidas contraídas por pessoa física.

<b>Coeficientes do Modelo 5</b>					
$Y_{Endividamento} = \alpha + \beta_1 \text{Fac de Cred} + \beta_2 \text{Parcel de Cont} + \beta_3 \text{Aum Sal} + \beta_4 \text{Qnt Cart de Cred} + \beta_5 \text{Qnt Conta Banc} + \beta_6 \text{Qnt Divida Ativa} + \beta_7 \text{Nome Limpo} + \varepsilon$					
Método Forward	Variáveis	B	Sig.	95% C.I. Exp(B)	
				Inf.	Sup.
Etapa 1	Qnt Cart de Cred	21,881	0,995	0,000	.
Etapa 2	Fac de Cred	21,140	0,995	0,000	.
	Qnt Cart de Cred	21,336	0,995	0,000	.
Etapa 3	Fac de Cred	21,631	0,994	0,000	.
	Qnt Cart de Cred	21,473	0,994	0,000	.
	Qnt Divida Ativa	21,626	0,995	0,000	.
Etapa 4	Fac de Cred	21,434	0,994	0,000	.
	Qnt Cart de Cred	21,421	0,993	0,000	.
	Qnt Conta Banc	20,757	0,994	0,000	.
	Qnt Divida Ativa	22,134	0,995	0,000	.
Etapa 5	Fac de Cred	21,394	0,993	0,000	.
	Qnt Cart de Cred	21,732	0,993	0,000	.
	Qnt Conta Banc	20,769	0,994	0,000	.
	Qnt Divida Ativa	22,535	0,995	0,000	.
Etapa 6	Nome Limpo	21,560	0,997	0,000	.
	Fac de Cred	21,497	0,993	0,000	.
	Aum Sal	20,785	0,997	0,000	.
	Qnt Cart de Cred	22,009	0,993	0,000	.
	Qnt Conta Banc	21,035	0,993	0,000	.
	Qnt Divida Ativa	22,511	0,995	0,000	.
	Nome Limpo	21,793	0,997	0,000	.
<b>Coeficientes do Modelo 6</b>					
$Y_{Tomd de Cred} = \alpha + \beta_1 \text{Conhec Score Cred} + \beta_2 \text{Entend Calc Score Cred} + \beta_3 \text{Conf Empresa} + \beta_4 \text{Conf Seg Dados} + \beta_5 \text{Fac de Cred} + \beta_6 \text{Valores Parcel} + \beta_7 \text{Consulta Serasa/SPC} + \varepsilon$					
Método Forward	Variáveis	B	Sig.	95% C.I. Exp(B)	
				Inf.	Sup.
Etapa 1	Fac de Cred	21,555	0,996	0,000	.
Etapa 2	Conhec Score Cred	21,456	0,996	0,000	.
	Fac de Cred	21,685	0,996	0,000	.
Etapa 3	Conhec Score Cred	21,916	0,996	0,000	.
	Fac de Cred	21,526	0,995	0,000	.
	Valores Parcel	21,447	0,995	0,000	.
Etapa 4	Conhec Score Cred	21,528	0,995	0,000	.
	Entend Calc Score Cred	21,324	0,996	0,000	.
	Fac de Cred	21,919	0,995	0,000	.
	Valores Parcel	21,965	0,995	0,000	.
Etapa 5	Conhec Score Cred	21,797	0,995	0,000	.
	Entend Calc Score Cred	21,268	0,996	0,000	.
	Fac de Cred	22,174	0,994	0,000	.
	Valores Parcel	22,118	0,995	0,000	.

Etapa 6	Consulta_Serasa/SPC	21,214	0,997	0,000	.
	Conhec_Score_Cred	21,919	0,995	0,000	.
	Entend_Calc_Score_Cred	21,256	0,996	0,000	.
	Conf_Empresa	20,315	0,996	0,000	.
	Fac_de_Cred	22,295	0,994	0,000	.
	Valores_Parcel	22,022	0,994	0,000	.
	Consulta_Serasa/SPC	21,472	0,997	0,000	.
Etapa 7	Conhec_Score_Cred	21,965	0,995	0,000	.
	Entend_Calc_Score_Cred	21,130	0,996	0,000	.
	Conf_Empresa	20,450	0,996	0,000	.
	Conf_Seg_Dados	20,338	0,997	0,000	.
	Fac_de_Cred	22,435	0,994	0,000	.
	Valores_Parcel	22,085	0,994	0,000	.
	Consulta_Serasa/SPC	21,628	0,997	0,000	.

**Fonte:** Elaborado pelos autores.

## 5. CONSIDERAÇÕES FINAIS

O presente artigo teve como objetivo analisar como o sistema de *Score* de crédito pode ser impactado pelo uso de *big data* e pela nova LGPD, bem como sua influência em relação as empresas que operam com crédito e com os tomadores de crédito.

