

INDÚSTRIA 4.0: DESAFIOS E OPORTUNIDADES COM O USO DA MATEMÁTICA

LIMA, Juliano Santos

Bacharelado em Matemática no Centro Universitário Internacional Uninter

PADILHA, Eliandro José

RESUMO

O contexto delimitado para a presente pesquisa corresponde à Quarta Revolução, conhecida também como Era da Internet das Coisas e iniciada em 2010. Este período, que perdura na contemporaneidade, conecta-se de forma direta com os ativos da indústria por meio da inclusão da chamada Indústria 4.0. Este conceito foi implantado por meio da junção do conhecimento teórico da Matemática Computacional com as aplicações práticas, através do Aprendizado de Máquina, comumente reconhecido por seu nome original, *Machine Learning* (ML). Frente à importância desempenhada pela ML, o objetivo geral da pesquisa visa evidenciar a relação existente entre o uso da Matemática e as práticas observadas na Indústria 4.0.

Palavras-chave: 1. *Machine Learning*; 2. Aprendizagem de máquina; 3. Matemática Computacional; 4. Inovação Tecnológica; 5. Algoritmo

1. INTRODUÇÃO

A temática do presente artigo tem como pano de fundo as transformações pelas quais passou o processo industrial, sendo estas marcadas pelas Revoluções Industriais. De acordo com Deloitte (2015), no caso da Primeira Revolução Industrial, esta ocorreu em meados de 1784, na chamada Era da Máquina a Vapor e caracterizada pela invenção deste maquinário. No entanto, a fabricação foi baseada puramente da força trabalhista e de forma mais cansativa. Já a Segunda Revolução, de 1870 na Era da Revolução para Produção em Massa foi marcada pela introdução da primeira produção da linha de montagem. Este passo foi essencial trazer mais produtividade para os trabalhadores, já que a demanda braçal foi minimizada.

A Terceira Revolução, de 1969, época também conhecida como Era da Revolução da Tecnologia de Informação, é caracterizada pela tecnologia eletrônica e na robótica industrial. As principais características marcantes referem-se à miniaturização das placas

de circuitos através de controladores lógicos programáveis, robótica industrial para simplificar, automatizar e aumentar a produção. No entanto, as operações produtivas ainda permaneceram isoladas de toda a empresa (DELOITTE, 2015).

Por fim, a Quarta Revolução, que se iniciou em 2010, deteve a chamada Era da Internet das Coisas, sendo que nesse período a concepção empresarial conecta-se de forma direta com os ativos da indústria por meio da inclusão da chamada Indústria 4.0. Nesta, todos os dispositivos componentes podem ser considerados inteligentes, já que desempenham funções com mais produtividade, comunicam-se entre si e desenvolvem informações cruciais para o entendimento da produção. Nesse sentido, cabe compreender o papel desempenhado pela Internet das Coisas (tradução livre de *Industrial Internet of Things* - IIoT - foi essencial para otimizar as vantagens dos ativos bem como aprimorar a integração e monitoramento produtivos, diagnóstico remoto e tomada de decisões eficazes, sendo todos esses os pontos que fundamentam a Manutenção Preditiva (*idib*). A quarta revolução é advinda das revoluções dos campos relacionados a mecânica, elétrica e tecnologia da informação, sendo as 3 primeiras revoluções da indústria mundial antecessoras a esta, segundo Drath e Horch (2014).

Drath e Horch (2014) também destacam que com o advento das novas tecnologias características da Indústria 4.0, os processos produtivos demonstraram maior produtividade, capacidade de auto-adaptação e auto-gestão, de maneira que a mão de obra humana passou a ser progressivamente substituída pelos equipamentos, destinando às pessoas aquelas atividades de cunho intelectual e mais especializadas como a programação, manutenção, aprimoramento e desenvolvimento das novas tecnologias.

Com esse viés, este trabalho vem com o objetivo geral evidenciar a relação existente entre o uso da Matemática e as práticas observadas na Indústria 4.0, cuja expressão dá-se, principalmente, por meio do Aprendizado de Máquina. Desta forma, é notável o potencial existente na Matemática Computacional destinada aos aprimoramentos e transformação dos processos nas indústrias, de forma a torná-los mais eficientes e automatizados, reduzir as perdas geradas na produção e tornar as empresas as empresas mais competitivas. Para o fim mencionado, os objetivos específicos traçados visam: i) compreender o conceito de inovação; ii) compreender o conceito da Indústria 4.0 e, por fim, iii) analisar as diversas nuances referentes ao aprendizado de máquina, desde o conceito, perspectivas, histórico das técnicas, aplicações práticas e boas práticas.

2. METODOLOGIA

A metodologia científica corresponde à disciplina que “estuda os caminhos do saber”, de forma que o estudante é colocado na atuação prática da pesquisa científica. Para a construção do presente trabalho foi necessária a pesquisa, sendo esta a fonte fundamental para as informações e dados científicos, com o intuito de analisar os pontos principais da temática e propiciar a metodologia mais adequada na investigação da questão apontada. Conforme ensinam Mentzer e Flint (1997), na obra de Dresch, Lacerda e Antunes (2015):

É essencial que o método de trabalho esteja muito bem estruturado e que seja seguido adequadamente, a fim de assegurar a replicabilidade do estudo. Um método de trabalho adequadamente definido também permite maior clareza e transparência na condução da pesquisa, o que possibilita que a sua validade seja, de fato, reconhecida por outros pesquisadores.

