



A importância da inteligência artificial para a engenharia de produção

The importance of artificial intelligence to production engineering

Robson Oliveira¹

Resumo

A engenharia de produção é uma área que utiliza tendências tecnológicas como recursos para a resolução de problemas relacionados a máquinas, materiais, mão de obra e energia. Paralelo a isso, a aprendizagem de máquina constitui um conjunto de métodos computacionais que tem sido amplamente utilizados em diversas áreas para análise de tendências, previsões e outros problemas.

Palavras-chave: Inteligência Artificial. Produção. Engenharia de Produção.

Abstract

Production engineering is an area that uses technological trends as resources for solving problems related to machines, materials, labor and energy. Parallel to this, machine learning constitutes a set of computational methods that have been widely used in various areas for trend analysis, forecasting and other problems.

Keywords: Artificial intelligence. Production. Production Engineering.

Introdução

Estamos vivenciando uma nova revolução industrial. Essa revolução tem sido

¹ Bacharel em Engenharia de Produção, Centro Universitário Santo Agostinho (UNIFSA), Av. Prof. Valter Alencar, 665, São Pedro, Teresina - PI, CEP: 64019-625. E-mail: robson_1200@hotmail.com
Orcid: <https://orcid.org/0009-0005-0153-1174>

impulsionada pelo desenvolvimento de tecnologias avançadas como a Inteligência Artificial (IA). As máquinas não estão somente fazendo trabalhos manuais, mas também trabalhos racionais, tarefas que requerem o uso do que se considera inteligência.

As máquinas estão aprendendo a dirigir automóveis. Já existem carros que podem se mover sem motorista, como os carros do Google e da Tesla. A liberação do uso de alguns desses carros, de forma totalmente autônoma e independente, está aguardando legislação adequada e a realização de mais testes em ambientes reais, assim como em situações excepcionais de alto risco. Tais sistemas devem ser robustos o suficiente para lidar com situações para as quais não tenham sido treinados, assim como situações que possam colocar as vidas dos motoristas e pedestres em risco (Feng et al., 2021).

O aumento da capacidade dos computadores atuais é parcialmente em razão das técnicas de Aprendizado de Máquina. Entretanto, não é de hoje que se deseja fazer que o computador aprenda. Por exemplo, Alan Turing, o pai da computação, desenvolveu um teste, conhecido como teste de Turing, para saber se os computadores eram capazes de aprender. De maneira simples podemos dizer que o teste de Turing consiste em um humano conseguir saber se ele está conversando com outro humano ou com uma máquina. Se o humano não conseguir descobrir se ele está conversando com uma máquina, é um indicativo de que o sistema é inteligente e passou no Teste de Turing (Turing, 1950). Hoje muitos sistemas de IA passam no teste de Turing, mas a capacidade de aprender dos computadores ainda não é igual à capacidade de aprender dos humanos.

Ainda não se sabe como fazer os computadores aprenderem como os humanos aprendem. Nem sequer se sabe exatamente como os humanos aprendem, mas já existem alguns algoritmos eficientes em “ensinar” algumas tarefas específicas aos computadores.

O objetivo desta revisão sistemática é identificar quais são como a inteligência artificial aplicada na atualidade em problemas da Engenharia de Produção.

Referencial Teórico

A área de Inteligência Artificial demonstrou avanços extraordinários nos últimos anos e, atualmente, é utilizada para solucionar inúmeros problemas tecnológicos e econômicos. Como boa parte do sucesso atual da Inteligência Artificial se deve às técnicas de Aprendizado de Máquina. A evolução da ciência da computação e da engenharia de *software* permite que máquinas sejam cada vez mais independentes do controle humano. A medida que as máquinas vem ganhando autonomia significativas nas fábricas, mudanças são incrementadas nas

finanças do país, nos produtos, processos e nas transações de bens e serviços. O desenvolvimento dos *chips*, *microchips* e *nano-chips* também vem ganhando força nessas últimas décadas, e a invenção de processadores mais potentes e memórias maiores tem permitido que máquinas façam armazenamento de maior quantidade de informações e tendo maior poder de processamento do que um humano normal. O aprimoramento dessas tecnologias não teve pausas e vem tendo saltos significativos a cada ano. O problema disso tudo é que quanto maior a autonomia das máquinas, menor a necessidade de trabalhos repetitivos, ou seja, trabalhos que exijam pouca qualificação ou nenhuma. Isso afetará não só os trabalhos manuais, mas também os trabalhos qualificados que, possivelmente, necessitará de novas qualificações para se adequar a revolução industrial 4.0.

