

O CONSUMIDOR DE SEGUROS NA ERA DO BIG  
DATA: DESAFIOS DA ATUAL REGULAMENTAÇÃO  
EUROPEIA FRENTE ÀS TÉCNICAS DE DEFINIÇÃO DE  
PERFIS, APRENDIZAGEM DE MÁQUINA E DECISÕES  
AUTOMATIZADAS

*THE INSURANCE CONSUMER IN THE BIG DATA ERA:  
CURRENT EUROPEAN REGULATION CHALLENGES IN THE  
FACE OF PROFILING TECHNIQUES, MACHINE LEARNING AND  
AUTOMATED DECISION-MAKING*

*Actualidad Jurídica Iberoamericana N° 18, febrero 2023, ISSN: 2386-4567, pp. 2134-2163*

Glauto LISBOA  
MELO JUNIOR

ARTIGO SUBMETIDO: 14 de octubre de 2022

ARTIGO APROVADO: 5 de diciembre de 2022

**RESUMO:** O setor de seguros, com maior ênfase que em outros mercados, incorpora técnicas próprias da era do *Big Data*. O uso destas técnicas acarreta diferentes impactos aos direitos e interesses dos consumidores. Este artigo visa analisar, sob o atual regramento da União Europeia, as diversas implicações legais e pontos para discussão de se aplicar o aprendizado de máquina, definir perfis de consumidores ou tomar decisões automatizadas no ramo de seguros. Procura ainda oferecer uma precisão desses conceitos partindo da reconstrução de sua compreensão à luz de uma interpretação normativa sistemática. Privilegia ainda a exploração de temas ligados ao uso dessas novas tecnologias, como causalidade, correlação, leis antidiscriminação e discriminação algorítmica, precificação e da noção de consumidor médio.

**PALAVRAS CHAVE:** Novas tecnologias; contratos de seguro; consumidores; aprendizado de máquina; definição de perfis; decisões automatizadas; causalidade e correlação; discriminação; precificação; consumidor médio.

**ABSTRACT:** *The insurance industry, with greater emphasis than in other markets, incorporates new techniques of the Big Data era. The application of these techniques has different impacts on the rights and interests of consumers. This article aims to analyze, under the current European Union regulations, the various legal implications and debating points when applying machine learning, profiling consumers or automated decision-making in the insurance business. The objective is also to offer a precision of these concepts starting from the reconstruction of their understanding in the light of a systematic normative interpretation. The study also focuses on the exploration of themes linked to the use of these new technologies, such as causality, correlation, antidiscrimination laws and algorithmic discrimination, pricing and the standard of average consumer.*

**KEY WORDS:** *New technologies; insurance contracts; consumers; machine learning; profiling; automated decisions; causality and correlation; discrimination; pricing; average consumer.*

**SUMÁRIO.- I. INTRODUÇÃO. - II. CONCEITUAÇÕES IMPORTANTES. - I. Definição de perfis. - 2. Aprendizado de máquina. - 3. Tomada de decisão automatizada. - III. COLETA DE INFORMAÇÕES: CONFLITOS FRENTE ÀS DECISÕES TOMADAS COM BASE NA APRENDIZAGEM DE MÁQUINAS E À FORMAÇÃO DE PERFIS DE CONSUMIDORES. - 1. Diferenças entre a causalidade e a correlação. - 2. Possibilidade de extração de informações com base em correlações. - IV. AS CONDIÇÕES DO RGPD PARA A APLICAÇÃO DE TOMADA DE DECISÃO AUTOMATIZADA NO ÂMBITO DO SETOR DE SEGUROS. - 1. Momento da aplicação das condições previstas no RGPD para a tomada de decisão automatizadas. - A) *Consequências legais ou outras consequências materiais para o cliente.* - B) *Nenhum envolvimento humano.* - 2. Condições que devem ser satisfeitas na tomada de decisões automatizada. - A) *Motivos válidos para tomada de decisão automatizada.* - B) *Nenhum uso de categorias especiais de dados.* - C) *Direito à intervenção humana e oportunidade de contestar a decisão.* - V. DISCRIMINAÇÃO DE PREÇOS E A RECUSA DE FORNECIMENTO COM BASE NO PERFIL. - 1. Discriminação de preços com base no que o cliente está disposto a pagar. - 2. Discriminação de preços com base nas características do cliente. - VI. A PROIBIÇÃO DE DISCRIMINAÇÃO POR MOTIVOS RACIAIS, ÉTNICOS, DE GÊNERO, RELIGIÃO E OUTROS APLICADA AO APRENDIZADO DE MÁQUINA. - 1. Discriminação devido a erros no engajamento do algoritmo. - 2. Discriminação por um algoritmo porque certos grupos têm de fato características estatisticamente corretas. - VII. A DEFINIÇÃO DE PERFIS E O SEU IMPACTO NO CONCEITO DE CONSUMIDOR MÉDIO. - VIII. CONCLUSÃO.**

## I. INTRODUÇÃO.

*Big Data* é um termo que descreve o grande volume de dados, estruturados ou não, que diariamente são produzidos e podem ser aproveitados por um determinado segmento do mercado<sup>1</sup>. A quantidade de dados é menos importante do que o uso que as organizações fazem deles. Esses grandes dados são, em princípio, analisados em busca de descobertas que propiciem melhores decisões e estratégias corporativas.

Nesse contexto, como não poderia deixar de ser, os grandes dados também desempenham um papel cada vez mais importante no setor de seguros. É cada vez mais frequente que as seguradoras passem a utilizar *Big Data* para entender melhor o comportamento dos seus clientes, identificar riscos e precisar preços dos produtos. Além disso, os grandes dados estão ajudando as seguradoras a detectar e prevenir fraudes, e até a melhorar o atendimento ao cliente<sup>2</sup>.

Dentre as novas técnicas orientadas por dados que são assimiladas pelo setor de seguros, temos o uso de aprendizagem de máquina, ou *machine learning*, que

1 MIRAGEM, B., PETERSEN, L.: "O Contrato de Seguros e a Lei Geral de Proteção de Dados", *Revista dos Tribunais*, 2020, v. 109, núm. 1018, pp. 61-106.

2 THOUVENIN, F., SUTER, F., GEORGE, D., WEBER, R. H.: "Big Data in the insurance industry: Leeway and limits for individualising insurance contracts", *Journal of Intellectual Property, Information Technology and Electronic Commerce Law*, Universitätsverlag Göttingen, 2019, v. 10, núm. 2, pp. 209-243.

### • Glauto Lisboa Melo Junior

Dottorando di Ricerca nell'Università degli Studi di Perugia  
glauto.lisboamelojunior@studenti.unipg.it

permite às companhias de seguros automatizar o processo de subscrição, que é a avaliação de risco para a fixação de prémios. Isso é feito por meio de algoritmos para processar grandes quantidades de dados a fim de identificar padrões e tendências. Esses dados podem ser obtidos de uma variedade de fontes, incluindo mídias sociais, registros financeiros e históricos de sinistros. O uso de *machine learning* pode contribuir à precisão da subscrição no seguro, bem como tornar o processo de contratação mais rápido e mais eficiente. Além disso, as seguradoras têm realizado a definição de perfis (*profiling*) para visar grupos determinados de clientes. Isso envolve o uso dos dados para identificar características que estão associadas a um risco maior ou menor de sinistros, por exemplo. Essas informações podem então ser usadas para direcionar o marketing e os preços a esses grupos específicos. No mesmo passo, as companhias de seguros fazem uso de decisões automatizadas. Isso envolve o uso de algoritmos para tomar decisões sobre preços e avaliação de riscos com base em dados<sup>3</sup>.

O uso de algumas destas técnicas tem um impacto relativamente baixo em relação aos direitos e interesses dos envolvidos. Por exemplo, as seguradoras comumente utilizam técnicas de aprendizado de máquina para gerir formas simples de relacionamento, como determinar se um cliente prefere ser contactado por telefone, e-mail ou carta. Maior impacto, no entanto, haverá quando as companhias passarem a usar essas técnicas para determinar quando e quais produtos podem ser relevantes para um cliente<sup>4</sup>. Por exemplo, utilizar *machine learning* para descobrir quando o cliente compra uma nova casa ou automóvel, o nascimento de um filho e, portanto, muito provavelmente tenderá a precisar de um novo produto ou serviço securitário. Um próximo nível é alcançado por empresas que poderão fazer uso estratégico dessas novas tecnologias de um modo até então pouco conhecido. Por exemplo, modular suas ofertas a partir do momento do dia e do meio pelo qual os clientes as procuram, de modo a estimar dinamicamente diferentes níveis de risco e precificação<sup>5</sup>.

Este artigo visa, portanto, analisar, no âmbito das regras estabelecidas pela União Europeia, as diversas implicações legais e pontos para discussão de se aplicar

- 3 Autoridade Europeia dos Seguros e Pensões Complementares de Reforma (EIOPA), *Artificial Intelligence governance principles, towards ethical and trustworthy Artificial Intelligence in the European insurance sector : a report from EIOPA's Consultative Expert Group on Digital Ethics in insurance*, Publications Office, 2021, Disponível em <https://data.europa.eu/doi/10.2854/49874> . Acesso em 22 de novembro de 2022.
- 4 COLOMBO,C., FACHINNI NETO, E.: "Decisões automatizadas em matérias de perfis e riscos algorítmicos: diálogos entre Brasil e Europa acerca dos direitos das vítimas de dano estético digital", em AA.VV. *Responsabilidade Civil e Novas Tecnologias* (coord. por G. MAGALHÃES MARTINS e N. ROSENVALD), Editora Foco, Indaiatuba, SP, 2020, pp. 163-183.
- 5 BALASUBRAMANIAN, R., LIBARIKIAN, A., McELHANEY, D.: "Insurance 2030 – The impact of AI on the future of insurance", *McKinsey's Insurance Practice*, março 2021, pp. 1-10. Disponível em <https://www.mckinsey.com/industries/financial-services/our-insights/insurance-2030-the-impact-of-ai-on-the-future-of-insurance> . Acesso em 22 novembro 2022.

o aprendizado de máquina, traçar perfis de consumidores ou tomar decisões automatizadas no ramo de seguros.

Essas novas técnicas da era do *Big Data*, por certo, são também aplicadas em outros ramos e atividades empresariais. Todavia, o setor de seguros é particularmente afetado porque historicamente sempre dependeu da coleta e análise de grandes quantidades de dados para seu bom funcionamento<sup>6</sup>.

Em muitos momentos neste artigo opta-se por dar preferência ao uso da expressão “cliente”, já que este é um termo legalmente indefinido, sobretudo para fins do direito da União Europeia<sup>7</sup>. Além disso, o escopo da proteção dos diferentes tipos de normas a serem consideradas aqui diferem entre si. Neste sentido, o Regulamento (UE) 2016/679 do Parlamento Europeu e do Conselho de 27 de abril de 2016, relativo à proteção das pessoas singulares no que diz respeito ao tratamento de dados pessoais e à livre circulação desses dados, conhecido como “RGPD”, tutela, em linha de princípio, as pessoas físicas<sup>8</sup>, independentemente de estarem atuando no curso de seus negócios ou profissão<sup>9</sup>. De outro lado, a Diretiva (UE) 2016/97 do Parlamento Europeu e do Conselho de 20 de janeiro de 2016 sobre a distribuição de seguros se aplica a clientes-consumidores<sup>10</sup>.