Desta feita, a linha de estudo basear-se-á no método da Pesquisa Bibliográfica, já que se trata de uma investigação destinada aos aspectos qualitativos atrelados à questão exposta com o intuito de melhor alcançar a compreensão do fenômeno hodierno, comumente intrincado, nas suas circunstâncias concretas (DRESCH *et al.*, 2015). A Pesquisa Bibliográfica, segundo Vergara (2000) “tem como principal objetivo tornar algo inteligível, justificar-lhe os motivos” que no caso do trabalho em questão traduz-se em esclarecer a relação entre o uso da matemática e a indústria 4.0. Nesse sentido, empregar-se-á o uso de material alcançável à coletividade, como livros, artigos acadêmicos, teses e periódicos disponibilizados em bibliotecas e internet.

3. DESENVOLVIMENTO

3.1. INOVAÇÃO

3.1.1. Conceito

O conceito de criatividade está muito relacionado ao conceito de inovação, podendo este ser analisado a partir de várias perspectivas. Uma concepção mais simples de inovação compreende o conceito como algo que nunca foi feito por ninguém. De acordo

com Lagarto (2013), a inovação consiste em uma atividade intencional, a intenção é focada na resolução de problemas, e se trata de uma mudança que implica novidade, produtos ou métodos inovadores, algo que nunca foi visto, que vai modificar o que se tem atualmente.

A inovação é fator central para promover crescimento tanto do produto quanto da produtividade, a globalização e o desenvolvimento tecnológico têm afetado de forma significativa o contexto de mercado, tornando o conhecimento cada vez mais importante no processo de crescimento econômico e inovação (OECD, 2005).

3.1.2. Desafios Referentes à Inovação

Um dos maiores desafios, é compilar todas as informações com base nos pensamentos de uma geração que está em constante mudança e focadas na era da tecnologia, forçando cada vez mais, o Marketing e P&D ser mais proativo nas tomadas de decisão.

Fatores importantes para garantir o sucesso da organização e dar velocidade ao atendimento às necessidades dos clientes e consumidores. O atual dinamismo do mercado propicia o constante surgimento de negócios cada vez mais competitivos. Por um lado, essa realidade pode afetar todas as organizações, na medida em que tentam oferecer produtos diferenciados para os clientes utilizando a digitalização e a tecnologia.

O objetivo das organizações referente às inovações é voltado aos fatores econômicos, visto a necessidade de substituição dos produtos que chegaram à curva final do gráfico da vida útil e precisa ser substituído na prateleira. Produtos obsoletos são substituídos para não gerar custos e prejuízos. Ocorre então, a revisão de portfólio a diversificação de novos produtos sem impactar financeiramente e sem gerar danos ao negócio e ao meio ambiente visando à sustentabilidade para aumentar sua valorização e participação no mercado.

3.3. MATEMÁTICA COMPUTACIONAL E INOVAÇÕES

A Matemática Computacional é a base do conceito de inovação que tem se destacado cada vez mais na sociedade, especialmente no âmbito organizacional. As discussões e estudos referentes a Matemática Computacional começaram a ganhar força a partir da Revolução Industrial, momento marcado pela ascensão de grandes empresas e

novas formas de organizar o trabalho, devido ao aumento da complexidade. A evolução sempre esteve presente na vida humana, sendo notada a partir das mudanças em equipamentos e máquinas, como exemplo, é possível citar o desenvolvimento desde o barco a vapor até as tecnologias que são utilizadas atualmente para facilitar a vida das organizações e clientes (BAYLÃO; OLIVEIRA, 2015).

Tecnologia não se limita ao surgimento de computadores e aparelhos celulares, mas também, ao conjunto de conhecimentos, técnicas e conceitos que são utilizados para modificar a realidade da sociedade; se trata de uma adaptação e transformação no sentido de combinar ferramentas, máquinas e técnicas para atenderem as necessidades da sociedade que tem se tornado mais complexas com o passar dos anos (FRANCHON, 2009).

As principais ações da Matemática Computacional podem ser observadas nas evoluções tecnológicas, as quais impactam as empresas não somente a produção, mas o ambiente organizacional como um todo, as relações de trabalho, pois influenciam na vida do trabalhador, modificam funções, criam novas funções. Dentre as principais mudanças é possível citar a automação como uma das que mais afetaram a vida do trabalhador, afinal, muitos cargos foram substituídos por máquinas e mecanismos que realizam o trabalho antes realizado por pessoas (CARVALHO, 2010).

A Tecnologia da Informação foi outro grande avanço que modificou o trabalho nas empresas de forma geral. Frente ao cenário da globalização, os avanços tecnológicos formam sendo desenvolvidos a fim de formar uma cadeia de suprimentos global, o que fortaleceu a economia e ampliou significativamente a produção industrial. Tal fator se relaciona com a chamada Revolução Digital, que ocorreu na pós-modernidade, responsável por modificar a comunicação entre as pessoas (NORONHA; BARBOSA; CASTRO, 2012; FRANCHON, 2009).

A Revolução Digital foi responsável por trazer a internet, ferramenta que atualmente tem se mostrado indispensável no contexto organizacional e na vida cotidiana das pessoas. A internet foi uma das evoluções tecnológicas mais significativas, consiste em uma rede de comunicação descentralizada que permite a conexão e comunicação entre pessoas em qualquer local do mundo. Para as empresas, esta mudança representa uma ampliação importante da rede de comunicação, ampliando negócios e permitindo acompanhar a dinâmica da globalização (FRANCHON, 2009).