2.1 Desafios da Inteligência Artificial

Há um interesse crescente de pesquisadores e profissionais em desenvolver e implantar modelos e algoritmos de Aprendizado de Máquina que não são apenas precisos, mas são também explicáveis, justos, que preservam a privacidade, são causais e robustos. Essa ampla área de pesquisa é comumente referida como Aprendizado de Máquina Confiável.

Os sistemas de IA precisam ser explicáveis porque as pessoas devem entender as soluções sugeridas pelos modelos. As explicações dos modelos de IA também servem para se descobrir possíveis erros no próprio modelo, por exemplo, talvez uma das variáveis utilizadas não esteja ajudando na solução ou até esteja atrapalhando. Algumas pesquisas estão sugerindo explicar os modelos complexos de IA pelo uso de modelos mais simples. Outras pesquisas estão usando Técnicas de Explicações Definidas a *Posteriori* (do inglês, *Post Hoc Explanations Techniques*), mas as explicações obtidas com essas soluções ainda não são confiáveis.

Como mencionado anteriormente, parte do sucesso da IA é oriunda da quantidade de dados disponíveis atualmente e do poder computacional das máquinas modernas. Em relação à quantidade e complexidade dos dados, as máquinas precisam de uma quantidade muito maior de exemplos que os humanos para aprender. Não se sabe ainda quantos exemplos são necessários para a máquina aprender uma tarefa complexa. É também necessário reduzir a necessidade de tantos exemplos nos algoritmos de Aprendizado de Máquina porque com dados mais complexos, máquinas melhores serão necessárias. Por outro lado, os humanos aprendem também por correlação com o que já sabem para resolver novos problemas, um mecanismo como esse dos humanos precisa ser desenvolvido para as técnicas de IA.

Na área de Processamento de Linguagem Natural, para reduzir o tempo de treinamento dos algoritmos, foram desenvolvidos sistemas pré-treinados, como BERT (*Bidirectional Encoder Representations from Transformers*) e GPT (*Generative Pre-Training Transformer*), que foram treinados com enormes conjuntos de dados de linguagem geral, como, por exemplo o *Corpus* da *Wikipédia*, e podem ser ajustados para tarefas de linguagens específicas (Devlin et. al., 2019).

Existem pesquisas que utilizam Aprendizado Auto-supervisionado (do inglês, *Self-Supervised Learning*) para realizar o aprendizado com um menor número de exemplos (Ravanelli et. al, 2020).

Além da necessidade de muitos exemplos no processo de treinamento, alguns exemplos das tarefas reais podem ser letais e a experiência limitada e custosa. Não existem disponíveis bons simuladores da vida real para gerar dados de treinamento, e muitos conceitos de alto nível e o conhecimento sobre o mundo são fornecidos por seres humanos, que rotulam dados de treinamento que serão apresentados aos algoritmos de Aprendizado de Máquina. Os conjuntos de treinamento fornecidos aos algoritmos podem não ser uma boa representação do mundo real, e as amostras podem estar enviesadas. Por exemplo, um sistema pode ser desenvolvido para distinguir gatos de cachorros, mas no conjunto de treinamento apresentado ao algoritmo, todos os cachorros são pretos e todos os gatos são brancos, então o sistema pode aprender a distinguir preto de branco e não gato de cachorro. Nesses casos, é necessária a experiência dos humanos para descobrir e solucionar o problema.

Outro aspecto relacionado aos dados é que muitos problemas reais são dinâmicos e dados são gerados continuamente, como, por exemplo no gerenciamento de transportes e monitoramento por redes de sensores. Para resolver problemas dinâmicos são necessárias técnicas de aprendizado em ambientes dinâmicos de fluxos contínuos de dados (Gama, 2012).

