

# **A EXPLICABILIDADE DAS TECNOLOGIAS DE INTELIGÊNCIA ARTIFICIAL**

Aluno: Otávio Morato de Andrade

Orientador: Dierle José Coelho Nunes

Curso: Administração

Trabalho apresentado ao Programa de Bolsas de Iniciação Científica, Tecnológica e Inovação (PROBIC), no âmbito da Pontifícia Universidade Católica de Minas Gerais (PUC-MG)

BELO HORIZONTE

2021

## INTRODUÇÃO

O avanço das tecnologias de inteligência artificial (IA) levanta uma série de desafios éticos e jurídicos sobre os processos decisórios inerentes a estes modelos. Questões como a responsabilização, a compreensão, o controle e a auditoria relativas às decisões tomadas por máquinas inteligentes permeiam o debate público acerca da aceitação e regulação dessas novas ferramentas.

Dentre tantas implicações possíveis no uso da IA, este trabalho propõe um recorte metodológico, buscando discutir a *explicabilidade* – ou seja, a melhor compreensão humana sobre o processo decisório das máquinas inteligentes – enquanto requisito para o desenvolvimento dessas novas tecnologias. Não há dúvidas de que a explosão do uso de IA marcará o desenvolvimento de uma infinidade de recursos para uma ampla variedade de tarefas. Neste cenário, *poderia a eficácia e a legitimidade desses sistemas ser limitada pela incapacidade da máquina de explicar seus resultados e ações aos humanos?*

A hipótese colocada é de que, se os usuários quiserem gerenciar e confiar nos sistemas artificialmente inteligentes, será fundamental oferecer mais transparência em relação aos processos internos que levaram os sistemas de IA a tomarem as suas decisões. Em última instância, explicar tais processos decisórios aumentaria a compreensão e a legitimação das ações tomadas pelos sistemas autônomos. Neste sentido, o objetivo geral do trabalho é investigar a *explicabilidade* enquanto requisito para a justificação e legitimação das decisões tomadas pelos modelos de inteligência artificial.

A presente pesquisa apresenta abordagem qualitativa, uma vez que o problema em questão não pode ser quantificável. Afinal, será preciso verificar especificidades de natureza teórica para compreender de maneira mais completa como a *explicabilidade* pode ser estruturada no contexto da inteligência artificial (VERGARA, 1998). Em relação à lógica utilizada, a pesquisa é definida como indutiva, pois busca-se chegar a uma conclusão genérica a partir da análise um conjunto teórico específico acerca do tema, gerando conhecimento sobre um tema relativamente pouco desenvolvido (RICHARDSON, 1999). Quanto ao objeto, a pesquisa é descritiva e exploratória. Descritiva porque possui como principal objetivo descrever características de determinada população ou fenômeno sem a interferência do observador (VERGARA, 1998). E é exploratória por apoiar a construção de uma teoria num campo de conhecimento não muito sedimentado, no qual a análise é qualitativa (GIL, 1999).

O trabalho é apresentado em três etapas. Primeiramente, será formulada uma síntese dos conceitos basilares necessários para compreender a IA, tais como redes neurais, *machine learning* e *deep learning*, apresentando-se também um breve histórico da evolução da IA. Em

segundo lugar, a partir da discussão sobre a opacidade e a transparência dos algoritmos, estabelece-se o conceito de *explicabilidade*, que compreende a importância de identificar, o mais detalhadamente possível, os passos ou mecanismos que levam os algoritmos a construir suas decisões. Na terceira e última etapa do trabalho, será formulada uma reflexão crítica acerca da emergência Direito à Explicação, considerando-se as principais legislações existentes sobre o tema.

## **1. INTELIGÊNCIA ARTIFICIAL: DO APRENDIZADO SIMBÓLICO AO DEEPLARNING**

De acordo com RUSSEL & NORVIG (1995), a inteligência artificial pode ser definida como a capacidade da máquina de interpretar dados de forma racional e humana, tomando decisões autônomas com base em padrões preexistentes. No mesmo sentido, SIMONS (2016) preleciona que é a ciência de ensinar computadores a “*aprender, raciocinar, perceber, inferir, comunicar e tomar decisões como os humanos*”.