Para melhor ordenar as ideias e temas enfrentados, o presente artigo seguirá uma estruturação em tópicos. No tópico II, são expostos os termos técnicos relevantes. Há uma explicação sobre o que se entende por definição de perfil, aprendizado de máquina e tomada de decisão automatizada. Em seguida, abordar-se-á as várias complicações decorrentes da aplicação destas técnicas pelas empresas no relacionamento com seus clientes. A primeira complicação a ser

6 ARMBRÜSTER, C; HACKER, P.: “Datenprivatrecht”, *ZVersWiss*, 2020, núm. 109, pp. 299-303.

7 No direito italiano, por exemplo, a expressão “cliente” consta de diversas disposições do *Testo Unico Bancario* (Decreto legislativo 1° settembre 1993, n. 385), mas sempre para definir qualquer indivíduo ou pessoa jurídica que tenha uma relação contratual ou pretenda entrar em um relacionamento com um banco. A definição de cliente não inclui os intermediários financeiros e quaisquer outros sujeitos que realizam atividades de intermediação financeira. Neste sentido: PROTO, A.: “La trasparenza nei rapporti banca-cliente”, em AA.VV. *L'attività delle banche: operazioni e servizi* (coord. por A. PROTO), G. Giappichelli Editore, Turim, 2018, pp. 47-71.

8 Art. 1°, I, do RGPD: “O presente regulamento estabelece as regras relativas à proteção das pessoas singulares no que diz respeito ao tratamento de dados pessoais e à livre circulação desses dados”.

9 Na verdade, o conceito de consumidor não aparece em lugar algum no texto do RGPD. No entanto, este Regulamento também se aplica às relações de consumo, tendo há muito estabelecido padrões para a concepção e regulamentação do direito do consumidor no mercado digital do consumidor. Ao mesmo tempo, as normas e valores do RGPD têm, sabidamente, um efeito profundo no direito privado e do consumidor europeu. Ver: D'IPPOLITO, G.: “Evoluzione della disciplina consumeristica e rapporto con la normativa sulla protezione dei dati personali”, em AA.VV. (coord. por Consumers' Forum e Università degli Studi Roma Tre), *Consumerism 2019. Dodicesimo rapporto annuale. Dal codice del consumo al Digital Service Act. Quella dal consumatore al cittadino digitale è vera evoluzione?*, 2019, pp. 70-80. Disponível em [https://www.consumersforum.it/files/eventi/2019/CF\\_Consumerism-2019.pdf](https://www.consumersforum.it/files/eventi/2019/CF_Consumerism-2019.pdf). Acesso em 22 de novembro de 2022.

10 MARANO, P.: “Management of Distribution Risks and Digital Transformation of Insurance Distribution – A Regulatory Gap in the IDD,” *Risks*, MDPI, 2021, v. 9(8), pp. 1-11; AMODIO, A.: “La Direttiva (UE) 2016/97 e il regime informativo a tutela del consumatore”, *Amministrazione e Contabilità dello Stato e degli Enti Pubblici*, 2018, núm. 4, pp. 63-78.

discutida aparece no tópico III, já que estas novas técnicas dependem mais da correlação (conexão casual) que da causalidade (conexão necessária). E ao que parece a legislação de muitos Estados-Membros não está preparada para garantir que as decisões relativas aos clientes sejam tomadas com base na correlação, em detrimento da causalidade. No tópico IV discute-se acerca de quais condições devem ser satisfeitas sob a vigência do RGPD para que a tomada de decisão automatizada seja permitida. Também se discute quais as implicações práticas que o citado Regulamento UE tem para os possíveis modelos de negócios das empresas de seguros. No ponto V, discute-se a discriminação de preços. Se os clientes são mais conhecidos através da aplicação das novas técnicas, isso nem sempre será vantajoso para eles. As empresas podem tentar cobrar mais de alguns clientes ou recusar outros. Na literatura econômica, isto é referido como discriminação de preços. No tópico VI, discute-se quando há discriminação proibida no sentido jurídico – por exemplo, com base em critérios étnicos – na tomada de decisão automatizada. Em essência, a questão posta é: como pode ser determinado que um computador discrimina? No tópico VII, aborda-se brevemente a questão do que significa para o conceito de “consumidor médio”, frequentemente utilizado no direito do consumidor, se a companhia seguradora é capaz de visar segmentos específicos de clientes através da definição de perfis. As considerações finais vêm apresentadas no tópico final VIII.

## II. CONCEITUAÇÕES IMPORTANTES.

### I. Definição de perfis.

O RGPD traz uma definição sobre perfil que pode ser extraída da seguinte passagem: “qualquer forma de tratamento automatizado de dados pessoais para avaliar aspetos pessoais relativos a uma pessoa singular, em especial a análise e previsão de aspetos relacionados com o desempenho profissional, a situação económica, saúde, preferências ou interesses pessoais, fiabilidade ou comportamento, localização ou deslocações do titular dos dados”<sup>11</sup>.

De acordo com o Grupo de Trabalho do Artigo 29º para a Proteção de Dados<sup>12</sup>, a definição de perfis envolve essencialmente o seguinte<sup>13</sup>: (i) são coletadas informações sobre um indivíduo; (ii) suas características e padrões

11 Excerto do Considerando 71 do Regulamento (UE) 2016/679.

12 Este grupo de trabalho foi instituído ao abrigo do artigo 29º da revogada Diretiva 95/46/CE. Trata-se de um órgão consultivo europeu independente em matéria de proteção de dados e privacidade. As suas atribuições encontram-se descritas no artigo 30º da Diretiva 95/46/CE e no artigo 15º da Diretiva 2002/58/CE.

13 *Orientações sobre as decisões individuais automatizadas e a definição de perfis para efeitos do Regulamento (UE) 2016/679*, adotadas em 3 de outubro de 2017 e com a última redação revista e adotada em 6 de fevereiro de 2018, p. 7. Disponível em <https://ec.europa.eu/newsroom/article29/items/612053/en> (versão em português). Acesso em 22 de novembro de 2022.

de comportamento são analisados; (iii) o indivíduo é colocado em um grupo ou categoria de indivíduos similares; (iv) com base nisso, suas capacidades são avaliadas ou são feitas previsões.

A ideia é que as pessoas são parecidas. Se o indivíduo A for semelhante ao indivíduo B nas características 1, 2 e 3, então é plausível que se o indivíduo B tiver a característica 4, o indivíduo A também apresentará esta característica 4. Um exemplo: se você comprou os livros 5, 6 e 7 do site Amazon e outro cliente comprou os livros 5, 6, 7 e 8, é provável que você também vai gostar do livro 8. A Amazon poderá então decidir recomendar a você este livro 8. Um outro exemplo menos agradável é o seguinte: o cliente A tem as características 1, 2 e 3. O cliente B também tinha estas mesmas características 1, 2 e 3 e em algum momento envolveu-se em acidentes de trânsito com consequências graves ou mesmo teve sua carteira de motorista suspensa por ter sido flagrado sob o efeito de álcool. O cliente A então não obtém a renovação de seu seguro ou, se conseguir obtê-la, terá uma substancial majoração do preço da apólice. Assim, dependendo de como o perfil é utilizado, ele pode ter mais ou menos impacto para o cliente.

## 2. Aprendizado de máquina.

○ “aprendizado de máquina”<sup>14</sup> é um conjunto de técnicas e ferramentas que permitem aos computadores encontrar padrões em grandes dados<sup>15</sup>.

Com base nos padrões que descobre nos dados, o computador pode responder perguntas, fazer previsões ou tomar decisões. É, pois, uma tecnologia voltada à aplicação de algoritmos que aprendem a partir de dados<sup>16</sup>.

Um exemplo bem conhecido é que os computadores podem determinar se uma imagem representa uma bicicleta. O computador “aprendeu” isto através da análise de muitas fotos que as pessoas indicaram mostrando exatamente uma bicicleta, este maravilhoso velocípede de duas rodas que todos nós conhecemos. Posteriormente, o computador também pode reconhecer fotos de uma

14 O surgimento da expressão “aprendizado de máquina” é comumente atribuído a Arthur Lee Samuel que em julho de 1959 publicou “Some Studies in Machine Learning Using the Game of Checkers”, *IBM Journal of Research and Development*, Riverton, NJ, 1959, v. 3, núm. 3, pp. 210-229. Neste trabalho, A. L. SAMUEL demonstrou que as máquinas podem aprender com erros passados, um dos primeiros exemplos de computação não-numérica, de acordo com HOOK, D. H., NORMAN, J. M.: “Origins of Cyberspace: A Library on the History of Computing and Computer-Related Telecommunications”, *Historyofscience.com*, Novato, CA, 2002, núm. 874 apud *Jeremy Norman’s HistoryofInformation.com Exploring the History of Information and Media through Timelines*. Disponível em <https://www.historyofinformation.com/detail.php?id=779>. Acesso em 22 novembro 2022.

15 Conceituação adotada, dentre outras, pela autoridade de proteção de dados do Reino Unido. Ver Information Commissioner’s Office, *Big data, artificial intelligence, machine learning and data protection*, versão 2.2, 2017, p. 6. Disponível em <https://ico.org.uk/media/for-organisations/documents/2013559/big-data-ai-ml-and-data-protection.pdf>. Acesso em 22 de novembro de 2022.

16 NILSSON, N. J.: *Introduction to Machine Learning: An Early Draft of a Proposed Textbook*, Stanford University, Stanford, CA, 1998, p. 1.

bicicleta sem ser informado. Um computador não precisa ser informado com antecedência sobre o que procurar, mas pode aprender isso por si mesmo<sup>17</sup>. Por exemplo, um humano pode raciocinar que a probabilidade de um cliente não pagar seu financiamento imobiliário aumenta à medida que a quantidade de suas economias diminui. Ele pode então fazer o computador pesquisar clientes com contas de investimento cujos saldos estão diminuindo. Isto é automação, mas não aprendizagem de máquina. O computador apenas executa ações totalmente pensadas com antecedência pelo ser humano<sup>18</sup>. Entretanto, um humano também pode dar ao computador uma grande quantidade de dados sobre clientes. O computador pode então encontrar nesses dados padrões, correlações ocultas ou implícitas, que um humano não encontraria imediatamente ou jamais conseguiria fazê-lo. Por exemplo, o computador pode descobrir que clientes que remodelaram seus imóveis instalando uma piscina no jardim, apresentam um percentual mais alto de problemas com o pagamento de empréstimos pessoais um ano depois. Ou ainda mais correlações inusitadas, que, portanto, nem saberíamos dizer. Assim, o computador aprende coisas novas e surpreende o ser humano. O aprendizado da máquina e a criação de perfis muitas vezes andam juntos, mas não é necessariamente assim<sup>19</sup>. Por exemplo, a aprendizagem de máquinas também pode ser usada para examinar a conexão entre os dias da semana, o clima, várias outras variáveis e a ocorrência de congestionamentos no trânsito. Como não são extraídas conclusões sobre pessoas identificáveis, não há um perfil envolvido.