A resolução de problemas complexos utilizando técnicas de AM necessita do *design* automático, eficiente e correto do sistema. Escolhas eficientes de pré-processamento dos dados, seleção da família de algoritmos apropriados, escolha dos hiperparâmetros dos algoritmos, seleção de atributos e pós-processamento. Para uma maior aplicabilidade das técnicas de AM, a resolução dos problemas com AM precisa ser mais automática. Uma possibilidade é usar Meta-Aprendizado (Hospedales et al., 2020). No meta-aprendizado temos algoritmos que aprendem quais algoritmos e que valores de parâmetros devem ser utilizados para se alcançar bons desempenhos de forma automática.

Com o mesmo intuito da inteligência artificial, a robótica se faz presente em nossa rotina, vindo a desenvolver-se de uma forma cada vez mais avançada. Presente nos variados

segmentos de nossa sociedade, a inteligência artificial através da utilização de robôs se vem realizando tarefas, desde as atividades relativamente simples como aspirador de pó, por exemplo, bem como em veículos autônomos e cirurgias médicas. Os robôs apresentam-se de uma forma mais assídua em indústrias constituindo parte no setor de serviços.

Conforme Junior, Puhl, Flávio L. Na obra Robótica.

Na indústria, os robôs são utilizados em razão das avançadas capacidades de montagem, solda, mistura, embalagem de produtos, inspeção e engarrafamento. Já na área de serviços atuam embalagem, inspeção de tubulações, produção agrícola e segurança. A expectativa é do IDC (instituto internacional de data corporation) é que o nosso continente os robôs vêm a desempenhar um papel relevante na colheita de frutas e verduras e na modernização da infraestrutura dos países.

Os robôs são controlados remotamente por um ser humano ou pré-programados. Quando um robô é pré-programado não existe evolução, pois todas as suas funcionalidades já foram anteriormente delimitadas. Programá-los com uma certa inteligência, e que essa inteligência possa tomar decisões independentes através das informações recebidas por meio de sensores e processá-las. Permitido assim, a tomada de decisões para recálculos das suas funções e dar sequência aos seus objetivos. Neste contexto, o trabalho seguirá a trilha de investigação da integralização da Inteligência Artificial, a Lógica Fuzzy, comum Robô de Sumô, afim de transformá-lo de um veículo pré-programado para um veículo dotado de uma inteligência que lhe permitirá perceber, interagir e modificar sua interação com o meio em que está inserido. Também montar um protótipo de robô sumô e ver a viabilidade e comparar qual modalidade de grau de pertinência se encaixara no projeto do robô. Fazendo testes com gráficos e testes práticos com o protótipo.

Nos últimos anos, o campo da inteligência artificial se consolidou em vários aspectos. Obviamente, o uso de computadores, micro controladores e processadores de sinais digitais, com a aplicação de tecnologia de controle, permite que campos férteis implementem algoritmos complexos em aplicações industriais, geração e transporte de energia, entretenimento e aplicações domésticas. Além da tecnologia, os países também prestam atenção ao desenvolvimento sustentável. Desta forma, a aplicação de inteligência artificial, especialmente a inteligência artificial de modelagem e controle fuzzy, encontrou um campo fértil na aplicação de sistemas de geração de energia renovável.(SIMÕES; SHAW,2007).O autor discorre ainda na obra quanto as funções especiais de lógica fuzzy (também chamada de lógica difusa em alguns casos) Por meio da teoria das possibilidades representa uma maneira inovadora de lidar com informações imprecisas de uma forma diferente da teoria da probabilidade. A teoria fuzzy também pode ser comparada a sistemas

de redes neurais, os chamados sistemas Neuro-fuzzy, através da *interface* com dados numéricos para aumentar a capacidade de aprendizagem. A lógica difusa, incerta, informações qualitativas, comunicação oral, capacidade de aprendizagem e estratégias de tomada de decisão são características humanas. Portanto, como a teoria fuzzy, as redes neurais e neuro-fuzzy imitam a inteligência, geralmente são chamados de humanos inteligentes. Em aplicações industriais, os sistemas de modelagem e controle baseados em lógica difusa alcançaram sucesso reconhecido em todo o mundo e provaram ser usados como outra ferramenta nas áreas de engenharia de controle industrial, faturas manuais, comunicação homem-máquina e controle industrial (ou tecnologia), no sistema de decisão. (SIMÕES; SHAW,2007).