Assim, a partir do surgimento da internet, mudanças nas relações de trabalho foram observadas. Para que a internet possa ser utilizada a favor do trabalho é importante que haja conhecimento de seus recursos. Não basta, portanto, possuir o equipamento adequado, mas saber utilizá-lo de maneira correta e adequá-lo as suas necessidades (FRANCHON, 2009). A associação destas tecnologias permitiu às empresas utilizar ferramentas a favor de uma gestão estratégica, buscando uma boa posição competitiva no mercado. Softwares, equipamentos, plataformas e outros tem facilitado a organização, gestão, alcance do cliente, atendimento de suas necessidades. A internet trouxe muita praticidade, velocidade e confiabilidade na troca de informações, muito utilizada para realizar pesquisa de informações que auxiliam os gestores na tomada de decisão (CERVIERI JUNIOR et al., 2015).

Frente a isso, nota-se a relação direta existente entre Matemática e surgimento de novas tecnologias, como a Indústria 4.0, sendo indissociável estes dois elementos das práticas oriundas da Matemática Computacional.

3.4. INDÚSTRIA 4.0

A Indústria 4.0 é uma iniciativa estratégica lançada em 2011 pelo governo alemão, em parceria com as universidades e a indústria, com o objetivo de tornar o país um pioneiro na utilização de alta tecnologia, que promete revolucionar a produção (ALMEIDA, 2019; SANTOS *et al.*, 2018; SACOMANO *et al.*, 2018; SCHWAB, 2016). Cabe ressaltar que as tecnologias emergentes com a Indústria 4.0 ou com a Quarta Revolução Industrial são pautadas no conhecimento e em sistemas provenientes das Revoluções Industriais ocorridas anteriormente (SCHWAB, DAVIS, 2019), especialmente no que tange aos recursos digitais da Terceira Revolução Industrial, que iniciou a utilização de Controladores Lógicos Programáveis nas máquinas e de Tecnologia da Informação para otimizar os processos de fabricação (SANTOS *et al.*, 2018).

A Indústria 4.0 ou a Quarta Revolução Industrial, no entanto, não diz respeito apenas a sistemas e máquinas inteligentes conectadas. Seu escopo é muito mais amplo e utiliza conceitos de *big data*, cibersegurança, computação em nuvem, integração de sistemas, Internet das Coisas (IoT), manufatura aditiva (impressão 3D), robótica autônoma, realidade aumentada e simulação computacional, que são conhecidos como os nove

pilares da Indústria 4.0. Além dos conceitos de biotecnologia, domótica (popularmente conhecida como automação residencial), inteligência artificial, logística inteligente, mobilidade inteligente, nanotecnologia, rede elétrica inteligente, veículo autônomos, inteligência empresarial (*business intelligence*), entre outros, que são conhecidos como os impulsionadores da Indústria 4.0 (QUINTINO, 2019).

Esse movimento tem modificado as empresas, em aspectos como no gerenciamento do ciclo de vida, na cadeia de abastecimento, no uso de materiais, na engenharia, entre outras atividades. Além disso, as tecnologias precisam ser empregadas para promover a integração entre as máquinas e entre as máquinas e o homem, em que as máquinas passam a processar os dados gerados e coletados nos processos e sistemas, promovendo a eliminação da intervenção humana. O ser humano, nesse cenário, atua deixando de executar tarefas perigosas, repetitivas e massivas, se envolvendo mais com o planejamento de sistemas, coordenação, pesquisas e definições estratégicas (SACOMANO *et al.*, 2018).

Por meio de tecnologias como virtualização, *Big Data* e Internet das Coisas (IoT), os equipamentos do fluxo produtivo se tornam mais inteligentes. Isso implica receber e fornecer dados do sistema de controle administrativo (*Enterprise Resource Planning*) e de Inteligência de Negócios (*Business Intelligence*), para promover a produção enxuta ao mesmo tempo em que satisfaz as necessidades dos consumidores (SANTOS *et al.*, 2018).

A Indústria 4.0 é um novo conceito e impõe grandes desafios às empresas brasileiras, principalmente para conseguirem fazer com que os processos e equipamentos obsoletos se adequem a essa nova realidade (REIS, 2019).

Dessa forma, a integração digital entre processos e sistemas proposto por este conceito requer que haja a automação do processo, informatização dos sistemas, novas tecnologias e o envolvimento da engenharia e dos demais setores da organização (ALMEIDA, 2019). Os negócios não poderão evitar a inovação e o investimento deve ser baseado em estratégias que ofereçam produtos e serviços de maneira inovadora. Trata-se de um fenômeno mundial e irreversível.

3.5. APRENDIZADO DE MÁQUINA

3.5.1. Conceito

Atualmente, como principal exemplo das possibilidades oriundas da correlação entre Matemática e Indústria 4.0, tem-se os dispositivos eletrônicos inteligentes, os quais se encontram constantemente na vida de grande parte da população, sendo que parte destes possuem tecnologia baseada no *Machine Learning* de forma direta ou indireta. Os motores de busca de grandes plataformas associadas aos aparelhos conhecidos por *smartphones* estão “aprendendo” sobre hábitos de cada um com o propósito de trazer melhores resultados (ROZA, 2016).

De acordo com Roza (2016), nos últimos vinte anos, o aprendizado de máquinas, também conhecido como *Machine Learning*, tornou-se um dos principais pilares da tecnologia da informação, exercendo um papel muito importante em nossas vidas. O aumento na quantidade de dados disponíveis tende também a aumentar a necessidade de que existam estudos e técnicas de análise de dados que empreguem uma inteligência cada vez maior, sendo que esse é um elemento fundamental para o progresso tecnológico e científico na atualidade.

Prati (2006) ressalta que, ao passo que a análise estatística dos dados pode determinar as tendências centrais e variâncias de determinados fatores, esta não pode gerar a descrição qualitativa das regularidades e também não pode inferir a dependência de fatores que não estejam explícitos nos dados.

A revista *Management Solutions* (2018) dispõe que as técnicas de aprendizagem automática podem ser definidas como um conjunto de métodos que são capazes de detectar automaticamente padrões em dados.