### 3. Tomada de decisão automatizada.

A tomada de decisão automatizada não vem definida pelo RGPD. Não obstante, sua conceituação é aportada pelo Grupo de Trabalho do Artigo 29<sup>o</sup> <sup>20</sup>. Em essência, é qualquer decisão que não envolva um ser humano e que se baseie em dados relativos a uma pessoa física. Esta pode ser uma decisão simples. Por exemplo, o processo pelo qual um cidadão é multado por excesso de velocidade em relação a um radar eletrônico de velocidade é totalmente automatizado. No entanto, esta decisão automatizada também pode ser baseada na definição de perfis ou no aprendizado de máquinas. Um exemplo de tomada de decisão automatizada baseada em perfis é: a seguradora tem acesso aos dados dos radares

- 
- 17 De acordo com Tom M. Mitchel, “[d]iz-se que um programa de computador aprende com a experiência E em relação a alguma classe de tarefas T e medida de desempenho P, se seu desempenho em tarefas em T, medido por P, melhora com a experiência E” [tradução nossa] (in MITCHEL, T. M.: *Machine Learning*, McGraw-Hill, New York, 1997, p. 3)
- 18 NERSESSIAN, D; MANCHA, R.: “From Automation to Autonomy: Legal and Ethical Responsibility Gaps in Artificial Intelligence Innovation”, *Michigan Technology Law Review*, 2020, v. 27, núm. 1, pp. 55-96.
- 19 Por todos, ver VAN OTTERLO, M.: “A Machine Learning View on Profiling”, em AA.VV.: *Privacy, Due Process and the Computational Turn: The Philosophy of Law Meets the Philosophy of Technology* (coord. por M. HILDEBRANDT e K. DE VRIES), Routledge, London, 2013, pp. 41-64.
- 20 *Orientações sobre as decisões individuais automatizadas e a definição de perfis para efeitos do Regulamento (UE) 2016/679*, adotadas em 3 de outubro de 2017 e com a última redação revista e adotada em 6 de fevereiro de 2018, pp. 8-9. Disponível em <https://ec.europa.eu/newsroom/article29/items/612053/en> (versão em português). Acesso em 14 de novembro de 2022.

e controladores eletrônicos de trânsito, o computador é instruído a rejeitar automaticamente qualquer cliente com mais de quatro multas de trânsito em um período determinado de tempo – em um ano, por exemplo - para fins de um seguro de vida, porque as estatísticas revelam que as pessoas que dirigem agressivamente muitas vezes também se envolvem em outros comportamentos indesejáveis, havendo risco maior de morte prematura ou incapacidade parcial ou total para o trabalho<sup>21</sup>.

### III. COLETA DE INFORMAÇÕES: CONFLITOS FRENTE ÀS DECISÕES TOMADAS COM BASE NA APRENDIZAGEM DE MÁQUINAS E À FORMAÇÃO DE PERFS DE CONSUMIDORES.

Uma primeira complicação com a aprendizagem de máquinas e a definição de perfis é que os padrões de coleta de informações no contexto dos seguros assumem relações causais. Entretanto, a essência da formação de perfis e da aprendizagem de máquinas é a correlação. Isto significa que as decisões tomadas com base no perfil e na aprendizagem de máquinas podem não atender aos padrões legais atuais.

#### I. Diferenças entre a causalidade e a correlação.

Os conceitos de uma e outra remetem geralmente às ciências matemáticas e econômicas<sup>22</sup>. No entanto, em termos básicos, podemos dizer que embora a correlação e a causalidade possam dar-se ao mesmo tempo, a correlação não implica causalidade. Esta última aplica-se aos casos em que uma ação *A* causa necessariamente o resultado *B*.

De fato, na causalidade existe uma relação lógica, de causa, entre *A* e *B*. Um exemplo de relação causal: quando o ciclista pedala (causa *A*), a sua bicicleta começa a se mover (consequência *B*). Em correlação, *A* e *B* frequentemente as situações se fazem ou se realizam ao mesmo tempo, mas não é sempre claro que *A* causa *B*. Assim, o que é considerado nas correlações é a existência de relações estatísticas. Não se trata, portanto, de apurar relações determinísticas, que são reservadas à causalidade<sup>23</sup>.

21 Esta questão, por óbvio, suscita outros debates e problemas na doutrina jurídica, em especial quanto à discriminação algorítmica. Ver PASQUALE, F.: *The black box society: the secret algorithms that control money and information*, Harvard University Press, Cambridge, 2015, pp. 26-30; e JUNQUEIRA, T.: *Tratamento de dados pessoais e discriminação algorítmica nos seguros*. São Paulo: Thomson Reuters Brasil, São Paulo, 2020, *passim*.

22 Para maior aprofundamento, veja-se PATRÍCIO, M.: "Correlações e causalidade: breves reflexões numa perspectiva económica", *Revista Jurídica Luso-Brasileira*, 2016, ano 2, n. 4, pp. 1347-1380.

23 PATRÍCIO, M.: "Correlações e causalidades", *cit.*, p. 1359.

Um exemplo bem conhecido para esclarecer a correlação: por meio de ferramentas disponibilizadas pelo Google é possível usar a aprendizagem da máquina para prever um novo surto de sarampo. Isto porque este é o caso quando são feitas mais buscas no Google para a palavra “sarampo”. Entretanto, todos entenderão que estas buscas não causam nenhuma epidemia da doença. Se você procurar no Google a palavra “sarampo” incontáveis vezes e durante muitos dias, isso não fará com que você seja infectado. Ou seja, lançar no Google a palavra sarampo (evento A) e uma epidemia de sarampo (evento B) frequentemente ocorrem de modo simultâneo (i. e., correlação), mas A não pode ser definida como causa de B.

Sabe-se que atualmente os algoritmos são capazes de reunir e analisar dados de múltiplas fontes, mesmo que sequer saibamos<sup>24</sup> Um exemplo hipotético de perfil baseado em correlação do setor de seguros poderia ser quando uma companhia estabelece diferença entre os perfis de risco das pessoas que buscam seus serviços via e-mail, aplicativos de celular ou sítio eletrônico. A hora do dia em que o formulário de solicitação é enviado pode representar algo, assim como o tempo que o cliente despense preenchendo o formulário-padrão. Qualquer pessoa vai entender que o fato de uma pessoa escolher preencher um formulário à tarde e não à noite, ou somente durante um feriado, não determina o risco maior ou menor daquela pessoa ao seguro pretendido. Um consumidor que tomou ciência dos termos de uso e política de privacidade de uma Companhia A que oferece produtos on-line, e decidiu preencher o formulário durante o horário em que deveria estar dormindo, não apresenta, portanto, um risco maior de morrer prematuramente. Aparentemente, porém, é verdade que as pessoas que procuram um seguro de vida ou seguro de acidentes em um determinado dia da semana ou horário geralmente têm certas características que as tornam aparentemente mais organizadas, cuidadosas ou saudáveis que outras. Assim, embora exista uma correlação entre quando as pessoas preenchem e enviam suas propostas de seguro e a maior ou menor expectativa de vida, não existe uma relação de causalidade.

## 2. Possibilidade de extração de informações com base em correlações.

Para análise desse ponto é necessário ampliar as noções sobre a possibilidade de as empresas conhecerem seus clientes através de perfis e aprendizado de máquinas.

24 Um interessante e, até certo ponto, aterrador panorama dessa potencialidade algorítmica foi anunciada em matéria jornalística veiculada em 2018 pela agência de notícias BBC News Brasil, em DUARTE, F.: “Nove algoritmos que podem estar tomando decisões sobre sua vida - sem você saber”. Disponível em <https://www.bbc.com/portuguese/geral-42908496>. Acesso em 22 de novembro de 2022.

Atualmente, os seres humanos limitam-se a considerar as informações que a mente humana facilmente compreende, tais como informações sobre renda, dívidas, composição familiar, histórico médico dos indivíduos etc. Entendemos quais as conclusões sobre a solvência ou a expectativa de vida do cliente podem ser tiradas a partir destas informações. Compreendemos que um cliente é fumante e sedentário (causa A), e que isto possivelmente o levará a uma doença incapacitante em poucos anos (consequência B). As correlações são mais difíceis de entender. Podemos concluir que há um maior risco de morte prematura porque o cliente viveu em um código postal que corresponda a uma região periférica da sua cidade, apresentou sua proposta de seguro tarde da noite por meio de um aplicativo de celular, houve erros ortográficos no formulário por ele preenchido e os seus amigos mais próximos do Facebook não têm bons empregos? O elo causal entre estas informações e os riscos a serem considerados na subscrição de produtos securitários não é tão forte – nem completamente ausente –, mas é possível que na prática estas informações sejam um melhor preditor<sup>25</sup> da maior expectativa de vida do cliente ou de sua capacidade de pagar suas contas no futuro do que sua renda comprovada e seus hábitos de vida atuais declarados<sup>26</sup>.

Nesse cenário, é preciso ampliar a compreensão sobre métodos alternativos de avaliação do cliente, mesmo que nós, baseados em nossa limitada compreensão humana, não entendamos a lógica e não possamos detectar inteiramente os elos causais presentes no método de operação. A condição, entretanto, é que a empresa fornecedora dos produtos e serviços ofertados possa demonstrar que estes métodos alternativos, no mais das vezes, definam e caracterizem o cliente tal qual seria possível pelos métodos usuais. É admissível, por óbvio, que em um ou outro caso concreto, o método alternativo falhe. Afinal, mesmo o método comum, se comparado com o método alternativo, não está livre de erros e poderá caracterizar os clientes pior do que o método alternativo.

#### IV. AS CONDIÇÕES DO RGPD PARA A APLICAÇÃO DE TOMADA DE DECISÃO AUTOMATIZADA NO ÂMBITO DO SETOR DE SEGUROS.

O RGPD estabelece condições para a aplicação da tomada de decisão automatizada. É preciso discutir, assim, quando estas condições se aplicam, para depois examinar estas condições e eventuais entraves que podem ser esperados na prática no setor de seguros.

25 Sobre análises preditivas, ver MÜHLHOFF, R.: "Predictive privacy: towards an applied ethics of data analytics", *Ethics and Information Technology*, 2021, v. 23, núm. 4, pp. 675-690.

26 Nesse sentido, uma recente pesquisa que avalia um modelo baseado em rede de inteligência artificial para prever os prêmios dos seguros de saúde, em KAUSHIK, K., BHARDWAJ, A., DWIVEDI, A.D., SINGH, R.: "Machine Learning-Based Regression Framework to Predict Health Insurance Premiums", *International Journal of Environmental Research and Public Health*, 2022, v. 19, 2022, 7898.

## I. Momento da aplicação das condições previstas no RGPD para a tomada de decisão automatizada.

O RGPD associa condições rígidas à tomada de decisão automatizada se duas circunstâncias a serem discutidas abaixo forem atendidas. Na ausência destas circunstâncias, as condições discutidas não se aplicam.

### A) *Consequências legais ou outras consequências materiais para o cliente.*

A primeira circunstância a considerar é se há consequências jurídicas associadas a esta tomada de decisão, ou se esta mesma tomada de decisão afeta o cliente de outra forma significativa<sup>27</sup>.

Quando uma decisão afeta o cliente de forma significativa não é exatamente claro. O Considerando 71 do RGPD só menciona como exemplo “a recusa automática de um pedido de crédito por via eletrónica”<sup>28</sup>. Uma primeira interpretação possível é que o cliente será significativamente afetado por uma decisão em particular se a seguradora estiver agindo como contraparte desse cliente, ou seja, nas decisões sobre a contratação<sup>29</sup>. Uma decisão de uma

27 É o que dispõe o artigo 22º (1), do RGPD: “O titular dos dados tem o direito de não ficar sujeito a nenhuma decisão tomada exclusivamente com base no tratamento automatizado, incluindo a definição de perfis, que produza efeitos na sua esfera jurídica ou que o afete significativamente de forma similar”. Ao depois, mesmo que a tomada de decisão automatizada não afete significativamente o cliente, várias obrigações de transparência são aplicadas aos casos de contratação de crédito ou seguros. Ver Grupo de Trabalho do Artigo 29º para a Proteção de Dados, *Orientações sobre as decisões individuais automatizadas e a definição de perfis para efeitos do Regulamento (UE) 2016/679*, adotadas em 3 de outubro de 2017 e com a última redação revista e adotada em 6 de fevereiro de 2018, pp. 23-25. Disponível em <https://ec.europa.eu/newsroom/article29/items/612053/en> (versão em português). Acesso em 14 de novembro de 2022.