Em linhas gerais, foram propostos e aplicados seis novos modelos, dos quais quatro modelos buscaram analisar as relações no uso do *Score* de crédito por lojistas/empresas e dois modelos procuraram examinar as correlações, tanto no endividamento quanto na tomada de crédito, pelos indivíduos.

Observando o modelo 1 aplicado aos lojistas/empresas que possuem somente dívidas contraídas pela pessoa jurídica, sob a percepção do que poderia ser ruim para o uso do *Score* de crédito, é possível verificar que os respondentes que selecionaram a variável independente credibilidade têm uma chance 6,6% menor de usar o *Score* quando comparado com os que não escolheram esta variável.

Examinando o modelo 3 aplicado aos lojistas/empresas que possuem somente dívidas contraídas pela pessoa jurídica, com relação ao que pode inibir a adequação à LGPD, foi possível verificar que os respondentes que selecionaram a variável investimento na segurança dos dados têm uma chance 19,8% menor de se adequar quando comparado com os que não escolheram esta variável.

Os modelos 2 e 4 aplicados aos lojistas/empresas que possuem apenas dívidas contraídas por pessoas jurídicas, embora validados por meio da interação entre a variável dependente com as variáveis independentes, não foi possível fazer observações conclusivas acerca das variáveis independentes.

Avaliando os modelos 1 e 3 para lojistas/empresas que possuem dívidas contraídas por pessoas jurídicas e pessoas físicas, apesar desses modelos terem sido validados por meio da interação entre a variável dependente com as variáveis independentes, não foi possível ter observações conclusivas.

Verificando os modelos 2 e 4 impostos aos lojistas/empresas que possuem dívidas contraídas por pessoas jurídicas e pessoas físicas não tiveram interação entre a variável dependente com as variáveis independentes, foi verificado como único modelo válido o modelo nulo, sem interferência de variáveis independentes.

Com relação aos tomadores de crédito pessoas físicas, os modelos 5 e 6, ainda que validados por meio da interação entre a variável dependente com as variáveis independentes, não foi possível fazer observar valores conclusivos.

Como sugestões para futuras pesquisas, no que diz respeito a como o sistema de *Score* de crédito pode ser impactado pelo uso de *big data* e pela nova LGPD, talvez modelos desenvolvidos com menos variáveis preditoras dicotômicas e uma maior quantidade de indivíduos respondentes possa refinar e aperfeiçoar o cálculo das possíveis *odds ratio* desses modelos, com o intuito de promover uma constante melhora no desenvolvimento desse conteúdo.

## 6. REFERÊNCIAS

AKERKAR, R. Analytics on big aviation data: Turning Data into Insights. **International Journal of Computer Science and Applications**, v. 11, n.3, p.116-127; 2014.

ANALYTICS10. **Top 10 Big Data Trends of 2020**. 2020. Disponível em: <https://www.analyticsinsight.net/top-10-big-data-trends-2020/>. Acesso em: 22 de Dezembro de 2020.

ARRUDA, V. C. G. **Big Data, dados pessoais e propriedade intelectual: limites e tutela jurídica das bases de dados**, 2019. 98 f. Dissertação (Direito Político e Econômico) – Universidade Presbiteriana Mackenzie, São Paulo.

BESSA, L. **Cadastro Positivo: Comentários à Lei 12.414 de 09 de junho de 2011**. 1ª ed. São Paulo: Revista dos Tribunais, 2011.

BOAVISTA. **Sobre a BoaVista SCPC**. 2020. Disponível em: <https://www.boavistaservicos.com.br/sobre-a-boa-vista-scpc/>. Acesso em: 15 dez. 2020.

BULOS, U. L. Curso de direito constitucional. rev. e atual. de acordo com a Emenda Constitucional n. 76/2013. **São Paulo: Saraiva**, 2014.

CAVALCANTI, P. P. **Privacidade e proteção de dados pessoais: uma análise comparativa dos quadros regulatórios brasileiro e europeu**. 2018. 62 f. TCC (graduação em Direito) - Universidade Federal de Pernambuco - UFPE – Recife.

CHARNET, R.; BONVINO, H; FREIRE C. A. L; CHARNET, E. M. R. **Análise de modelos de regressão linear com aplicações**. Campinas, SP: Unicamp, 1999.

CHIAVENATO, J. J. **Ética globalizada & sociedade de consumo**. 2 ed.reform. São Paulo: Editora Moderna Ltda, 2004.

COONEY, M. G. **how big trends in security, mobile, big data and cloud computing will change IT: a quick roundup of IT trends, from Android adoption to cloud security**. Network World, 2012. Disponível em: <https://www.networkworld.com/article/2161069/lan-wan/gartner--how-big-trends-in-security--mobile--big-data-and-cloud-computing-will-change-it.html>. Acesso em: 16 de Dezembro de 2020.

CORTAZIO, R. S. Banco de dados no Brasil: Uma análise do sistema credit scoring à luz da lei n. 13.709/2018 (LGPD). **Revista Eletrônica da Procuradoria Geral do Estado do Rio de Janeiro**, v. 2 n. 3, p.23, 2019.