Roza (2016) defende que o objetivo principal do *Machine Learning* é generalizar a resposta além dos exemplos existentes no conjunto de treinamento, uma vez que,

independentemente da quantidade de dados existentes, é pouco provável que os mesmos exemplos apareçam. Dessa forma, a generalização do conhecimento apresentada pelo modelo pode se tornar um algoritmo que, ao utilizar o modelo como referência, possa atribuir algum tipo de valor aos novos dados em um mesmo formato que já foi utilizado no treinamento, mas que não faziam parte do conjunto de dados. Abaixo o exemplo de um trecho de um algoritmo de *Machine Learning* bem como a derivada parcial e grafo computacional utilizado.

Figura 1: Trecho de um algoritmo de *Machine Learning*.

Algorithm 1: LR MLE using IRLS

```

Data:  $\mathbf{X}, \mathbf{y}, \hat{\beta}^{(0)}$ 
Result:  $\hat{\beta}$ 
1 begin
2    $c = 0$ 
3   while  $\left| \frac{DEV^{(c)} - DEV^{(c+1)}}{DEV^{(c+1)}} \right| > \varepsilon_1$  and  $c \leq \text{Max IRLS Iterations}$  do
4     for  $i \leftarrow 1$  to  $n$  do
5        $\hat{p}_i = \frac{1}{1 + e^{-\mathbf{x}_i \hat{\beta}}}$ ; /* Compute probabilities */
6        $v_i = \hat{p}_i(1 - \hat{p}_i)$ ; /* Compute weights */
7        $z_i = \mathbf{x}_i \hat{\beta}^{(c)} + \frac{(y_i - \hat{p}_i)}{\hat{p}_i(1 - \hat{p}_i)}$ ; /* Compute the adjusted response */
8      $\mathbf{V} = \text{diag}(v_1, \dots, v_n)$ 
9      $(\mathbf{X}^T \mathbf{V} \mathbf{X} + \lambda \mathbf{X}) \hat{\beta}^{(c+1)} = \mathbf{X}^T \mathbf{V} \mathbf{z}^{(c)}$ ; /* Compute  $\hat{\beta}$  via WLS */
10     $c = c + 1$ 
11 end

```

Algorithm 2: Linear CG. $\mathbf{A} = \mathbf{X}^T \mathbf{V} \mathbf{X} + \lambda \mathbf{X}$, $\mathbf{b} = \mathbf{X}^T \mathbf{V} \mathbf{z}$

```

Data:  $\mathbf{A}, \mathbf{b}, \hat{\beta}^{(0)}$ 
Result:  $\hat{\beta}$  such that  $\mathbf{A} \hat{\beta} = \mathbf{b}$ 
1 begin
2    $\mathbf{r}^{(0)} = \mathbf{b} - \mathbf{A} \hat{\beta}^{(0)}$ ; /* Initialize the residual */
3    $c = 0$ 
4   while  $\|\mathbf{r}^{(c+1)}\|^2 > \varepsilon_2$  and  $c \leq \text{Max CG Iterations}$  do
5     if  $c = 0$  then
6        $\zeta^{(c)} = 0$ 
7     else
8        $\zeta^{(c)} = \frac{\mathbf{r}^{T(c+1)} \mathbf{r}^{(c+1)}}{\mathbf{r}^{T(c+1)} \mathbf{A} \mathbf{r}^{(c)}}$ ; /* Update A-Conjugacy enforcer */
9        $\mathbf{d}^{(c+1)} = \mathbf{r}^{(c+1)} + \zeta^{(c)} \mathbf{d}^{(c)}$ ; /* Update the search direction */
10       $s^{(c)} = \frac{\mathbf{r}^{T(c)} \mathbf{r}^{(c)}}{\mathbf{d}^{T(c)} \mathbf{A} \mathbf{d}^{(c)}}$ ; /* Compute the optimal step length */
11       $\hat{\beta}^{(c+1)} = \hat{\beta}^{(c)} + \zeta^{(c)} \mathbf{d}^{(c+1)}$ ; /* Obtain approximate solution */
12       $\mathbf{r}^{(c+1)} = \mathbf{r}^{(c)} - s^{(c)} \mathbf{A} \mathbf{d}^{(c+1)}$ ; /* Update the residual */
13       $c = c + 1$ 
14 end

```

Fonte: Sítio eletrônico de DS Academy (2021)¹

¹ Disponível em: <https://blog.dsacademy.com.br/conceitos-fundamentais-de-machine-learning-parte-5/>; Acesso em: 10 sert. 2021.


Figura 2: Derivada parcial utilizada em *Machine Learning*.

$$\frac{\partial}{\partial a}(a + b) = \frac{\partial a}{\partial a} + \frac{\partial b}{\partial a} = 1$$

$$\frac{\partial}{\partial u}uv = u \frac{\partial v}{\partial u} + v \frac{\partial u}{\partial u} = v$$

Fonte: Sítio eletrônico de *Deep Learning Book* (2021)²

Figura 3: Exemplo de grafo computacional utilizado em *Machine Learning*.



Fonte: Sítio eletrônico de *Deep Learning Book* (2021)³

Vale também apresentar um exemplo de Matriz de Confusão, sendo esta utilizada para cálculo da performance dos algoritmos de *Machine Learning* representada na Figura 4.

² Disponível em: <https://www.deeplearningbook.com.br/algorithm-backpropagation-parte1-grafos-computacionais-e-chain-rule/>. Acesso em: 10 set. 2021.

³ Disponível em: <https://www.deeplearningbook.com.br/algorithm-backpropagation-parte1-grafos-computacionais-e-chain-rule/>. Acesso em: 10 set. 2021.