28 Considerando 71: “O titular dos dados deverá ter o direito de não ficar sujeito a uma decisão, que poderá incluir uma medida, que avalie aspetos pessoais que lhe digam respeito, que se baseie exclusivamente no tratamento automatizado e que produza efeitos jurídicos que lhe digam respeito ou o afetem significativamente de modo similar, como a recusa automática de um pedido de crédito por via eletrónica ou práticas de recrutamento eletrónico sem qualquer intervenção humana. Esse tratamento inclui a definição de perfis mediante qualquer forma de tratamento automatizado de dados pessoais para avaliar aspetos pessoais relativos a uma pessoa singular, em especial a análise e previsão de aspetos relacionados com o desempenho profissional, a situação económica, saúde, preferências ou interesses pessoais, fiabilidade ou comportamento, localização ou deslocações do titular dos dados, quando produza efeitos jurídicos que lhe digam respeito ou a afetem significativamente de forma similar. No entanto, a tomada de decisões com base nesse tratamento, incluindo a definição de perfis, deverá ser permitida se expressamente autorizada pelo direito da União ou dos Estados-Membros aplicável ao responsável pelo tratamento, incluindo para efeitos de controlo e prevenção de fraudes e da evasão fiscal, conduzida nos termos dos regulamentos, normas e recomendações das instituições da União ou das entidades nacionais de controlo, e para garantir a segurança e a fiabilidade do serviço prestado pelo responsável pelo tratamento, ou se for necessária para a celebração ou execução de um contrato entre o titular dos dados e o responsável pelo tratamento, ou mediante o consentimento explícito do titular. Em qualquer dos casos, tal tratamento deverá ser acompanhado das garantias adequadas, que deverão incluir a informação específica ao titular dos dados e o direito de obter a intervenção humana, de manifestar o seu ponto de vista, de obter uma explicação sobre a decisão tomada na sequência dessa avaliação e de contestar a decisão. Essa medida não deverá dizer respeito a uma criança”.

29 Neste sentido, consultar o Grupo de Trabalho do Artigo 29º para a Proteção de Dados, *Orientações sobre as decisões individuais automatizadas e a definição de perfis para efeitos do Regulamento (UE) 2016/679*, adotadas em 3 de outubro de 2017 e com a última redação revista e adotada em 6 de fevereiro de 2018, p. 11. Consultar também as *Guidelines for identifying a controller or processor's lead supervisory authority*, 5 April 2017, pp. 11-12. Disponível em [https://ec.europa.eu/newsroom/document.cfm?doc\\_id=44102](https://ec.europa.eu/newsroom/document.cfm?doc_id=44102). Acesso em 22 de novembro de 2022. Importante referir que em 10 de outubro de 2022, o Comitê Europeu para a

seguradora não fornecer um produto ou apenas a um preço desfavorável pode significar que o cliente acabe pagando mais ou que o produto financeiro não possa comprá-lo de forma alguma.

Entretanto, quando a empresa age como consultora ou intermediária em nome do cliente – uma corretora, por exemplo – é pouco provável que este cliente seja afetado significativamente pela tomada de decisões automáticas. Afinal de contas, um cliente pode sempre optar por desconsiderar a orientação ou procurar outro intermediário. Além disso, os interesses de um intermediário/consultor geralmente são paralelos aos do cliente, enquanto uma parte que vende um produto ao cliente pode ter um interesse conflitante. Portanto, as regras sobre tomada de decisão automatizada geralmente não se aplicam se à empresa que estiver em uma função consultiva ou intermediária, mas frequentemente o fazem se ela oferecer um produto financeiro ao cliente na condição de contraparte.

Ao depois, deve-se ter presente que nem toda decisão relativa a um produto financeiro tem um impacto significativo sobre o cliente. A decisão de oferecer uma apólice de seguro-viagem com uma tarifa um pouco mais cara é de ordem diferente da decisão de cobrar juros extras em um financiamento imobiliário de médio e longo prazo.

#### B) Nenhum envolvimento humano.

A segunda circunstância é que nenhum ser humano está envolvido na tomada de decisão. Entretanto, o simples envolvimento formal de um ser humano em uma decisão é insuficiente<sup>30</sup>. Assim, uma empresa só é excluída das obrigações associadas à tomada de decisão automatizada se as decisões do computador forem endossadas por uma pessoa que realmente faz sua própria avaliação. A fim de fazer esta avaliação, o ser humano também terá que ser capaz de entender qualquer orientação passada pelo computador, o que nem sempre é fácil no caso de decisões baseadas no aprendizado da máquina.

---

Proteção de Dados (European Data Protection Board - EDPB) adotou as *Guidelines 8/2022 on identifying a controller or processor's lead supervisory authority*, disponível em [https://edpb.europa.eu/system/files/2022-10/edpb\\_guidelines\\_202208\\_identifyinglsa\\_targetedupdate\\_en.pdf](https://edpb.europa.eu/system/files/2022-10/edpb_guidelines_202208_identifyinglsa_targetedupdate_en.pdf). Trata-se de uma versão atualizada das Diretrizes WP244 (rev.01) anteriores, que foram adotadas em 13 de fevereiro de 2016 pelo Grupo de Trabalho do Artigo 29° e depois aprovadas pela EDPB em 25 de maio de 2018. O novo texto está sendo submetido a uma breve consulta pública até o dia 2 de dezembro de 2022. Ver páginas 13 a 14.

30 Grupo de Trabalho do Artigo 29° para a Proteção de Dados, *Orientações sobre as decisões individuais automatizadas e a definição de perfis para efeitos do Regulamento (UE) 2016/679*, adotadas em 3 de outubro de 2017 e com a última redação revista e adotada em 6 de fevereiro de 2018, pp. 10-11.

## 2. Condições que devem ser satisfeitas na tomada de decisões automatizada.

Se as duas circunstâncias acima ocorrerem, então a tomada de decisão automatizada só é permitida se todas as quatro condições discutidas abaixo forem atendidas<sup>31</sup>.

### A) Motivos válidos para tomada de decisão automatizada.

Deve haver um motivo válido para aplicar a tomada de decisão automatizada. O RGPD elenca três fundamentos:

*i. a decisão é necessária para a celebração ou a execução de um contrato entre o titular dos dados e um responsável pelo tratamento*

Este fundamento não é facilmente satisfeito. A razão para isto é que a necessidade é interpretada de forma estrita<sup>32</sup>. Em particular, um pequeno ganho de eficiência por si só não será suficiente para satisfazer a necessidade<sup>33</sup>. Portanto, terá que haver pelo menos um grande ganho de eficiência para que a empresa possa confiar neste fundamento.

*ii. a decisão é autorizada por uma disposição da legislação da União ou da legislação dos Estados-Membros aplicável ao responsável pelo tratamento, que também prevê medidas adequadas para proteger os direitos e liberdades e os legítimos interesses de pessoa titular dos dados.*

Este poderia ser especialmente o caso se as transações realizadas no contexto do mercado segurador que forem automaticamente suspensas para impedir a lavagem de dinheiro ou o financiamento do terrorismo<sup>34</sup>.

*iii. a decisão se baseia no consentimento explícito da pessoa em questão*

31 Vide artigo 22 do RGPD.

32 Grupo de Trabalho do Artigo 29º para a Proteção de Dados, *Orientações sobre as decisões individuais automatizadas e a definição de perfis para efeitos do Regulamento (UE) 2016/679*, adotadas em 3 de outubro de 2017 e com a última redação revista e adotada em 6 de fevereiro de 2018, p. 14. Ver também Information Commissioner's Office, *Big data, artificial intelligence, machine learning and data protection*, versão 2.2, 2017, p. 35. Disponível em <https://ico.org.uk/media/for-organisations/documents/2013559/big-data-ai-ml-and-data-protection.pdf>. Acesso em 22 de novembro de 2022.

33 Grupo de Proteção de Dados do Artigo 29º, *Parecer 3/2012 sobre a evolução das tecnologias biométricas*, adotado em 27 de abril de 2012, pp. 8-10. Disponível em [https://ec.europa.eu/justice/article-29/documentation/opinion-recommendation/files/2012/wp193\\_pt.pdf](https://ec.europa.eu/justice/article-29/documentation/opinion-recommendation/files/2012/wp193_pt.pdf). Acesso em 22 de novembro de 2022.

34 As regras europeias em matéria de combate à lavagem de dinheiro e ao financiamento do terrorismo são igualmente aplicáveis ao mercado segurador e foram consideravelmente reforçadas nos últimos anos, com a adoção de reformas consecutivas desde 2015, com destaque para as revisões da Diretiva Branqueamento de Capitais (Diretiva (UE) 2015/849 do Parlamento Europeu e do Conselho, de 20 de maio de 2015), por meio da Diretiva (UE) 2018/843, de 30 de maio de 2018 e da Diretiva (UE) 2019/2177, de 18 de dezembro de 2019. A propósito, ver Conselho da União Europeia, *Conclusions on an Anti-Money Laundering Action Plan*, de 4 de dezembro de 2018. Disponível em <https://www.consilium.europa.eu/media/37283/st15164-en18.pdf>. Acesso 22 de novembro de 2022.

O consentimento explícito também não pode ser facilmente obtido pela empresa. Fato é que o consentimento não só deve ser explícito, mas também ser dado livremente. O consentimento não é considerado livre se o cliente não tem escolha real de renunciar ao consentimento. Essa escolha real não existe se o cliente que recusa o consentimento não pode então adquirir o produto ou serviço de nenhum modo ou apenas de forma mais dispendiosa<sup>35</sup>. Se a empresa não puder atender a nenhum desses fundamentos, então a tomada de decisão automatizada não é permitida.

#### B) Nenhum uso de categorias especiais de dados.

A tomada de decisão automatizada não deve ser baseada em categorias especiais de dados pessoais. O RGPD menciona: origem racial ou étnica, opiniões políticas, crenças religiosas ou filosóficas, filiação sindical, dados genéticos, dados biométricos com o propósito de identificar de forma única uma pessoa, ou dados relativos à saúde, ou dados relativos ao comportamento sexual ou orientação sexual de uma pessoa<sup>36</sup>.

Uma exceção a isto é novamente possível se o cliente consente explicitamente ao tratamento destas categorias especiais de dados pessoais ou devido a razões de interesse público substancial<sup>37</sup>. Mesmo se o consentimento for obtido, estas informações não podem ser usadas para discriminar injustificadamente.

Informações úteis sobre a lógica subjacente, assim como a importância e as consequências esperadas desse processamento para o cliente, devem ser fornecidas<sup>38</sup>. Pode ser complicado explicar ao cliente a lógica das decisões

35 Grupo de Trabalho do Artigo 29º para a Proteção de Dados, *Orientações sobre as decisões individuais automatizadas e a definição de perfis para efeitos do Regulamento (UE) 2016/679*, adotadas em 3 de outubro de 2017 e com a última redação revista e adotada em 6 de fevereiro de 2018, p. 22; EDPB, *Diretrizes 05/2020 relativas ao consentimento na ação do Regulamento 2016/679*, p. 11. Disponível em [https://edpb.europa.eu/sites/default/files/files/file/edpb\\_guidelines\\_202005\\_consent\\_pt.pdf](https://edpb.europa.eu/sites/default/files/files/file/edpb_guidelines_202005_consent_pt.pdf). Acesso em 22 de novembro de 2022.

36 RGPD, artigo 9º, I, RGPD: “É proibido o tratamento de dados pessoais que revelem a origem racial ou étnica, as opiniões políticas, as convicções religiosas ou filosóficas, ou a filiação sindical, bem como o tratamento de dados genéticos, dados biométricos para identificar uma pessoa de forma inequívoca, dados relativos à saúde ou dados relativos à vida sexual ou orientação sexual de uma pessoa”. Ver também Considerandos 51, 71 e 75.