As primeiras pesquisas sobre IA, feitas a partir das décadas de 1940 e 1950, visavam a solução de problemas a partir de *métodos simbólicos*. De acordo com OSÓRIO (1999, p. 6), os métodos simbólicos consistiam em mecanismos matemáticos menos sofisticados, como, por exemplo, o aprendizado por analogia/instâncias (exemplo: sistemas baseados em casos); o aprendizado por indução (e.g.: árvores de decisão) e o aprendizado por evolução/seleção (e.g.: algoritmos genéticos). Nestas abordagens, as máquinas eram orientadas para manipular informações simbólicas (qualitativas), o que gerava limitações para manipular valores numéricos e também para tratar o problema com completude.

Em contraponto aos métodos de aprendizado simbólico, desenvolveu-se o estudo das redes neurais artificiais (RNA), que utilizavam o chamado *método conexionista*. Este método era baseado na modelagem dos neurônios humanos, que são conhecidamente conectados entre si com um grande número de ligações e operam em paralelo. Diversos modelos de RNA surgiram ao longo dos anos, dentre os quais destacam-se o Perceptron (1959), modelo de Hopfield (1982) e o Perceptron multicamadas – evolução do Perceptron engendrada na década de 1980. Em 1983, a Agência de Projetos de Pesquisa Avançada de Defesa (DARPA), órgão norte-americano que visa manter a superioridade tecnológica do país, fundou um segmento destinado a pesquisas em neurocomputação, impulsionando o desenvolvimento das RNAs, que enfim acabaram prevalecendo sobre os métodos simbólicos.

A partir da década de 1980, começou a emergir, no campo das redes neurais artificiais, o aprendizado de máquina (*machine learning*). Esta área da computação passou a desenvolver

algoritmos que se aprimoram automaticamente por meio da experiência e do uso de dados, construindo modelos baseados em dados de amostra, conhecidos como dados de treinamento (*training data*), a fim de fazer previsões ou decisões sem serem explicitamente programados para isso. Para Harry Surden (2014):

*Machine learning* refere-se a um subcampo da ciência da computação preocupada com programas de computador capazes de aprender com experiência e, assim, melhorar seu desempenho ao longo do tempo (...). Se tiver um bom desempenho, os algoritmos de *machine learning* podem produzir resultados automatizados que se aproximam daqueles que teriam encontrados por uma pessoa em situação semelhante (SURDEN, 2014, p. 89-90, tradução nossa).

No *machine learning*, o computador é desenvolvido para “se autoprogramar” com base em sua própria experiência. Ele reúne dados, interpreta essas informações e toma decisões diferenciadas, trabalhando com padrões cognitivos similares aos usados por humanos (ARENS, 2017). Além das adaptações realizadas pelo próprio sistema com base em sua experiência prévia, o *machine learning* pode se dar através da intervenção humana. Neste sentido, os desenvolvedores podem reeditar o código do software, fazendo ajustes e correções até que o computador passe a executar a tarefa com grau aceitável de acuidade (MILLER, 2019).

Por sua vez, o aprendizado profundo (*deeplearning*), que vem sendo desenvolvido mais recentemente, é uma classe de algoritmos de aprendizado de máquina que usa múltiplas camadas para extrair progressivamente recursos de nível superior da entrada bruta. Por exemplo, no processamento de imagem, algumas camadas de processamento podem identificar as bordas dos objetos, enquanto outras camadas são responsáveis por identificar características relevantes para um ser humano, como dígitos, letras ou rostos.