Figura 4: Matriz de Confusão.

		Valor Predito	
		Sim	Não
Real	Sim	Verdadeiro Positivo (TP)	Falso Negativo (FN)
	Não	Falso Positivo (FP)	Verdadeiro Negativo (TN)

Fonte: Sítio eletrônico de Deep Learning Book (2021)⁴

Ao retomar a questão conceitual, ressalta-se que Vasconcelos (2017) propõe que o *Machine Learning* seja um ramo da estatística e da computação que reúne uma série de métodos com dois objetivos: desempenho preditivo de modelos e aprendizado com os dados observados ou automação do processo de modelagem de dados.

Sendo assim, as definições – por mais variadas que possam ser – incluem o uso de padrões conhecidos para realizar previsões ou para a tomada de outros tipos de decisões em ambientes de incerteza. Entretanto, se comparadas às técnicas estatísticas clássicas, as de *Machine Learning* permitem otimizar o processo de estimativa de modelos não só com o aumento no potencial de previsão através de novas metodologias e técnicas de seleção variáveis, mas também com a otimização da eficiência dos processos por meio da automatização (MANAGEMENT SOLUTIONS, 2018).

Um dos maiores objetivos do aprendizado por máquina é desempenhar com precisão tarefas não conhecidas a partir das experiências “aprendidas” pelo sistema. Para isso, é necessário construir um modelo de aprendizagem utilizando algoritmos que usam a teoria do aprendizado computacional, treinando-os para usar a probabilidade e a estatística a fim de analisar as informações oferecidas. Essa habilidade é chamada de generalização. E, para melhorar a performance do algoritmo na habilidade de generalização, utilizam-se hipóteses. Se a hipótese utilizada é menos complexa que a função, então o modelo faz o *underfitting* (ou subajuste) dos dados, agora, se a hipótese é muito complexa, então o modelo faz o *overfitting* (ou sobreajuste), e a generalização será mais pobre do que o esperado. No caso, o sobreajuste é relativo à produção de uma análise que corresponde com muita proximidade ou exatamente a um conjunto de dados

⁴ Disponível em: <https://www.deeplearningbook.com.br/algoritmo-backpropagation-parte1-grafos-computacionais-e-chain-rule/>. Acesso em: 10 set. 2021.

específico e, portanto, pode falhar no ajuste de dados adicionais ou previsões de observações futuras com base na confiabilidade (SIPSER, 2006).

Dessa forma, elege-se como a definição clássica da aprendizagem automática o que se diz na revista *Management Solutions* (2018, p. 19), descrevendo-a como “o campo de estudo que dá aos computadores a capacidade de aprender sem serem explicitamente programados”, sendo um campo que se dedica à construção de algoritmos que melhorem de forma autônoma com a experiência.

3.5.2. Perspectivas

Construir máquinas capazes de aprender por experiência é um objeto de discussão tanto de âmbito técnico como filosófico. Sob o ponto de vista técnico, esse debate vem sendo cada vez mais enriquecido desde o advento dos computadores eletrônicos na década de 1980 e sua consolidação na década de 1990. As pesquisas nessa área demonstram que as máquinas podem e têm um grande nível de aprendizagem, mesmo que as fronteiras da definição de aprendizagem e condicionamento operante ainda não estejam definidas. Entretanto, ao longo dos anos (de 2006 a 2019), sabemos que já é possível que o *software* reconheça os caracteres manuscritos e os converta em linguagem digital, assim como foram as inovações tecnológicas vanguardistas no início dos anos 2000, tais quais o reconhecimento de sequências de DNA que codificam genes cancerosos, uma filtragem de correspondência eletrônica, ou ainda a detecção e o reconhecimento facial (PRATI, 2006).

A resolução desses problemas resultou em avanços significativos, tanto em suas respectivas áreas quanto na área da computação e do aprendizado de máquinas, pois, se pudermos entender como programar computadores para que os mesmos possam resolver problemas, podemos obter resultados importantes em diversos campos da ciência e tecnologia, sendo revertidos inclusive em melhorias no cotidiano das pessoas, na saúde, educação e segurança pública.

Entende-se por aprendizagem como algo que relaciona a correta manipulação de conhecimentos prévios com novas observações que possam levar a novos conhecimentos

(PRATI, 2006). Sendo assim, tem-se a inferência indutiva e a dedutiva. Podemos definir como inferência indutiva aquela em que se utiliza o raciocínio indutivo, e as generalizações são obtidas a partir de premissas específicas. Diga-se que esse é o procedimento mais utilizado nas pesquisas experimentais, que justamente têm conclusões que extrapolam as condições do experimento (ROZA, 2016).

Já no caso das inferências dedutivas, são utilizados os processos de dedução, em que a resposta parte de um conjunto de proposições gerais e se obtém um conjunto de proposições específicas. Ou seja, trata-se do processo pelo qual se obtém conhecimento de um membro específico de uma classe baseado no conhecimento geral referente a todos os membros daquela mesma classe. Um dos métodos mais utilizados em Inteligência Artificial é a dedução. A resolução de problemas, por exemplo, é um dos mecanismos de inferência lógica mais utilizados em sistemas especialistas e é a base do motor de inferência de linguagem de programação lógica (Prolog).

De acordo com Prati (2006), existem dois tipos de tarefas:

1. Procura por uma porção de informação que pode ser verdadeira, baseada em uma teoria geral que descreva um domínio de interesse.
2. Construção de novas teorias que possam descrever o comportamento atual de um determinado processo e que seja possível prever o seu comportamento futuro.