37 Ver RGPD, artigo 9º, 2, alíneas a, b, c, d, e, f, g, h, i, j e parágrafo 3.

38 RGPD, artigo 14º: “1. Quando os dados pessoais não forem recolhidos junto do titular, o responsável pelo tratamento fornece-lhe as seguintes informações: a) A identidade e os contactos do responsável pelo tratamento e, se for caso disso, do seu representante; b) Os contactos do encarregado da proteção de dados, se for caso disso; c) As finalidades do tratamento a que os dados pessoais se destinam, bem como o fundamento jurídico para o tratamento; d) As categorias dos dados pessoais em questão; e) Os destinatários ou categorias de destinatários dos dados pessoais, se os houver; f) Se for caso disso, o facto de o responsável pelo tratamento tencionar transferir dados pessoais para um país terceiro ou uma organização internacional, e a existência ou não de uma decisão de adequação adotada pela Comissão ou, no caso das transferências mencionadas nos artigos 46º ou 47º, ou no artigo 49º, nº I, segundo parágrafo, a referência às garantias apropriadas ou adequadas e aos meios de obter cópia das mesmas, ou onde foram disponibilizadas; 2. Para além das informações referidas no nº 1, o responsável pelo tratamento fornece ao titular as seguintes informações, necessárias para lhe garantir um tratamento equitativo e transparente:

automatizadas, mas isto não é, na opinião do Grupo de Trabalho do Artigo 29º, uma desculpa para omiti-la<sup>39</sup>.

O Grupo de Trabalho do Artigo 29º considera que o objetivo desta explicação é permitir que os clientes contestem o resultado de uma decisão. Dá como exemplo a explicação que uma empresa que rejeita um pedido de empréstimo deve fornecer<sup>40</sup>: “O responsável pelo tratamento explica que este processo o ajuda a tomar decisões de concessão de empréstimo equitativas e responsáveis. Fornece os dados relativos às principais características consideradas na tomada da decisão, a fonte dessas informações e a sua relevância, o que pode incluir, por exemplo: as informações fornecidas pelo titular dos dados no formulário de pedido; informações sobre a anterior gestão própria da conta, incluindo eventuais atrasos em pagamentos; e informações de registos públicos oficiais, designadamente informações de registos de fraudes e registos de insolvências”.

O nível de detalhamento deste dever de explicação pode colocar problemas práticos ao minar a praticidade de certos modelos. Estes envolvem modelos baseados na correlação, não na causalidade.

Com efeito, no exemplo acima mencionado, que bem pode ser adaptado à hipótese de uma contratação de seguro, algumas companhias podem considerar o momento em que o cliente preenche um formulário de proposta de seguro e através de qual canal de aquisição esse cliente chegou até essa companhia. Entretanto, uma vez que um cliente saiba disto, ele ajustará facilmente este comportamento e assim jogará com o sistema. Ele ainda acessará o site da seguradora por um diverso – em vez de utilizar um link de acesso disponibilizado nas redes sociais – e preencherá o formulário em horário comercial, evitando o acesso durante a madrugada.

Não obstante, isso não fará desse cliente um segurado melhor. Em outras palavras, certos sistemas são inúteis se o cliente souber exatamente o que está

---

[...] g) A existência de decisões automatizadas, incluindo a definição de perfis referida no artigo 22º, nº 1 e 4, e, pelo menos nesses casos, informações úteis relativas à lógica subjacente, bem como a importância e as consequências previstas de tal tratamento para o titular dos dados”.

39 *Parecer 3/2012 sobre a evolução das tecnologias biométricas*, adotado em 27 de abril de 2012, p. 10. O responsável pelo tratamento deve encontrar formas simples de informar o titular dos dados sobre a lógica subjacente ou os critérios em que se baseou para chegar à decisão. O RGPD exige que o controlador forneça informações significativas sobre a lógica envolvida, não necessariamente uma explicação complexa dos algoritmos usados ou a divulgação do algoritmo completo. As informações fornecidas devem, no entanto, ser suficientemente abrangentes para que o titular dos dados entenda os motivos da decisão. A complexidade não é desculpa para a falta de informação ao titular dos dados. O Considerando 58 do RGPD refere que o princípio da transparência é “especialmente relevante em situações em que a proliferação de operadores e a complexidade tecnológica das práticas tornam difícil que o titular dos dados saiba e compreenda se, por quem e para que fins os seus dados pessoais estão a ser recolhidos, como no caso da publicidade por via eletrónica”.

40 *Orientações sobre as decisões individuais automatizadas e a definição de perfis para efeitos do Regulamento (UE) 2016/679*, adotadas em 3 de outubro de 2017 e com a última redação revista e adotada em 6 de fevereiro de 2018, p. 28.

fazendo. Isto é diferente dos modelos baseados na causalidade. Por exemplo, um segurado que entende que pagará menos prêmio se deixar de fumar e ajustar seu comportamento pagará, com razão, menos a título de prêmio – uma situação, diga-se, quase óbvia, já que o risco de um sinistro sob a apólice de seguro de vida diminuiu. Por isso, não há problemas práticos se o segurado estiver ciente da exata relação exata entre seu comportamento tabagista e o valor do prêmio do seguro pretendido.

C) *Direito à intervenção humana e oportunidade de contestar a decisão.*

Em um contexto de estabelecimento de garantias, a empresa deve tomar medidas apropriadas para proteger os direitos e liberdades do cliente e os legítimos interesses, incluindo pelo menos o direito à intervenção humana na tomada de decisões, o direito de expressar seu ponto de vista e o direito de contestar a decisão<sup>41</sup>.

Existem aqui duas complicações. Primeiro, há a complicação factual de que nas decisões baseadas no aprendizado por máquina, o fator decisivo para uma decisão nem sempre é fácil de identificar, pois a lógica pode ser difícil de ser compreendida pelos humanos. Isto pode exigir um esforço significativo por parte da empresa de seguros para ainda compreender quais fatores no caso do cliente levaram a uma decisão específica<sup>42</sup>. Em segundo lugar, o direito de contestar o mérito de uma decisão é de grande alcance se comparado com decisões que não são tomadas por computador. Uma empresa de seguros é aparentemente livre para determinar sua própria política de preços e, ao fazê-lo, decidir por si mesma quais serão as circunstâncias que deseja levar em consideração ao determinar, por exemplo, o valor do prêmio. Daí que, a não ser que o direito interno de um determinado Estado-Membro preveja, não se impõem circunstâncias que devem ser levadas em consideração ao determinar o valor de um prêmio<sup>43</sup>.

41 RGPD, artigo 22º, 3: “Nos casos a que se referem o n.º 2, alíneas a) e c), o responsável pelo tratamento aplica medidas adequadas para salvaguardar os direitos e liberdades e legítimos interesses do titular dos dados, designadamente o direito de, pelo menos, obter intervenção humana por parte do responsável, manifestar o seu ponto de vista e contestar a decisão”.

42 Para maiores aprofundamentos, ver DOSHI-VELEZ, F., KORTZ, M.; BUDISH, R., BAVITZ, C., GERSHMAN, S., O'BRIEN, D., SHIEBER, S., WALDO, J., WEINBERGER, D., WOOD, A.: “Accountability of AI Under the Law: The Role of Explanation”, *Berkman Center Research Publication*, 2017, Forthcoming, p. 7. Disponível em <https://cyber.harvard.edu/publications/2017/11/AIExplanation>. Acesso em 22 de novembro de 2022.

43 Ressalva há de ser feita quanto a diferenças proporcionais nos prêmios e prestações dos segurados quando o sexo é um fator determinante. Neste sentido é a declaração de invalidade do artigo 5º, 2, da Diretiva 2004/113/CE de 13 de dezembro de 2004, que aplica o princípio de igualdade de tratamento entre homens e mulheres no acesso a bens e serviços e seu fornecimento, pelo Tribunal de Justiça da União Europeia (TJUE), causa C-236/09, *Association Belge des Consommateurs Test-Achats ASBL e o. contra Reino da Bélgica*, em 1º de março de 2011. Disponível em <https://curia.europa.eu/juris/document/document.jsf?text=&docid=80019&pageIndex=0&doclang=PT&mode=lst&dir=&occ=first&part=1&cid=255873>. Acesso em 22 de novembro de 2022.

Assim, uma seguradora é livre para fazer uma oferta com base nas condições que deu a conhecer prévia e inequivocamente ao interessado. O fato de uma seguradora escolher determinar o valor do prêmio de um seguro com base em uma classificação objetiva – por exemplo, uma tabela fixa – e não com base em uma avaliação mais individual pertence à sua liberdade política e não é contrário a qualquer obrigação que recaia sobre o segurador.

Agora suponha-se que a mesma decisão não tenha sido tomada por um funcionário da companhia, mas pelo computador; a empresa seguradora teria agora que fundamentar sua decisão de forma mais abrangente e incluir mais dados em seu julgamento?

O Grupo de Trabalho do Artigo 29º parece considerar que este é o caso<sup>44</sup>: “A intervenção humana é um elemento essencial. Qualquer revisão tem de ser levada a cabo por alguém com a devida autoridade e competência para alterar a decisão. O revisor deve realizar uma avaliação exaustiva de todos os dados pertinentes, incluindo quaisquer informações adicionais transmitidas pelo titular dos dados”.

Na prática, isso pode ser visto de duas maneiras. Ou o direito de contestar uma decisão, a nosso ver, não servirá muito.

Uma empresa de seguros precisa apenas explicar como chegou a uma decisão. A ideia é que isto permite ao cliente descobrir erros ou omissões nos algoritmos que são prejudiciais a ele e trazê-los à atenção da seguradora. Entretanto, o cliente deve respeitar a política discricionária da empresa em não considerar certas informações.

A outra possibilidade é que as empresas de seguros também deverão ser capazes de fundamentar uma decisão e explicar porque ela se justifica. A liberdade de uma seguradora para estabelecer seu preço, por exemplo, ou para determinar qual cliente ela aceita ou não, será restringida. Neste último caso, espera-se que isso não se limite a decisões automatizadas. Afinal, é estranho que, se uma decisão é tomada por um humano em vez de um computador, isso também permitiria que tivesse um conteúdo diferente.

## V. DISCRIMINAÇÃO DE PREÇOS E A RECUSA DE FORNECIMENTO COM BASE NO PERFIL.

O próximo aspecto da definição de perfis que precisa de especial atenção é a possibilidade de longo alcance de discriminação de preços.

<sup>44</sup> *Orientações sobre as decisões individuais automatizadas e a definição de perfis para efeitos do Regulamento (UE) 2016/679, adotadas em 3 de outubro de 2017 e com a última redação revista e adotada em 6 de fevereiro de 2018, p. 30.*

De fato, a definição de perfis permite conhecer melhor o cliente e, assim, cobrar um preço especificamente adaptado a ele para um produto ou serviço<sup>45</sup>. Uma empresa não tem que recusar explicitamente os clientes ou fazer suas próprias ofertas a clientes diferentes. O marketing baseado em perfis permite que uma empresa atraia um grupo específico de clientes em particular, mas isso pode ter consequências.

No âmbito do Sistema Europeu de Supervisão Financeira (SESF)<sup>46</sup>, desde 2016 a opinião expressada pelas Autoridades Europeias de Supervisão (AES) é de preocupação sobre isso: “More granular segmentations could however also lead to access issues for some consumers classified as undesirable. For example, in the insurance sector, the result of a more granular risk segmentation could lead either to higher premiums for certain customers or to certain customers (with high risks or unusual profiles) having difficulties accessing (certain types of) insurance cover. This could create difficulties for consumers seeking household insurance for real estate properties located in geographical areas exposed to high risks such as floods, earthquakes or crime. The latter could eventually have broader social consequences and require action protecting the general good, since obtaining household insurance is a legal requirement in several Member States for renting or owning real estate properties. The increasing individualisation of risk profiles could have, to a certain extent, implications for the principle of solidarity and risk pooling in the insurance sector”<sup>47</sup>.