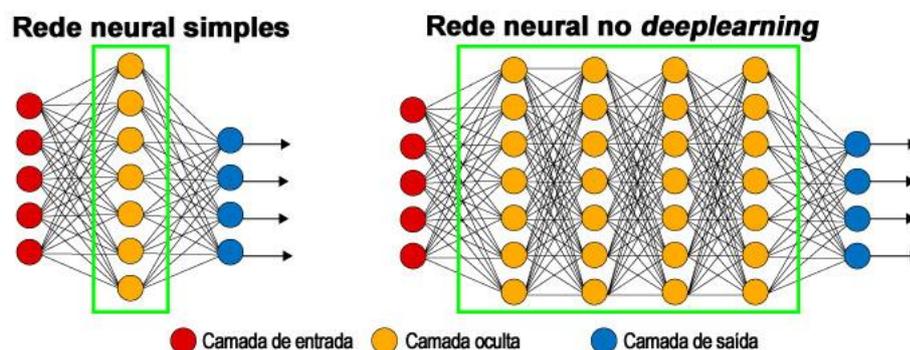


Figura 1: diferença entre a rede neural simples e a rede neural no deeplearning. Destaca-se, em verde, a complexidade e a multiplicidade dos processos de aprendizagem profunda.

Enquanto o aprendizado de máquina usa algoritmos para analisar dados, aprender com esses dados e tomar decisões informadas com base no que aprendeu, o aprendizado profundo estrutura algoritmos em camadas para criar uma “rede neural artificial” que pode aprender e tomar decisões inteligentes por conta própria.

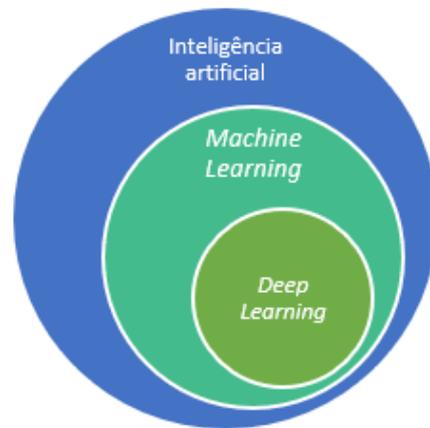


Figura 2: O *deeplearning* é um subcampo do *machine learning*. Embora ambos se enquadrem na ampla categoria de IA, o *deeplearning* deixa a inteligência artificial ainda mais semelhante à humana.

*Elaborado pelo autor.*

Um exemplo de *deeplearning* é um trabalho recente de um grupo de cientistas liderados por Sebastian Thrun, onde eles programaram uma única rede convolucional neural (*convolutional neural network* – CNN) para detectar o câncer de pele, depois de treinar o algoritmo com um banco de dados de 129.450 imagens de manchas dérmicas. A performance de uma única CNN na detecção do câncer de pele foi confrontada com a de 21 médicos dermatologistas, e em todas as tarefas de identificação propostas, o desempenho do algoritmo foi igual ao dos especialistas humanos (ESTEVA et al, 2017).

Em 2016, a *DeepMind Technologies* (hoje adquirida pelo Google) também deu uma demonstração do poder do *deeplearning*, ao introduzir o algoritmo AlphaGo, que aprendeu a jogar o jogo de tabuleiro chamado Go, conhecido por exigir intelecto e intuição aguçados. O sistema foi além do *machinelearning*, sem precisar ser informado quando deveria fazer movimentos específicos, e em um grau de complexidade extraordinário, derrotou vários mestres mundialmente renomados do “Go”, depois de estudar, aprender e reverter suas técnicas mais complexas enquanto jogava (SILVER et al, 2017).

O avanço das tecnologias de inteligência artificial levanta uma série de desafios éticos e jurídicos sobre os processos decisórios inerentes a estes sistemas. Questões como a responsabilização, a compreensão, o controle e a auditoria relativas às decisões tomadas por

máquinas inteligentes permeiam o debate público acerca da aceitação e regulação dessas novas ferramentas. Entre estes desafios, analisaremos a questão da opacidade algorítmica, ou seja, a dificuldade do ser humano em compreender as operações dos modelos da IA.