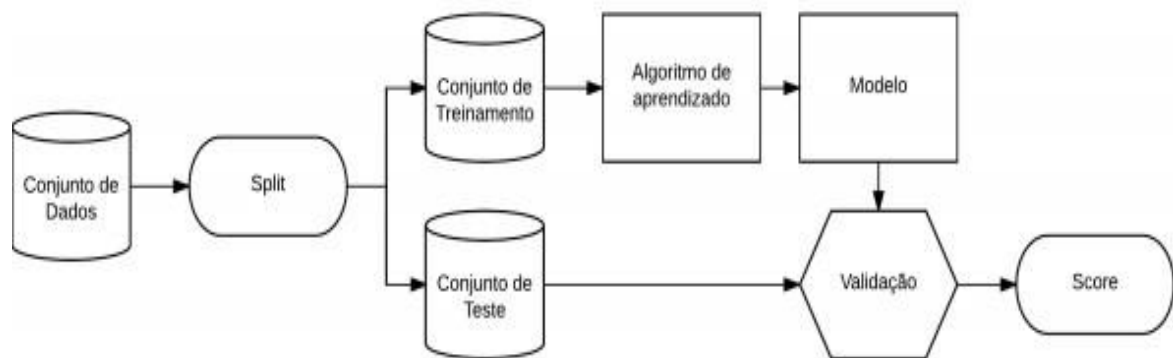
Pode-se dizer que, para ambas as classes de problemas, a inferência não dedutiva é necessária, de modo que seja possível suprir a necessidade de explicação para 1) generalização e 2) dedução, sendo esta normalmente utilizada em diagnósticos e planejamentos.

Atualmente, entende-se por sistema de aprendizagem de máquina como um programa de computador que toma decisões baseadas em experiências acumuladas por meio da solução de problemas anteriores. Mesmo que as grandes dimensões de análises sejam uma das principais razões para que se usem os algoritmos de *Machine Learning*, isso também traz dificuldades para a boa avaliação dos resultados obtidos através desses algoritmos, pois a intuição humana não é suficiente para avaliar determinados aspectos.

Sendo assim, técnicas de avaliação de algoritmos e modelos matemáticos são muito estudadas devido a sua importância para avaliar o grau de confiança sobre os resultados obtidos (ROZA, 2016).

Para Russel e Norvig (2003), em alguns sistemas de aprendizagem é necessário que se saiba se certa ação irá responder com determinada saída. Nessa perspectiva, o aprendizado de máquina pode ser classificado em: aprendizagem supervisionada, aprendizagem não supervisionada, aprendizagem semissupervisionada e aprendizagem por reforço. Portanto, corresponde à aprendizagem na qual um conjunto de observações não rotuladas objetivam estabelecer a existência de grupos ou similaridades. Nesses casos, pode-se dizer que se tem paradigma de aprendizagem estatístico.

Figura 5: Processo de treinamento e avaliação em aprendizagem supervisionada.



Fonte: Roza (2016)

Esses algoritmos de aprendizagem supervisionada criam modelos que possam classificar as variáveis categóricas, além de permitir a regressão das variáveis contínuas. A classificação, portanto, se baseia na atribuição de um rótulo para a saída a partir de determinada entrada. Já a regressão atribui um valor que pertence a um espectro contínuo de valores (ROZA, 2016).

Prati (2006, p. 18) ainda propõe a definição para a aprendizagem semissupervisionada, que, além de classificar os itens não rotulados, tem como objetivo criar novas categorias que satisfaçam as condições dos itens do grupo rotulado e não

rotulado. Para isso, utiliza-se o paradigma de aprendizagem conexionista. Por fim, o modo de aprendizagem por reforço é aquele em que o aprendiz interage com o meio onde está inserido e aprende de acordo com a experiência e o contato direto com esse meio. Dependendo de suas ações, o aprendiz pode ser penalizado ou recompensado. O objetivo, nesse sentido, é que o algoritmo desenvolva uma política ótima que maximize a quantidade de recompensas recebidas ao longo de sua execução (PRATI, 2006).

Isso significa que o algoritmo deva coletar o máximo de informações possível do meio e criar sugestões de modo a serem validadas pelo usuário. O propósito do algoritmo é que suas proposições sejam estatisticamente mais aprovadas do que recusadas, para que esse contato com o meio possa aprimorar as respostas produzidas pelo aprendizado de máquina por reforço. Exemplo, o corretor ortográfico em *smartphones*, que sugerem palavras de modo a serem validadas pelo usuário. A validação positiva faz com que o algoritmo sugira mais opções similares em detrimento das similaridades daquelas que nunca são escolhidas (*ibid*).

Pode-se dizer que o *Machine Learning* possui alguns paradigmas que norteiam o aprendizado da máquina. Alguns deles são os paradigmas simbólico, estatístico, conexionista e genético.

O aprendizado por árvore de decisão é uma metodologia que permite a modelagem de sistemas discretos em um modelo único, sendo um dos métodos mais utilizados na inferência indutiva por ser confiável, além de facilmente compreensível, permitindo a representação gráfica de um modelo gerado (ROZA, 2016). Já o paradigma estatístico de aprendizagem é responsável por criar diversos métodos de classificação, sendo que a maioria deles é semelhante aos métodos científicos no *Machine Learning*. De maneira geral, técnicas estatísticas tendem a utilizar tarefas em que todos os atributos tenham valores contínuos ou ordinais. A maioria desses métodos são paramétricos, ou seja, assumem um modelo pré-estabelecido e ajustam os valores apropriados para os parâmetros do modelo partindo dos dados.

3.5.3. Histórico das Técnicas

O entendimento acerca de técnicas de *Machine Learning* esbarra em um conceito muito antigo da informática: a Inteligência Artificial (IA). Esta é uma questão presente na mente dos pesquisadores desde o início do uso de computadores pelo homem, na busca de uma possibilidade de aproveitar a capacidade de processamento das máquinas para que elas possam emular o comportamento humano. As pesquisas nesse campo vêm desenvolvendo o ramo da ciência da computação conhecido com Inteligência Artificial ao longo de aproximadamente 60 anos.