O mesmo fez a Organização para a Cooperação e Desenvolvimento Econômico (OECD): “Technology driven: the increasing use of algorithms, which can affect decisions about credit, insurance or investments and can lead to denied access to certain services or inappropriate charges based on inaccurate or wrong correlations made without human interpretation; misuse of data including big data and small data (e.g transactional, airtime data); unreliability of mobile networks and digital finance platforms may lead to inability to carry out transactions, inaccessibility of funds or cybersecurity risks”<sup>48</sup>.

45 Ver ZUIDERVEEN BORGESIU, F., POORT, J.: “Online Price Discrimination and EU Data Privacy Law”, *Journal Consum Policy*, 2017, v. 40, pp. 347-366.

46 O SESF é composto pelo Comitê Europeu do Risco Sistêmico (CERS), pelas três Autoridades Europeias de Supervisão – designadamente a Autoridade Bancária Europeia (EBA), a Autoridade Europeia dos Valores Mobiliários e dos Mercados (ESMA) e a Autoridade Europeia dos Seguros e Pensões Complementares de Reforma (EIOPA) – pelo Comitê Conjunto das AES e pelos supervisores nacionais. O principal objetivo do SESF é assegurar que as regras aplicáveis ao setor financeiro sejam impostas adequadamente em todos os Estados-Membros, de modo a preservar a estabilidade financeira, promover a confiança e proteger os consumidores.

47 Joint Committee of the European Supervisory Authorities: *Joint Committee Discussion Paper on the Use of Big Data by Financial Institutions*, 19 December 2016, JC/2016/86, p. 22. Disponível em [https://www.esma.europa.eu/sites/default/files/library/jc-2016-86\\_discussion\\_paper\\_big\\_data.pdf](https://www.esma.europa.eu/sites/default/files/library/jc-2016-86_discussion_paper_big_data.pdf). Acesso em 22 de novembro de 2022.

48 OECD (2018), G20/OECD: *Policy Guidance on Financial Consumer Protection Approaches in the Digital Age*, p. 13. Disponível em <https://www.oecd.org/finance/G20-OECD-Policy-Guidance-Financial-Consumer-Protection-Digital-Age-2018.pdf>. Acesso em 22 de novembro de 2022.

De acordo com as mesmas Autoridades Europeias de Supervisão, isto poderia entrar em conflito com a obrigação geral das empresas financeiras de levar em conta os interesses de seus clientes: “Firms’ price adjustments based on consumer features and behaviour-based factors could go against financial institutions’ overarching obligation to treat customers in a fair and nondiscriminatory manner. This could be particularly the case when insufficient transparency and disclosure measures about the pricing and segmentation criteria as well as the data sources used by financial institutions when profiling customers are in place”<sup>49</sup>.

Um caso de discriminação de preços explicitamente mencionado pela Autoridade Bancária Europeia (EBA) como um risco é aquele em que as empresas financeiras rejeitam reclamações justificadas porque determinaram, com base no perfil, que é improvável que um cliente dê seguimento à inconformidade. Refere-se ao risco de tais empresas possam explorar o *Big Data* de uma maneira que não seja do melhor interesse do consumidor, confiando na probabilidade estatística (previsibilidade) de que o consumidor aceitará a oferta inicial ou mesmo uma resposta negativa<sup>50</sup>.

Há dois tipos de discriminação de preços, ambos a provocar suas próprias preocupações do ponto de vista jurídico.

### I. Discriminação de preço com base no que o cliente está disposto a pagar.

No primeiro tipo de discriminação de preço, a uma determinada empresa custará o mesmo valor para oferecer um produto independentemente de quem é o cliente, mas a empresa ainda assim cobrará preços diferentes. Explica-se. Em um mercado normal, há clientes que estão dispostos a pagar mais por um produto - estes preferem-no ou desconhecem as alternativas mais baratas - e clientes sensíveis ao preço que só querem pagar pouco<sup>51</sup>. Se todos os clientes pagam o mesmo por um produto, então os clientes que estão dispostos a pagar mais se beneficiam da pressão de preços exercida pelos clientes sensíveis aos preços. Um exemplo: em uma rede de supermercados A, cada cliente paga o mesmo por uma

49 Joint Committee of the European Supervisory Authorities: *Joint Committee Discussion Paper on the Use of Big Data by Financial Institutions*, 19 December 2016, JC/2016/86, p. 22; e *Joint Committee Final Report on Big Data*, 15 March 2018, JC/2018/04, pp. 30-33. Disponível em [https://www.esma.europa.eu/sites/default/files/library/jc-2018-04\\_joint\\_committee\\_final\\_report\\_on\\_big\\_data.pdf](https://www.esma.europa.eu/sites/default/files/library/jc-2018-04_joint_committee_final_report_on_big_data.pdf). Acesso em 22 de novembro 2022.

50 *Discussion Paper on the EBA’s approach to financial technology (FinTech)*, 4 August 2017, EBA/DP/2017/02, p. 48. Disponível em <https://www.eba.europa.eu/sites/default/documents/files/documents/10180/1919160/7a1b9cda-10ad-4315-91ce-d798230ebd84/EBA%20Discussion%20Paper%20on%20Fintech%20%28EBA-DP-2017-02%29.pdf?retry=1>. Acesso em 22 de novembro de 2022.

51 A propósito do tema, cabe dizer que o preço há muito vem sendo estudado sob várias perspectivas e níveis de intensidade, notadamente pelas ciências econômicas, psicologia, finanças e mesmo marketing, em que pese este último tenha contribuído muito pouco para a eficácia de apereçamento por parte das empresas. Há de se considerr também uma certa discrepância entre a teoria e a prática no estudo do preço, devido principalmente à negligência, aos problemas de informação, quantificação e implementação de modelos teóricos de precificação. Para aprofundamentos, ver SIMON, H.: *Price management*, Elsevier Science Publishers, Amsterdam, 1989, p. 40.

garrafa de refrigerante de dois litros, ou seja, 2 euros. É bem possível que haja clientes dispostos a pagar 2,20 euros por este mesmo produto. Somente se o preço passa a ser de 3 euros os clientes irão considerá-lo excessivo e, por isso, irão procurar a rede de supermercado B. No entanto, alguns clientes farão um desvio para as lojas de B mesmo se houver um pequeno aumento de preço. Como o a rede A não quer perder esses clientes conscientes do preço e cada cliente paga o mesmo pela garrafa de refrigerante, os clientes menos conscientes do preço se beneficiam da pressão de preços exercida pelos clientes conscientes do preço. Acontece que a empresa pode tentar cobrar de cada cliente o máximo que ele está disposto a pagar. Isto significa que cada cliente recebe o seu preço individual e, ao conhecer o cliente da melhor forma possível, a empresa cobra exatamente o que o cliente está disposto a pagar.

Retomando o exemplo anterior: alguns clientes continuam a pagar 2 euros, pois caso contrário correm o risco de se dirigem para as lojas da rede de supermercados B; outros clientes, entretanto, pagarão 2,20 euros pelo mesmo produto, pois mesmo com este preço, este grupo não migrará para a concorrência. Em muitos mercados, esta discriminação de preços já ocorre.

Do mesmo modo, muitos consumidores frequentemente pagam valores diferentes pelo mesmo modelo de automóvel. É comum que nas negociações o revendedor sempre tente descobrir onde está o limite pessoal do cliente, isto é, o ponto em que fará com que este mesmo cliente vá à procura de outro revendedor ou desista de comprar um carro. Os vários sistemas de bônus, cartões de desconto e programas de fidelidade, entre outros, também tentam distinguir entre o cliente sensível ao preço e o cliente que não o é. Por exemplo, o cliente sensível ao preço participará de ofertas específicas de bônus e descontos, enquanto o cliente da outra categoria comprará o que for conveniente a ele e não se dará ao trabalho de juntar selos e recortar cupons de desconto<sup>52</sup>.

A questão a considerar, por fim, é se isso pode ser admitido quando praticado por empresas de seguros.

## 2. Discriminação com base nas características do cliente.

No segundo tipo de discriminação de preços, os custos de produção de um produto ou serviço dependem de quem é o cliente. Por exemplo, o seguro de

52 Embora não seja objeto deste estudo, segundo a doutrina especializada, todo comprador seria sensível ao preço, porém esta sensibilidade pode variar tremendamente de uma situação para outra. Essa variação ocorreria de acordo com a importância da satisfação que o produto proporciona, ou o sacrifício necessário para adquirir o bem. Ter somente consumidores sensíveis como alvo, pode significar que a empresa está deixando de faturar. Para mais aprofundamentos, ver NAGLE, T. T., HOLDEN, R.K.: *Estratégia e Táticas de Preços: um guia para decisões lucrativas*, Person, São Paulo, 2003, *passim*; KOTLER, P., KELLER, K. L.: *Administração de marketing*, Pearson Education do Brasil, São Paulo, 2012, pp. 163-188; LAMBIN, J.: *Marketing Estratégico*. McGraw-Hill Interamericana de España S.L, Madrid, 1995, pp. 467-515.

vida é mais caro para um fumante, pois estes geralmente morrem mais cedo. Atualmente, em muitos lugares da União Europeia os fumantes já pagam mais do que os não fumantes por seguros desse tipo. No entanto, em outras partes do mundo já existem companhias de seguro de saúde que correlacionam o prêmio do seguro aos hábitos de consumo e estilo de vida do cliente<sup>53</sup>. Mas também é possível relacionar todos os tipos de arquivos de dados.

Agora suponha que uma seguradora passe a considerar que as pessoas desempregadas geralmente têm mais problemas de saúde do que as pessoas empregadas. Você perde seu emprego e muda seu status no LinkedIn para “Open to Work”. Como consequência, você é então recusado ao tentar contratar um seguro-saúde. Este exemplo ilustra que se as seguradoras souberem mais sobre o cliente, a solidariedade entre os clientes pode estar sob pressão<sup>54</sup>, o que, no caso mais extremo, pode resultar na recusa de fornecer um serviço ou produto a um cliente<sup>55</sup>.

A esse ponto cabe observar que questão não é apenas até que ponto esta distinção é legalmente permitida, mas também se tal distinção e o uso de dados nessas situações são atos socialmente aceitáveis. Isso porque costumamos atribuir particular importância e somos bastante sensíveis ao uso de dados pessoais por parte das instituições financeiras. As expectativas da sociedade são maiores, porque maiores são os riscos e maiores podem ser as perdas para os consumidores<sup>56</sup>.

53 Faz-se referência ao caso do seguro de vida oferecido por *John Hancock Life Insurance Company*, uma companhia de seguros fundada em 1862, com sede em Boston, Estados Unidos da América. Esta companhia passou a oferecer uma solução inovadora que atribui pontos pela prática de um estilo de vida saudável. Para tal, quando o cliente adere ao seguro recebe um *smartwatch*, e a quantia associada à mensalidade paga pelo relógio é determinada pela quantidade de exercício físico realizado pelo consumidor durante o mês. Segundo anunciado no seu sítio eletrônico, a seguradora tem uma parceria com o *Vitality Group*, operando nos Estados Unidos e na África do Sul, que é uma subsidiária da *Discovery Limited*, um grupo de serviços financeiros com sede em Sandton, na África do Sul. Outros exemplos recentes são a *Policybazaar Insurance Brokers Private Limited* e da *ICICI Lombard General Insurance Company Limited*, ambas seguradoras com sede Índia, que oferecem descontos no prêmio dos seus seguros. Os clientes vinculam os seus dispositivos pessoais aos aplicativos das seguradoras, que recebem diretamente os dados de plataformas como Google Fit, Apple Health e Fitbit, integrados para rastrear as atividades de bem-estar do usuário.