2.2 Internet das Coisas (IoT)

De acordo com Magrani (2018), Internet das Coisas (do inglês *Internet of Things* (IoT)) é um ambiente na qual objetos físicos estão conectados a *internet* através de um dispositivo embutido, levando-os a estarem em todos os lugares ao mesmo tempo, aumentando a facilidade de acesso por usuários do cotidiano e trazendo respostas para os problemas do dia a dia.

Ainda Magrani (2018) diz que materiais físicos, sistemas de computação e dispositivos que respondem a um sinal elétrico se juntarão para processar dados e tabelas usando uma conexão ininterrupta e, que a maioria das definições sobre *internet* das coisas, se encaixam nisso.

A *internet* das Coisas surgiu pela tecnologia das áreas de sistemas em microprocessadores, que executam tarefas específicas; integração de circuitos eletrônicos; comunicação e sensoriamento. Sendo de fato muito importante para as universidades e fábricas pela sua utilidade em várias áreas humanas (SANTOS et al., 2016).

Santos et al. (2016) acrescenta que a *Internet* das Coisas é uma amplificação da *internet* convencional, colocando qualquer objeto doméstico ou industrial, com a internet. Esses objetos entrarão em contato com uma rede mundial de computadores, que poderão ser controlados por essa rede, e abrindo caminho para que os próprios objetos sejam acessados como provedores de serviços.

A *Internet* das coisas é a combinação de várias tecnologias na qual colocará objetos físicos no mundo virtual, mas para isso é necessário construir uns blocos básicos de construção do IoT, sendo eles, segundo Santos et al. (2018):

- **Identificação:** é o bloco mais valioso, serve para identificar os objetos antes de conectá-los a *internet*. A identificação dos objetos será feita usando *chip* RFID (Identificação por radiofrequência), endereço de protocolo da Internet ou comunicação por campo de proximidade.
- **Sensores/Atuadores:** pegam dados do local onde estão os objetos e, logo depois, enviam esses dados para o repositório central de informações. Os 25 atuadores vão ler os dados e, dependendo do contexto, poderão modificar ou opor-se de acordo com os dados periciados.
- **Comunicação:** as formas que serão utilizadas para conectar os objetos inteligentes. As tecnologias utilizadas para fazer a comunicação entre objetos serão: *Bluetooth*, *Wifi*, RFID, etc. Essas tecnologias consomem muita energia, principalmente de dispositivos que dependem de baterias para se manterem ligados.
- **Computação:** são unidades que fazem o processamento de informações e algoritmos. Tais exemplos são: dispositivo lógico programável com circuitos integrados, processadores ou pequeno computador num único circuito integrado.
- **Serviços:** A *internet* das coisas pode oferecer diversas categorias de serviços, tais como os serviços de identificação, de agregação de dados, de colaboração/inteligência e de ubiquidade.
- **Semântica:** refere-se a habilidade de extrair dados dos objetos de forma eficiente. Não só extrai os dados, mas também usa o conhecimento de forma eficiente dos dados para entregar um determinado serviço.

2.3 Automação Industrial

A evolução da automação vem acontecendo ao longo dos séculos. Desde os primórdios que o homem vem criando máquinas mecânicas e dispositivos para reduzir o esforço físico e aumentar a produção de tarefas. Exemplos de tais dispositivos mecânicos, que hoje são consideradas simples, são a roda, para movimentação de cargas pesadas, e os moinhos, que naquela época eram movidos pelo vento ou por força animal. Porém, a automação só ganhou notoriedade na Primeira Revolução Industrial, no século XVIII, na terra dos ingleses. Devido a evolução do modo de produção, houve um aumento da escala na qual os produtos eram produzidos. A produtividade era o principal objetivo da Primeira Revolução Industrial, e para atingi-la, foi necessário criar tecnologias nesse período, tais como: máquinas modernas, que produziam com maior velocidade e com menos erros que o trabalho braçal; novas fontes de

energia, tal como o vapor, que substituiu a energia gerada pela água e pelo esforço físico (ROGGIA; FUENTES, 27 2016).