Machado et al. (2016) nos apresenta que a Inteligência Artificial surgiu na década de 1950 com o propósito de desenvolver tarefas genuinamente humanas para que fossem realizadas por máquinas. Tais tarefas normalmente não podiam ser bem executadas pelas máquinas daquele tempo por conta da complexidade, já que não possuíam uma solução algorítmica viável pela computação convencional.

Já nos primórdios da Inteligência Artificial consagrada como uma disciplina acadêmica, os pesquisadores empenhavam-se em fazer com que as máquinas aprendessem a partir dos dados. Sendo assim, eles tentaram abordar o problema com vários métodos simbólicos, como o de rede neural artificial, feito com *perceptrons* – um tipo de rede neural artificial inventada em 1957 por Frank Rosenblatt no Cornell Aeronautical Laboratory; ele pode ser visto como o tipo mais simples de rede neural *feedforward*: um classificador linear. Além desse, utilizaram-se outros modelos que mais tarde foram entendidos como reinvenções de modelos estatísticos lineares generalizados. Também foi utilizada a lógica probabilística, a qual era muito útil para diagnósticos médicos automatizados (RUSSEL; NORVIG, 2003).

Por muito tempo, essa linha de pesquisa não esteve muito ativa, mas o advento da acessibilidade aos microprocessadores pequenos e baratos possibilitou a implementação de conexões compostas de milhares de microprocessadores, o que deu um novo impulso para as pesquisas da área (MACHADO, 2016).

Na década de 1980, os sistemas especialistas haviam dominado a Inteligência Artificial de forma que os modelos estatísticos utilizados até então entraram em desuso (LANGLEY, 2011). Além disso, o Japão lançou o projeto Quinta Geração, que se tratava de um plano para a construção de computadores inteligentes em um prazo de dez anos. As

instruções dos processadores eram em linguagem de programação lógica (Prolog). Esses sistemas deveriam ser capazes de fazer milhões de inferências por segundo. Uma das ambições do plano era a compreensão da linguagem natural, como um projeto que veio revitalizar a IA em todo o mundo (MACHADO, 2016).

Os trabalhos em aprendizado baseado em conhecimento simbólico continuaram com a Inteligência Artificial, conduzidos até a programação lógica indutiva. Entretanto, as pesquisas mais voltadas para a estatística estavam fora do campo da IA, em reconhecimento de padrões e recuperação de informação (RUSSEL; NORVIG, 2003). Normalmente, os sistemas de IA podem ser divididos em quatro categorias: os sistemas que raciocinam de forma semelhante aos humanos, os que pensam de forma racional, os que agem como os seres humanos e os que agem de forma racional.

3.5.4. Aplicação Prática

Com base nas informações coletadas a respeito do *Machine Learning*, foi possível notar que o conceito de aprendizado é muito importante para as aplicações dessa tecnologia. Assim sendo, define-se aprendizado, nesse caso, como quaisquer processos nos quais um sistema tem seu desempenho melhorado por meio da experiência. Isso significa, para o *Machine Learning*, a preocupação de um sistema de computador em aprimorar a sua performance com autonomia conforme adquire suas experiências (HANNUN; ANDRADE, 2018).

Uma das aplicações mais simples e comuns do *Machine Learning* está no desenvolvimento de sistemas que estão automaticamente se adaptando e se customizando para usuários individuais, tais como o recebimento de notícias personalizadas pelo *smartphone* ou o filtro de spam do e-mail. Além disso, existem aplicações mais complexas, com o descobrimento de novos conhecimentos no uso de bancos de dados, como as aplicações utilizadas na área médica. Por exemplo, no domínio dos transplantes renais, a utilização da previsão computacional é uma prática para predizer a rejeição crônica do aloenxerto e também a estimativa de sobrevivência do enxerto (*ibid*).

As técnicas de *Machine Learning* se baseiam na importância do preditor e na resposta direcionada ao invés de apenas na análise estatística de valores. Santos (2018) dispõe que modelos preditivos estimam, por exemplo, o risco de eventos fatais ou agravantes relativos à saúde de um paciente, podendo ser utilizados como ferramenta auxiliar nas tomadas de decisão pelos líderes e profissionais da área de saúde. Desse modo, alguns algoritmos de *Machine Learning* têm a capacidade de encontrar relações complexas não lineares presentes em dados, o que tem resultado em consequências positivas na performance preditiva de diagnósticos em saúde.

4. CONSIDERAÇÕES FINAIS

Diante do que fora exposto neste trabalho, nota-se a evidente importância da aplicação da matemática na indústria 4.0, principalmente, por meio de algoritmos de *Machine Learning*. Destaca-se que há muito o que se fazer para que este conceito seja implementado de fato nas empresas nacionais, parcialmente ou em sua totalidade. Setores relacionados à Matemática Computacional são os que têm uma relação estreita com este conceito; no entanto, as atividades profissionais que envolvem automação de processos industriais e informatização de sistemas, por exemplo, devem ser integradas através do *Machine Learning*, onde os profissionais desenvolvam as adequações dos projetos existentes em conjunto e de forma inequívoca, considerando a segurança da informação, a integração digital entre processos e sistemas e modelos estudados por vários pesquisadores, bem como inserir as customizações estratégicas de cada organização empresarial.