54 SARLET, G. B. S; MOLINARO, C. A.: “Questões tecnológicas, éticas e normativas da proteção de dados pessoais na área da saúde em um contexto de big data”, *Direitos Fundamentais & Justiça*; 2019, v. 13, núm. 41, pp. 183-212.

55 É certo que o acesso ao seguro poderia ser aumentado para alguns consumidores. Como as ferramentas do *Big Data* permitem que as empresas estimem o risco com mais precisão, algumas seguradoras podem aumentar a oferta de produtos para esses consumidores. Inversamente, poderia resultar em seguradoras optando por não atender mais a certos perfis de consumidores, em particular aqueles que são consideradas de maior risco. Se todas, ou a maioria, das seguradoras fizerem análises semelhantes sobre a exclusão de certos consumidores devido aos seus perfis de risco, isso pode levar a que alguns consumidores não consigam mais encontrar cobertura. Ver Financial Conduct Authority, *Call for Inputs: Big Data in retail general insurance*, 2015, pp. 11-12. Disponível em <https://www.fca.org.uk/publication/consultation/big-data-call-for-inputs.pdf>. Acesso em 22 de novembro de 2022.

56 Autoridade Bancária Europeia (EBA), *Discussion Paper on innovative uses of consumer data by financial institutions*, 4 May 2016, EBA/DP/2016/01, p. 12. Disponível em <https://www.eba.europa.eu/sites/default/documents/files/documents/10180/1455508/68e9f120-8200-4973-aabc-c147e9121180/EBA-DP-2016-01%20DP%20on%20innovative%20uses%20of%20consumer%20data%20by%20financial%20institutions.pdf?retry=1>. Acesso em 22 novembro de 2022.

## VI. A PROIBIÇÃO DE DISCRIMINAÇÃO POR MOTIVOS RACIAIS, ÉTNICOS, DE GÊNERO, RELIGIÃO E OUTROS APLICADA AO APRENDIZADO DE MÁQUINA.

Além da possibilidade de discriminação de preço discutida acima, o aprendizado por máquina e a definição de perfis também levam ao risco de discriminação. A essência da proibição de discriminação é que certas características de uma pessoa, incluindo sua origem racial ou étnica, ou religião, a menos que se justifique em um caso particularíssimos, não devem influenciar a forma como essa pessoa é tratada<sup>57</sup>. O mesmo se aplica a medidas com efeito semelhante. É importante perceber que mesmo um algoritmo pode discriminar.

### I. Discriminação devido a erros no engajamento do algoritmo.

Um algoritmo pode discriminar devido ao conjunto de dados pelo qual é alimentado e à forma como o algoritmo aprende<sup>58</sup>. Por exemplo, o Conselho de Estabilidade Financeira denomina “aprendizagem supervisionada”<sup>59</sup>. O algoritmo é alimentado com um conjunto de dados de “treinamento” que contém etiquetas em alguma parte das observações. Por exemplo, um conjunto de dados pode conter etiquetas em alguns pontos de dados identificando aqueles que são fraudulentos e aqueles que não são. O algoritmo “aprenderá” uma regra geral de classificação que usará para prever as etiquetas para as observações restantes no conjunto de dados. O algoritmo então pode obter os dados das propostas de um seguro com os dados indicando se o revisor humano a aprovou ou a desaprovou. O algoritmo reconhece os padrões e regras implícitas do revisor humano.

Entretanto, suponha que o revisor humano - inconscientemente ou não - tenha padrões e escolhas indesejáveis. Imagine-se a hipótese de análise de concessão de empréstimo por um banco. Se é provável que o avaliador humano recuse propostas de empréstimo de pessoas de aparência estrangeira, o algoritmo adotará este viés. Este risco existe mesmo que o conjunto de dados não declare explicitamente se alguém tem a aparência de um estrangeiro. Por exemplo, pessoas com aparência estrangeira são mais propensas a viver em certos códigos postais, nascer no exterior com mais frequência e ter nomes estrangeiros. A aparência estrangeira é uma variável oculta que coincide com estas variáveis que são conhecidas. O

57 Artigo 21º da Carta de Direitos Fundamentais da União Europeia: “É proibida a discriminação em razão, designadamente, do sexo, raça, cor ou origem étnica ou social, características genéticas, língua, religião ou convicções, opiniões políticas ou outras, pertença a uma minoria nacional, riqueza, nascimento, deficiência, idade ou orientação sexual”. Vera também considerando 71 do RGPD.

58 Para exemplos de outros tipos de discriminação involuntária por meio de algoritmos, ver Information Commissioner’s Office, *Big data, artificial intelligence, machine learning and data protection*, versão 2.2, 2017, pp. 44-45.

59 Financial Stability Board (FSB), *Artificial intelligence and machine learning in financial services. Market developments and financial stability implications*, 2017, p. 5. Disponível em <https://www.fsb.org/wp-content/uploads/P011117.pdf>. Acesso em 22 de novembro de 2022.

algoritmo aprende então que deve rejeitar pedidos de crédito de pessoas com essas características. Isto também é conhecido como viés de interação<sup>60</sup>. Isto é discriminação proibida e deve ser evitada por uma empresa financeira.

## 2. Discriminação por um algoritmo porque certos grupos têm de fato características estatisticamente corretas.

É também possível, entretanto, que certas características sejam de fato mais prevalentes em certos grupos. Suponha-se que o algoritmo descubra que pessoas com certos sobrenomes geralmente são mal pagadoras, será que o algoritmo pode agir sobre isso? Afinal, os sobrenomes são frequentemente relacionados à origem, portanto, a discriminação contra certos sobrenomes será, na prática, frequentemente discriminação racial. Enquanto a discriminação indireta através de sobrenomes ainda é fácil de detectar e assim combater, um algoritmo também será capaz de apreender substitutos menos óbvios para, digamos, raça, religião, saúde ou orientação sexual e tirar conclusões a partir disso. Um exemplo é que usando dados do Facebook, por meio dos conhecidos “likes”, é possível discriminar corretamente entre homens homossexuais e heterossexuais em 88% dos casos, afro-americanos e caucasianos em 95% dos casos, e entre democratas e republicanos em 85% dos casos, mesmo que isto não seja explicitamente declarado pelo usuário em seu perfil<sup>61</sup>. Em outras palavras, sem usar a variável proibida subjacente, um algoritmo ainda pode discriminar usando outras variáveis que estão suficientemente correlacionadas com a variável proibida. É criado o mesmo resultado como se a variável subjacente proibida tivesse sido usada. Isto é vedado. Também é possível que o resultado de um algoritmo possa afetar particularmente um determinado grupo e assim discriminar indiretamente, mas sem que isto constitua uma discriminação proibida.

Considere-se, por exemplo, que uma seguradora tenha determinado o prêmio de um seguro de vida com base em códigos postais. Por essa razão, os clientes de códigos postais de regiões mais pobres pagarão mais prêmio, já que estavam sujeitos a uma maior incidência de situações ambientais e sociais que abreviavam sua

60 Acerca dos perigos das previsões algorítmicas em face dos sujeitos e a da necessidade de avaliação dos danos de categorização próprios dos sistemas de inteligência artificial que captam estereótipos históricos e sociais, ver CARRERA, F.: “A raça e o gênero da estética e dos afetos: algoritmização do racismo e do sexismo em bancos contemporâneos de imagens digitais”, MATRIZES, 2020, v. 14, núm. 2, pp. 217-240; NOBLE, S. U.: *Algorithms of oppression: How search engines reinforce racism*. NYU Press, New York, 2018; OSOBA, O. A. & WELSER IV, W.: *An intelligence in our image: The risks of bias and errors in artificial intelligence*. Rand Corporation, Santa Mônica, CA, 2017; EUBANKS, V.: *Automating inequality: How high-tech tools profile, police, and punish the poor*. St. Martin’s Press, New York, 2018. Nesta última obra, de acordo com CARRERA, F., “A raça e o gênero”, cit., p. 223, EUBANKS, V. expõe como as predições automatizadas privilegiam indivíduos mais ricos, ao mesmo tempo em que excluem, vigiam e até mesmo punem pessoas pobres com negativa de crédito ou acesso a serviços de saúde, por exemplo. Segundo a autora, se um modelo de previsão automatizado se constrói por variáveis de resultado subjetivas, obviamente já se encontra comprometido.

61 KOSINSKI, M; STILLWELL, D., GRAEPEL, T.: “Private traits and attributes are predictable from digital records of human behavior”, *Proceedings of the National Academy of Sciences (PNAS)*, 2013, v. 110, núm. 15, pp. 5802-5805.

vida, prejudicam mais frequentemente sua saúde ou lhes colocavam em situações de elevado risco a sua integridade psicofísica. No entanto, e ainda seguindo nosso exemplo, os códigos postais pobres, coincidentemente, também são o lar de mais pessoas de minorias étnicas.

Uma solução possível para esse caso hipotético seria: determinar o valor do prêmio com base no código postal do segurado leva à discriminação indireta com base na origem, mas isto não é proibido porque existe uma justificativa objetiva para esta distinção. Assim, ao menos em tese, nenhuma discriminação se dá contra pessoas de baixa renda ou contra pessoas de origem étnica diversa.

Mas essa conclusão precisa estar assentada na seguinte premissa: a seguradora não está a utilizar o código postal do segurado para excluir grupos de pessoas, mas para obter informações sobre a renda e, portanto, medir o grau do risco de morte ou de incapacidade. Essencialmente, a utilização do código postal, na hipótese, não seria então uma forma de encontrar um determinado grupo étnico, mas sim uma forma de encontrar um determinado grupo de renda. A seleção por grupo étnico na verdade funcionaria muito mal para a seguradora, já que o grupo étnico tem uma correlação menor com a riqueza e, portanto, com a expectativa de vida do que o código postal. Em outras palavras, a etnia do cliente não é uma variável subjacente e, portanto, não haveria discriminação proibida.

Os algoritmos de autoaprendizagem podem tirar conclusões discriminatórias implícitas sem que os proprietários dos algoritmos o saibam<sup>62</sup>. O Grupo de Trabalho do Artigo 29º recomenda, portanto, que as empresas testem regularmente seus algoritmos, de forma estatística, para evitar que eles sejam discriminatórios<sup>63</sup>.

## VII. A DEFINIÇÃO DE PERFIS E O SEU IMPACTO NO CONCEITO DE CONSUMIDOR MÉDIO.

O perfil também desempenha um papel na interpretação do conceito de “consumidor médio”, como aparece em muitas regras de proteção ao consumidor;

62 Ver *Discussion Paper on the EBA's approach to financial technology (FinTech)*, 4 August 2017, EBA/DP/2017/02, pp. 47-48. No mesmo sentido, FISMAN, R., LUCA, M.: “Fixing Discrimination in online Marketplaces”, *Harvard Business Review*, December 2016, pp. 88-95

63 *Orientações sobre as decisões individuais automatizadas e a definição de perfis para efeitos do Regulamento (UE) 2016/679*, adotadas em 3 de outubro de 2017 e com a última redação revista e adotada em 6 de fevereiro de 2018, p. 30. A propósito da discriminação, importa recordar que, “conforme decorre do décimo quinto considerando das Diretivas 2000/43 e 2000/78 e do trigésimo considerando da Diretiva 2006/54, o direito nacional ou as práticas nacionais dos Estados-Membros podem prever, em especial, que a demonstração da discriminação indireta se possa fazer por quaisquer meios, incluindo os dados estatísticos” – acórdão da Segunda Seção do Tribunal de Justiça da União Europeia (TJUE), causa C-415/10, *Galina Meister contra Speech Design Carrier Systems GmbH*, de 19 de abril de 2012. Disponível em <https://eur-lex.europa.eu/legal-content/PT/TXT/HTML/?uri=CELEX:62010CJ0415&from=EN>. Acesso em 22 de novembro de 2022.

constituindo-se em uma das referências centrais no contexto da União Europeia, onde é, antes de tudo, um conceito normativo<sup>64</sup>.