## **2. OPACIDADE, TRANSPARÊNCIA E EXPLICABILIDADE**

Um dos aspectos mais preocupantes no contexto do avanço da IA é a dificuldade em se compreender o fluxo de raciocínio no interior de um modelo algorítmico, uma vez que, geralmente, conhecemos apenas o resultado de suas ações, mas sabemos pouco ou quase nada sobre a complexa sequência de processamento que levou a elas. Quando isso ocorre, estamos diante do que se convencionou chamar de “opacidade”.

Imagine-se, por exemplo, o caso de um carro autômato controlado por IA que atropela um pedestre. Ou de um robô que produz julgamentos enviesados e propaga comentários racistas. Assim como ocorre nos erros humanos, será necessário adentrar a esfera das decisões para definir a culpabilidade das ações. Todavia, se um modelo de IA não é suficientemente acessível ou claro a respeito dos procedimentos e operações que o levaram a determinada decisão, isso pode dificultar a investigação e até mesmo a responsabilização nos casos em que a IA comete ou contribuiu para cometer uma infração legal.

A constatação de que os computadores não explicam suas previsões e de que isso seria uma barreira para a adoção do aprendizado de máquina nos leva a refletir sobre a necessidade de explicar as decisões dos sistemas de IA. Como ocorre com as explicações em outras áreas do conhecimento, o entendimento dos processos internos da IA precisaria se valer de representações comunicáveis, como, por exemplo, sentenças linguísticas ou lógicas, simplificações de expressões matemáticas e esquemas visuais. Enquanto a opacidade produz uma “caixa preta”, que limita a compreensão humana acerca das decisões de um sistema de IA, a *explicabilidade* criaria o contrário, ou seja, uma “caixa de vidro” que permite entender adequadamente os processos internos por trás de uma decisão algorítmica.

Nos últimos anos, com o advento do *machine learning*, a necessidade de se interpretar as ações dos sistemas de inteligência artificial tem ficado cada vez mais evidente. Isso porque a alta performance e as “façanhas” das mais diversas máquinas que utilizam inteligência artificial têm suscitado preocupações sobre transparência e a confiabilidade destes sistemas. Tais preocupações são potencializadas pela detecção de vieses e preconceitos em alguns algoritmos, no contexto de uma sociedade cada vez mais preocupada com questões raciais, igualdade de gênero e diversidade (NUNES & MARQUES, 2018).

A explicação das decisões auxiliadas por inteligência artificial pode trazer benefícios significativos, tanto para a sociedade como para as empresas que detêm ferramentas algorítmicas. No âmbito empresarial, a *explicabilidade* garante, por exemplo, a melhoria da conformidade legal das ferramentas utilizadas, reduzindo os riscos jurídicos associados ao descumprimento de normas regulatórias sobre IA (INFORMATION COMMISSIONER'S OFFICE & ALAN TURING INSTITUTE, 2020, p. 16).

De igual forma, a *explicabilidade* é de importância fundamental para os indivíduos e para a sociedade. Primeiro, porque o maior conhecimento público acerca dos processos algorítmicos possibilita um debate mais instruído e consciente sobre a adoção e o desenvolvimento das novas tecnologias. Em segundo lugar, porque ela permite a otimização das decisões de inteligência artificial, ajudando a mitigar resultados discriminatórios e a eliminar vieses de modelos algorítmicos (INFORMATION COMMISSIONER'S OFFICE & ALAN TURING INSTITUTE, 2020, P. 17).

Alguns pesquisadores defendem que, com a emergência das novas tecnologias e a penetração cada vez maior dos sistemas de apoio de decisão de IA na sociedade, a *explicabilidade* deveria ser condição *sine qua non* para a legitimação de tais decisões. Neste sentido, ressalta Cédric Villani:

No longo prazo, a explicabilidade dessas tecnologias é uma das condições de sua aceitação social. [...] De fato, sem a possibilidade de explicar as decisões tomadas pelos sistemas autônomos, parece difícil justificá-las. Mas como aceitar o injustificável em áreas tão decisivas para a vida de um indivíduo quanto o acesso ao crédito, emprego, moradia, justiça ou saúde? Parece inconcebível. (VILLANI, 2018, p. 141-142).