Esta pesquisa disponibiliza dados aos profissionais que estudam o conceito da Indústria 4.0 e *Machine Learning com utilização de algoritmos baseados em matemática computacional*, sendo base para que novos estudos possam ser desenvolvidos, com o objetivo de auxiliar as empresas nacionais na implantação de forma específica das novas tecnologias e do novo modo de atuação no mercado nacional e internacional. Diante deste cenário, sugere-se como continuidade da pesquisa, a criação de um grupo de trabalho envolvendo as instituições públicas e privadas e as Universidades brasileiras para que possam iniciar estudos e trabalhos em empresas nacionais. Assim, haverá o estímulo à implantação otimizada do conceito da Indústria 4.0 e *Machine Learning*, bem como a

continuidade de formação de novos profissionais e adaptação dos existentes para que haja a conscientização acerca dos benefícios gerados pela aplicação prática de conceitos matemáticos.

REFERÊNCIAS

ALMEIDA, Paulo Samuel de. **Indústria 4.0: princípios básicos, aplicabilidade e implantação na área industrial**. Primeira edição, São Paulo: Editora Érica, 2019.

BAYLÃO, A. L. S.; OLIVEIRA, V. M. Impacto da evolução tecnológica na gestão empresarial. In: SIMPÓSIO DE EXCELÊNCIA EM GESTÃO E TECNOLOGIA, 12. **Anais...** Resende: AEDB, 2015.

CARVALHO, A. M. O impacto da tecnologia no mercado de trabalho e as mudanças no ambiente de produção. **Evidências**, n. 6, p. 153-172, 2010.

CERVIERI JÚNIOR, O. et al. Tecnologias emergentes aplicáveis ao varejo. **BNDES Setorial**, n. 42, p 131-166, 2015.

DELOITTE. **Making an impact that matters 2015**. Global Report, 2015.

DRATH, R.; HORCH, A. **Industrie 4.0: Hit or hype?** IEEE industrial electronics magazine, v. 8, n. 2, p. 56–58, 2014.

DRESCH, Aline; LACERDA, Daniel Pacheco; ANTUNES JR, José Antônio Valle. **Design Science Research: método de pesquisa para avanço da ciência e tecnologia**. 1ª ed. Porto Alegre: Bookman, 2015.

FRANCHON, A. M. **A inclusão digital como estratégia e política de gestão de relações públicas em organizações privadas**. 2009. 122 f. Dissertação (Mestrado em Ciências da Comunicação) – Universidade de São Paulo, São Paulo, 2009.

HANNUN, P. G. C.; ANDRADE, L. G. M. de. O futuro está chegando: perspectivas promissoras sobre o uso de machine learning no transplante renal. **Jornal Brasileiro de Nefrologia**, v. 41, n. 2, p. 284-287, 2018.

LAGARTO, J. R. **Inovação, TIC e sala de aula**. Universidade Católica Portuguesa, 2013.

LANGLEY, P. The changing science of machine learning. **Machine Learning**, v. 82, p. 275-279, 2011.

MACHADO, M. C.; BELLEMARE, M. G.; BOWLING, M. **A Laplacian Framework for Option Discovery in Reinforcement Learning**. In Proceedings of the International Conference on Machine Learning (ICML), pp. 2295–2304, 2016.

MANAGEMENT SOLUTIONS. **Machine Learning, uma peça chave na transformação dos modelos de negócio.** Revista eletrônica. 2018. 44 p.

NORONHA, N S.; BARBOSA, D. M. S.; CASTRO, C. C. Inovação tecnológica e o trabalho humano: o que mudou no mundo contemporâneo? In: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO, 32. **Anais...** Bento Gonçalves: ABEPRO, 2012.

OECD – Organização para Cooperação e Desenvolvimento Econômico. **Manual de Oslo.** 3 ed. FINEP, 2005.

PRATI, R. C. **Novas abordagens em aprendizado de máquina para a geração de regras, classes desbalanceadas e ordenação de casos.** 2006. 191p. Tese de Doutorado – Universidade de São Paulo, São Carlos, 2006.

QUINTINO, Luís Fernando et al. **Indústria 4.0.** Primeira edição, Porto Alegre: Editora Sagah Educação S.A., 2019.

REIS, Fábio. **Revolução 4.0: a educação superior na era dos robôs.** Primeira Edição, São Paulo: Editora de Cultura, 2019.

ROZA, F. S. da. **Aprendizagem de máquina para apoio à tomada de decisão em vendas do varejo utilizando registros de vendas.** 2016. 62 p. Monografia (Graduação) – Departamento de Automação e Sistemas do Centro Tecnológico da Universidade Federal de Santa Catarina, Florianópolis, SC, 2016.

SACOMANO, José Benedito et al. **Indústria 4.0: conceitos e fundamentos.** Primeira edição, São Paulo: Editora Edgard Blucher Ltda., 2018.

SANTOS, H. G. dos. **Comparação da performance de algoritmos de machine learning para a análise preditiva em saúde pública e medicina.** 2018. 206 p. Tese (Doutorado) – Faculdade de Saúde pública da Universidade de São Paulo, São Paulo, 2018.

SANTOS, Max Mauro Dias et al. **Indústria 4.0: fundamentos, perspectivas e aplicações.** Primeira edição, São Paulo: Editora Érica, 2018.

SCHWAB, Klaus et al. **Aplicando a Quarta Revolução Industrial.** Primeira edição, São Paulo: Edipro, 2019.

SCHWAB, Klaus. **A quarta revolução industrial.** Primeira edição, São Paulo: Edipro, 2016.

SIPSER, M. **Introduction to the Theory of Computation.** 2. ed. Massachusetts Institute of Technology: Thomson Course Technology, 2006. 206 p.

VERGARA, Sylvia Constant. **Projetos e relatórios de pesquisa em administração.** 3. ed. São Paulo: Atlas, 2000.