O conceito está inserido incluído na Diretiva 2005/29/CE relativa às práticas comerciais desleais como um referencial para medir se os consumidores devem ser protegidos contra práticas específicas<sup>65</sup>. A norma é usada para avaliar se uma prática é desleal, no sentido de que tem induzido o consumidor em erro e causa ou é provável que o leve a tomar uma decisão negocial que ele não teria tomado de outra forma.

As empresas podem utilizar a definição de perfis para se dirigirem a grupos específicos. Um subgrupo é então filtrado da grande população de consumidores. O consumidor médio a ser considerado nas normas de proteção ao consumidor é o consumidor médio do grupo que a empresa financeira procura.

As características específicas do grupo que está sendo atendido ou procurado também devem ser levadas em consideração ao determinar se um processo automático de tomada de decisão afeta significativamente o cliente<sup>66</sup>.

Portanto, se uma empresa seguradora procura e se aproxima de um grupo específico através do perfil, ela também deve levar em consideração as características particulares deste grupo ao cumprir com as regras de proteção ao consumidor.

## VIII. CONCLUSÃO.

O objetivo deste estudo foi introduzir alguns conceitos técnicos, tais como definição de perfis, aprendizagem de máquinas e tomada de decisão automatizada,

64 MAK, V.: "The consumer in European regulatory private law. A functional perspective on responsibility, protection and empowerment", em AA.VV.: *The Image(s) of the Consumer in EU Law: Legislation, Free Movement and Competition Law* (coord por D. LECZYKIEWICZ; S. WEATHERILL), Hart Publishing, Oxford, 2016, p. 381.

65 O marco de referência da Diretiva 2005/29/CE do Parlamento Europeu e do Conselho, de 11 de maio de 2005, relativa às práticas comerciais desleais das empresas face aos consumidores no mercado interno para avaliar o impacto de uma prática comercial é o conceito do "consumidor médio", que é normalmente informado e razoavelmente atento e advertido. Com efeito, este conceito proporciona aos tribunais e autoridades nacionais critérios comuns com vista a aumentar a segurança jurídica e reduzir a possibilidade de avaliações divergentes. O "consumidor médio" é uma pessoa com sentido crítico, consciente e advertida, no seu comportamento perante o mercado. Ver Considerandos 18 e 19; e Artigo 5º a 9º da Diretiva 2005/29/CE. Disponível em <https://eur-lex.europa.eu/legal-content/PT/TXT/?uri=CELEX%3A02005L0029-20220528> . Acesso em 22 de novembro de 2022. Ver ainda o Documento de trabalho dos serviços da Comissão Europeia – *Orientações sobre a Aplicação da Diretiva 2005/29/CE*, de 25 de maio de 2016, item 2.5 e seguintes, pp. 41-51. Disponível em <https://eur-lex.europa.eu/legal-content/PT/TXT/HTML/?uri=CELEX:52016SC0163&from=EN> . Acesso em 22 de novembro de 2022.

66 *Orientações sobre as decisões individuais automatizadas e a definição de perfis para efeitos do Regulamento (UE) 2016/679*, adotadas em 3 de outubro de 2017 e com a última redação revista e adotada em 6 de fevereiro de 2018, p. 11.

bem assim explorar as implicações jurídicas da aplicação destas técnicas. A aplicação de tais técnicas não só conduz à incidência de diferentes regulamentos, especialmente do RGPD e da legislação europeia antidiscriminação, mas também que conceitos existentes, tais como a causalidade e discriminação têm que ser redefinidos. A doutrina ainda precisa compreender melhor estes conceitos técnicos para atingimento desse fim, assim como melhor definir quais aplicações destas novas técnicas - e sob quais condições – serão consideradas aceitáveis. é uma tarefa que deve tocar também tanto aos legisladores quanto aos aplicadores. Do mesmo modo, as autoridades supervisoras, em especial, terão que incorporar estes novos conceitos em suas estratégias de atuação. Enfim, há muito material para contínuas pesquisas de aprofundamento. É melhor que assim ocorra, dada a rapidez dos desenvolvimentos tecnológicos e a importância do tema para as empresas seguradoras e consumidores.

## BIBLIOGRAFIA

AMODIO, A.: “La Direttiva (UE) 2016/97 e il regime informativo a tutela del consumatore”, *Amministrazione e Contabilità dello Stato e degli Enti Pubblici*, 2018, núm. 4, pp. 63-78.

ARMBRÜSTER, C; HACKER, P.: “Datenprivatrecht”, *ZVersWiss*, 2020, núm. 109, pp. 299-303.

BALASUBRAMANIAN, R., LIBARIKIAN, A., McELHANEY, D.: “Insurance 2030 – The impact of AI on the future of insurance”, *McKinsey’s Insurance Practice*, março 2021, pp. 1-10. Disponível em <https://www.mckinsey.com/industries/financial-services/our-insights/insurance-2030-the-impact-of-ai-on-the-future-of-insurance> . Acesso em 22 novembro 2022.

CARRERA, F.: “A raça e o gênero da estética e dos afetos: algoritmização do racismo e do sexismo em bancos contemporâneos de imagens digitais”, *MATRIZES*, 2020, v. 14, núm. 2, pp. 217-240.

COLOMBO, C., FACHINNI NETO, E.: “Decisões automatizadas em matérias de perfis e riscos algorítmicos: diálogos entre Brasil e Europa acerca dos direitos das vítimas de dano estético digital”, em AA.VV. *Responsabilidade Civil e Novas Tecnologias* (coord. por G. MAGALHÃES MARTINS e N. ROSENVALD), Editora Foco, Indaiatuba, SP, 2020, pp. 163-183.

D’IPPOLITO, G.: “Evoluzione della disciplina consumeristica e rapporto con la normativa sulla protezione dei dati personali”, em AA.VV. (coord. por Consumers’ Forum e Università degli Studi Roma Tre), *Consumerism 2019. Dodicesimo rapporto annuale. Dal codice del consumo al Digital Service Act. Quella dal consumatore al cittadino digitale è vera evoluzione?*, 2019, pp. 70-80.

DOSHI-VELEZ, F., KORTZ, M; BUDISH, R., BAVITZ, C., GERSHMAN, S., O’BRIEN, D., SHIEBER, S., WALDO, J., WEINBERGER, D., WOOD, A.: “Accountability of AI Under the Law: The Role of Explanation”, *Berkman Center Research Publication*, 2017, Forthcoming, p. 7. Disponível em <https://cyber.harvard.edu/publications/2017/11/AIExplanation> . Acesso em 22 de novembro de 2022.

DUARTE, F.: “Nove algoritmos que podem estar tomando decisões sobre sua vida - sem você saber”. Disponível em <https://www.bbc.com/portuguese/geral-42908496> . Acesso em 22 de novembro de 2022.

EUBANKS, V.: *Automating inequality: How high-tech tools profile, police, and punish the poor*. St. Martin’s Press, New York, 2018.

HOOK, D. H., NORMAN, J. M.: "Origins of Cyberspace: A Library on the History of Computing and Computer-Related Telecommunications, *Historyofscience.com*, Novato, CA, 2002, núm. 874 *apud* Jeremy Norman's *HistoryofInformation.com Exploring the History of Information and Media through Timelines*. Disponível em <https://www.historyofinformation.com/detail.php?id=779> . Acesso em 25 novembro 2022.

JUNQUEIRA, T.: *Tratamento de dados pessoais e discriminação algorítmica nos seguros*. São Paulo: Thomson Reuters Brasil, São Paulo, 2020.

KAUSHIK, K., BHARDWAJ, A., DWIVEDI, A.D., SINGH, R.: "Machine Learning-Based Regression Framework to Predict Health Insurance Premiums", *International Journal of Environmental Research and Public Health*, 2022, v. 19, 2022, 7898.

KOTLER, P., KELLER, K. L.: *Administração de marketing*, Pearson Education do Brasil, São Paulo, 2012, pp. 163-188; LAMBIN, J.: *Marketing Estratégico*. McGraw-Hill Interamericana de España S.L, Madrid, 1995.

KOSINSKI, M; STILLWELL, D., GRAEPEL, T.: "Private traits and attributes are predictable from digital records of human behavior", *Proceedings of the National Academy of Sciences (PNAS)*, 2013, v. 110, núm. 15, pp. 5802-5805.

MAK, V.: "The consumer in European regulatory private law. A functional perspective on responsibility, protection and empowerment", em AA.VV.: *The Image(s) of the Consumer in EU Law: Legislation, Free Movement and Competition Law* (coord por D. LECZYKIEWICZ; S. WEATHERILL), Hart Publishing, Oxford, 2016.

MARANO, P.: "Management of Distribution Risks and Digital Transformation of Insurance Distribution – A Regulatory Gap in the IDD," *Risks*, MDPI, 2021, v. 9(8), pp. I-II.

MIRAGEM, B., PETERSEN, L.: "O Contrato de Seguros e a Lei Geral de Proteção de Dados", *Revista dos Tribunais*, 2020, v. 109, núm. 1018, pp. 61-106.

MITCHEL, T. M.: *Machine Learning*, McGraw-Hill, New York, 1997.

MÜHLHOFF, R.: "Predictive privacy: towards an applied ethics of data analytics", *Ethics and Information Technology* , 2021, v. 23, núm. 4, pp. 675-690.

NAGLE, T. T., HOLDEN, R.K.: *Estratégia e Táticas de Preços: um guia para decisões lucrativas*, Person, São Paulo, 2003.

NERSESIAN, D; MANCHA, R.: "From Automation to Autonomy: Legal and Ethical Responsibility Gaps in Artificial Intelligence Innovation", *Michigan Technology Law Review*, 2020, v. 27, núm. 1, pp. 55-96.

NILSSON, N. J.: *Introduction to Machine Learning: An Early Draft of a Proposed Textbook*, Stanford University, Stanford, CA, 1998.

NOBLE, S. U.: *Algorithms of oppression: How search engines reinforce racism*. NYU Press, New York, 2018.

OSOBA, O. A. & WELSER IV, W.: *An intelligence in our image: The risks of bias and errors in artificial intelligence*. Rand Corporation, Santa Mônica, CA, 2017.

PATRÍCIO, M.: "Correlações e causalidade: breves reflexões numa perspectiva económica", *Revista Jurídica Luso-Brasileira*, 2016, ano 2, n. 4, pp. 1347-1380.

PASQUALE, F.: *The black box society: the secret algorithms that control money and information*, Harvard University Press, Cambridge, 2015.

SARLET, G. B. S; MOLINARO, C. A.: "Questões tecnológicas, éticas e normativas da proteção de dados pessoais na área da saúde em um contexto de big data", *Direitos Fundamentais & Justiça*; 2019, v. 13, núm. 41, pp. 183-212.

SIMON, H.: *Price management*, Elsevier Science Publishers, Amsterdam, 1989.

THOUVENIN, F., SUTER, F., GEORGE, D., WEBER, R. H.: "Big Data in the insurance industry: Leeway and limits for individualising insurance contracts", *Journal of Intellectual Property, Information Technology and Electronic Commerce Law*, Universitätsverlag Göttingen, 2019, v. 10, núm. 2, pp. 209-243.

VAN OTTERLO, M.: "A Machine Learning View on Profiling", em AA.VV.: *Privacy, Due Process and the Computational Turn: The Philosophy of Law Meets the Philosophy of Technology* (coord. por M. HILDEBRANDT e K. DE VRIES), Routledge, London, 2013, pp. 41-64.

ZUIDERVEEN BORGESIU, F., POORT, J.: "Online Price Discrimination and EU Data Privacy Law", *Journal Consum Policy*, 2017, v. 40, pp. 347-366.