A *explicabilidade*, portanto, traz uma série de benefícios a usuários, desenvolvedores e à sociedade de modo geral, sobretudo no atual contexto de 'digitalização da vida', em que os algoritmos têm um grande volume de dados à sua disposição e enorme capacidade de influenciar condutas individuais e estruturar o campo das ações possíveis (ALVES, 2018).

Muito se tem debatido acerca do direito de um cidadão ou da sociedade obter informações mais completas sobre as resoluções de um modelo de IA. Se parte da doutrina defende que as leis assegurem e façam valer uma espécie de "direito à explicação", há também quem entenda que tal proteção seria desnecessária e poderia retardar a inovação. Estes últimos argumentam que haveria custos altíssimos para se explicar alguns algoritmos complexos, e que mesmo assim, a interpretação fornecida poderia ser insatisfatória em alguns casos. Tais custos,

dizem estes, colocam restrições desnecessárias ao desenvolvimento da inteligência artificial, sufocando uma série de benefícios sociais e econômicos da tecnologia (KOZYRKOV, 2018).

### 3. O DIREITO À EXPLICAÇÃO

Apesar das críticas à *explicabilidade*, o Regulamento Geral sobre a Proteção de Dados da União Europeia (GDPR-EU), aprovado em 2016 e em vigor desde 2018, incluiu algumas garantias sobre o direito do cidadão à explicação, como artigos que asseguram, ao usuário, detalhes sobre como seus dados foram tratados por sistemas automatizados. Analisadas em conjunto, essas e outras garantias vêm sendo chamadas por alguns autores de “Direito à Explicação” (GOODMAN & FLAXMAN, 2017). Assim, qualquer decisão que utilize modelos algorítmicos para realizar uma avaliação automatizada dos dados de um indivíduo, gerando efeitos jurídicos a seu respeito, deveria ser explicada, ao menos razoavelmente, ao titular deste direito, possibilitando também que este conteste a decisão. Na prática, isso poderia ser aplicado, por exemplo, aos casos em que um sistema recusa o crédito online ou seleciona, de forma autômata, um candidato a uma vaga de emprego.

Alguns avanços normativos vêm contribuindo para consolidar e expandir tais garantias. Em abril de 2021 a União Europeia revelou um projeto de regras bem mais detalhado para regular a aplicação da IA, exigindo dos desenvolvedores uma espécie de “manual” sobre o funcionamento do sistema, como a descrição das etapas de funcionamento do algoritmo e o detalhamento de impactos potencialmente discriminatórios (COMISSÃO EUROPEIA, 2021, p. 6-7).

Na legislação brasileira, destaca-se o recente ingresso do tema no contexto regulatório nacional em 2020, através da Resolução nº 332 do Conselho Nacional de Justiça (CNJ), que determinou, em seu artigo 5º, inciso VI, o “*fornecimento de explicação satisfatória e passível de auditoria por autoridade humana*”, consolidando a *explicabilidade* como elemento constitutivo da transparência dos sistemas de inteligência artificial. De acordo com MONTEIRO (2018, p. 13), a legislação nacional não apenas consagrou o direito à explicação como foi além da GDPR, expandido o escopo de exercício desta garantia.

Desta forma, é possível perceber a entrada do tema da *explicabilidade* da inteligência artificial no contexto regulatório, muito embora ainda haja pouca especificação a respeito do assunto, particularmente no que diz respeito ao grau informacional que o indivíduo deve receber, bem como às sanções aplicáveis nos casos em que o direito à explicação é desrespeitado.