DEAN CAIRE, C. F. A. **Building Credit Scorecards for Small Business Lending in Developing Markets**, Bannock Consulting, 2004. Disponível em: [http://www.microfinance.com/English/Papers/Scoring\\_SMEs\\_Hybrid.pdf](http://www.microfinance.com/English/Papers/Scoring_SMEs_Hybrid.pdf). Acesso em: 10 de out de 2020.

FILHO, D. R. A diretiva europeia sobre proteção de dados pessoais - uma análise de seus Aspectos Gerais. **Lex magister**. 2013. Disponível em: [http://www.lex.com.br/doutrina\\_24316822\\_A\\_DIRETIVA\\_EUROPEIA\\_SOBRE\\_PROTECAO\\_DE\\_DADOS\\_PESSOAIS\\_UMA\\_ANALISE\\_DE\\_SEUS\\_ASPECTOS\\_GERAIS.aspx](http://www.lex.com.br/doutrina_24316822_A_DIRETIVA_EUROPEIA_SOBRE_PROTECAO_DE_DADOS_PESSOAIS_UMA_ANALISE_DE_SEUS_ASPECTOS_GERAIS.aspx). Acesso em: 07 de Novembro de 2020.

GOMES, H. S. **Lei Geral de Proteção de Dados (LGPD): Uma análise dos impactos da lei na cultura e tratamento de dados no Brasil**. 2019. 28 f. TCC (Tecnólogo em Análise e Desenvolvimento de Sistemas) – UNISUL, Universidade do Sul de Santa Catarina, Florianópolis.

GOULART, Guilherme. Por uma visão renovada dos arquivos de consumo: Databrokers e Score de crédito. **Revista de Direito do Consumidor**, v. 107, 2016.

HURLEY, M.; ADEBAYO, J. **Credit scoring in the era of big data**. **Yale JL & Tech.**, v. 18, n. 1, p. 1-70, 2017.

KHASHMAN, A. Credit risk evaluation using neural networks: Emotional versus conventional models. **Applied Soft Computing**, v. 11, n. 8, p. 5477-5484, 2011.

MARINHO, F. **A Adequação da LGPD nas empresas**. 2019. Disponível em: <https://www.linkedin.com/pulse/adequa%C3%A7%C3%A3o-da-igpd-nas-empresas-fernando-marinho/>, Acesso em: 19 de Dezembro de 2020.

MANYIKA, J.; CHUI, M.; BROWN, B.; BUGHIN, J.; DOBBS, R.; ROXBURGH, C.; BYERS, A. H. **Big data: The next frontier for innovation, competition, and productivity**. Washington: McKinsey Global Institute, 2011.

MENDES, G. F.; BRANCO, P. G. G. **Curso de Direito Constitucional**, 12ª ed. São Paulo: Saraiva, 2017.

MUCELIN, G. Peers Inc.: a nova estrutura da relação de consumo na economia do compartilhamento. **Revista de Direito do Consumidor**. vol. 118. ano 27. p. 77-126, 2018.

NOGUEIRA, Leandro César Borboleta. **Big Data: ranking dos cidadãos como instrumento de controle social**. Tese de Doutorado; 2020.

OLIVA, M. D; VIÉGAS, F. A. Tratamento de dados para a concessão de crédito. In: FRAZÃO, A.; TEPEDINO, G.; OLIVA, M. D. **Lei Geral de Proteção de Dados Pessoais e suas repercussões no direito brasileiro**. São Paulo: Thonson Reuters Brasil, 2019.

O'NEIL, C. **Weapons of Math Destruction: How Big Data Increases Inequality and Threatens Democracy**. New York: Crown, 2016.

PASQUALE, F. A. **The black box society: the secret algorithms that control money and information**. Cambridge: Harvard University Press, 2016.

POSPIECH, M.; FELDEN, C. A descriptive big data model using grounded theory. **Computational Science and Engineering (CSE), IEEE 16th International Conference** on 878–885, 2013.

QUOD. **Sobre nós**. 2020. Disponível em: <https://www.quod.com.br/a-quod>. Acesso em: 15 dez. 2020.

SIMON, P. **Too Big to Ignore: The business case for Big Data**. Hoboken: John Wiley & sons Inc, 2013.

STJ. **Recurso Especial: Nº 1.457.199** - RS (2014/0126130-2). Relator: Ministro Paulo de Tarso Sanseverino. DJ: 17/12/2014. **JusBrasil**, 2014. Disponível em: <https://bdjur.stj.jus.br/jspui/bitstream/2011/114173/REsp1457199.pdf>. Acesso em: 25 dez. 2020.

VARIAN, H. R. **Microeconomia - Princípios Básicos: Uma abordagem moderna**. Rio de Janeiro: Elsevier Brasil, 2006.

YANG Y. Adaptive credit scoring with kernel learning methods. **European Journal of Operational Research**, v. 183, n. 3, p. 1521-1536, 2007.