## CONCLUSÃO

Os primeiros artigos e experimentos sobre *explicabilidade* surgiram, de forma incipiente, nas décadas de 1960-1970, e o avanço dos estudos nesta área tem possibilitado gradativamente o desenvolvimento de princípios e abordagens para facilitar a interpretação dos modelos de inteligência artificial. Todavia, com o passar do tempo os algoritmos também se complexificam, processando maiores volumes de dados em camadas de processamento cada vez mais profundas e numerosas, o que dificulta a tarefa de interpretá-los.

Muito embora o aprendizado de máquina possibilite a otimização de uma série de tarefas, ele nem sempre gera decisões perfeitas, equânimes e imparciais. Um exemplo disso é a já mencionada susceptibilidade dos sistemas de IA aos chamados vieses algorítmicos, ou seja, “preconceitos cognitivos” que comprometem a imparcialidade de suas decisões. Além disso, a constante evolução do poder computacional faz com que as operações e decisões algorítmicas, mesmo quando perfeitamente adequadas, se tornem uma verdadeira incógnita para os seres humanos.

Esta pesquisa confirmou a hipótese de que a *explicabilidade* – ou seja, a capacidade de um modelo algorítmico de explicar o seu processo decisório ao ser humano – pode tornar os sistemas mais confiáveis e seguros, além de ajudar a detectar vieses e determinar responsabilidades. Tornar os sistemas mais transparentes e interpretáveis interessa, primeiramente, aos usuários, aumentando a confiabilidade e a legitimidade das decisões produzidas. Além disso, interessa aos desenvolvedores e às empresas, uma vez que o entendimento da lógica por trás de cada decisão pode auxiliar no aperfeiçoamento das funcionalidades dos próprios sistemas. Compreender como um algoritmo funciona ajuda os seus criadores a corrigir erros e aperfeiçoar o código de cada ferramenta, com vistas a otimizar suas decisões.

Desta forma, conclui-se que o desenvolvimento de uma melhor compreensão sobre o funcionamento dos sistemas de IA pode subsidiar o debate público sobre a conformação das novas tecnologias à ordem democrática, colaborando na regulação das ferramentas existentes e na definição de parâmetros éticos e legais para o design das que ainda estão por vir. Portanto, é extremamente importante pautar a discussão sobre *explicabilidade* no campo jurídico, considerados o crescente impacto da inteligência artificial na sociedade e as inúmeras implicações éticas e jurídicas que sua aplicação acarreta.

## REFERÊNCIAS BIBLIOGRÁFICAS

- ALVES, Marco Antônio Sousa. **Cidade inteligente e governamentalidade algorítmica: liberdade e controle na era da informação**. *Philosophos*, v. 23, n. 2, Goiânia, p. 191-232, 2018. Disponível em: <https://www.revistas.ufg.br/philosophos/article/view/52730>. Acesso em: 01 set 2020.
- ARENS, Bob. **Cognitive computing: Under the hood**. Thomson Reuters. Jan 2017. Disponível em <https://blogs.thomsonreuters.com/answerson/cognitive-computing-hood/>. Acesso em: 15/09/2020.
- COMISSÃO EUROPEIA. **Regulamento (UE) 2016/679 do parlamento europeu e do Conselho**. 27 de abril de 2016. Disponível em <https://eur-lex.europa.eu/legal-content/PT/TXT/HTML/?uri=OJ:L:2016:119:FULL>. Acesso em 2 de junho de 2021.
- CONSELHO NACIONAL DE JUSTIÇA. **Resolução nº 332**. 21 de agosto de 2020. Disponível: <https://www.anoreg.org.br/site/wp-content/uploads/2020/08/Resoluc%CC%A7a%CC%83o-332-CNJ.pdf>. Acesso em 15/09/2019
- ESTEVA, Andre; KUPREL, Brett; NOVOA, Roberto A.; KO Justin; SWETTER Susan M.; BLAU Helen M.; THRUN, Sebastian. **Dermatologist-level classification of skin cancer with deep neural networks**. *Nature*, 542, p. 115–118, 2017.
- GIL, Antônio Carlos. **Métodos e técnicas de pesquisa social**. 5ª Ed São Paulo: Atlas, 1999.
- GOODMAN, Bryce; FLAXMAN, Seth. **European Union Regulations on Algorithmic Decision-Making and a “Right to Explanation”**. *AI Magazine* 38(3), p. 50-57. 2 de outubro de 2017. Disponível: <https://ojs.aaai.org/index.php/aimagazine/article/view/2741>. Acesso em 2 de junho de 2021.
- INFORMATION COMMISSIONER’S OFFICE; ALAN TURING INSTITUTE. **Explaining decisions made with AI**. Londres, 2020.
- KOZYRKOV, Cassie. **Explainable AI won’t deliver. Here’s why**. Hackernoon. Disponível em: <https://hackernoon.com/explainable-ai-wont-deliver-here-s-why-6738f54216be>. Acesso em 5 de julho de 2018.
- MONTEIRO, Renato Leite. **Existe um direito à explicação na Lei Geral de Proteção de Dados do Brasil?** Instituto Igarapé. Artigo Estratégico 39, dezembro de 2018. Disponível em <https://igarape.org.br/wp-content/uploads/2018/12/Existe-um-direito-a-explicacao-na-Lei-Geral-de-Protecao-de-Dados-no-Brasil.pdf>. Acesso em 2 de junho de 2021.
- MILLER, Sterling. **Artificial intelligence and its impact on legal technology: to boldly go where no legal department has gone before**. Thomson Reuters. Acesso em 15/09/2020. Disponível: [https://static.legalsolutions.thomsonreuters.com/static/pdf/S045\\_388\\_1\\_Final.pdf](https://static.legalsolutions.thomsonreuters.com/static/pdf/S045_388_1_Final.pdf)

NUNES, Dierle; MARQUES, Ana Luiza. **Inteligência artificial e direito processual: vieses algorítmicos e os riscos de atribuição de função decisória às máquinas.** Revista de Processo vol. 285/2018, p. 421 – 447, nov. 2018

OSÓRIO, Fernando. **Redes Neurais - Aprendizado Artificial.** Forum de I.A. '99. Disponível em: <http://www2.ic.uff.br/~labic/conteudo/textos/osorio-rn.pdf>

RICHARDSON, Roberto Jarry. **Pesquisa social: métodos e técnicas,** 1999.

RUSSEL, Stuart; NORVIG, Peter. **Artificial Intelligence: A Modern Approach.** New Jersey: Prentice-Hall, 1995.

SIMONS, John. **Tomorrow's Business Leaders Learn How to Work with A.I.** The Wall Street Journal. Nov. 2016. Disponível: <https://www.wsj.com/articles/tomorrows-business-leaders-learn-how-to-work-with-a-i-1480517287>. Acesso em 15/09/2020.

SILVER, David; SCHRITTWIESER, Julian, SIMONYAN, Karen, ANTONOGLOU, Ioannis, HUANG Aja; GUEZ Arthur; HUBERT Thomas; BAKER Lucas; LAI Matthew; BOLTON Adrian; CHEN Yutian, LILICRAP, Timothy; HUI Fan; SIFRE Laurent, VAN DEN DRIESSCHE George; GRAEPEL Thore; HASSABIS, Demis. **Mastering the game of Go without human knowledge.** Nature. 19 de outubro 2017.

SURDEN, Harry. **Machine Learning and Law.** Washington Law Review, Vol. 89, No. 1, 30 mar 2014

VERGARA, Sylvia Constant. **Projetos e relatórios de pesquisa em administração.** São Paulo, 1988.

VILLANI, Cédric. **Donner uns sens à li'intelligence artificielle: pour une stratégie nationale et européenne.** Disponível em: [https://www.aiforhumanity.fr/pdfs/9782111457089\\_Rapport\\_Villani\\_accessible.pdf](https://www.aiforhumanity.fr/pdfs/9782111457089_Rapport_Villani_accessible.pdf). Acesso em 15/09/2019