Ainda segundo Roggia e Fuentes (2016), a energia elétrica passou a ser usada no século XIX, contribuindo para o desenvolvimento das indústrias de siderúrgica e de produtos químicos. A produção do aço em quantidades elevadas foi possível pelos novos processos de produção que tornam o aço mais resistente e durável, e que mais para frente iria ser utilizados em algumas máquinas para automação. Os meios técnicos de comunicação foram os que mais se desenvolveram no século XIX, tais exemplos foram citados em capítulos anteriores como o telégrafo e o telefone. Os meios de transportes progrediram rapidamente com a construção de navios, estradas de ferro, motor a explosão e trens movidos a vapor. No século XX, dispositivos que aumentavam a força do operário, equipamentos eletrônicos que faziam o monitoramento e controle, aliados aos computadores, foram introduzidos na automação. Os computadores potentes de hoje são frutos de várias invenções que ocorreram ao longo do tempo, começando pelos ábacos criados pelos babilônios para fazer expressões aritméticas, indo até a régua de cálculo (século XVII) e pelos cartões perfurados que contém informação digital (Século XIX). Nesse intervalo de tempo foi desenvolvida a álgebra *booleana* que introduziu princípios binários que são usados pela computação moderna. Os computadores modernos são a base de qualquer modelo de automação e hoje são essenciais para se manter uma indústria (ROGGIA; FUENTES, 2016).

De acordo com Parreiras (2021), as grandes mudanças que vem ocorrendo no mundo fará com que o engenheiro de produção, pelo menos até 2030, tenha um bom mercado de trabalho. O futuro do mercado de trabalho do engenheiro de produção não é só baseado em estatísticas para medir o futuro, e sim pela medição de novas tecnologias que vem aparecendo atualmente. Porém, o profissional não deve ficar estagnado no tempo após a sua formação e precisará de cursos profissionalizantes para enriquecer seu currículo com novas tecnologias que estão surgindo, principalmente aquelas associadas a indústria 4.0.

Os sistemas controladores eletrônicos empregados na automação industrial são muito importantes para controlar e automatizar de forma adequada processos industriais. A busca pela qualidade nos produtos manufaturados e o atendimento por demandas do mercado consumidor cada vez mais exigente, torna fundamental não só implementar controle automáticos, mas também realizar o controle dos processos industriais com eficiência para que a indústria seja sempre competitiva. Para conseguir a competitividade com eficiência utilizam-se diferentes tipos e técnicas de controle nos processos industriais. Os processos industriais, podem ser discretos, contínuos ou por bateladas. Quase sempre são implementados

a partir de métodos tradicionais, algumas vezes por um modelo tecnológico disruptivo, baseado em técnicas de manufatura avançada utilizando a eletrônica digital, via a Internet e com automação dos processos industriais (Arbix et al., 2017; Junior et al., 2020). Na teoria e, na prática são utilizados os métodos tradicionais baseados em teorias clássicas de controle, assim como, as teorias mais modernas com a intensão de obter uma solução sistemas quase sempre lineares. Em sistema em que é necessário que se conheça detalhadamente o processo a ser controlado, como, todo o modelo matemático que descreve o processo. Existem aplicações que seus respectivos sistemas possuem características não lineares, neste tipo de sistema é impossível de obter um modelo matemático que reproduza o processo em questão. Tornando a forma tradicional de controle inviável de ser aplicada via os métodos tradicionais da teoria de clássica controle (Oliveira et al., 2010; Cambolm et al., 2014; Arbix et al., 2017; Junior et al., 2020).

2.4 Futuro dos Empregos da Engenharia de Produção

O mercado futuro para engenharia de produção é o que estará em melhor situação. Atualmente, a maioria dos engenheiros de produção vem conseguindo bons empregos, isso porque o engenheiro de produção tem uma excelente qualificação científica e consegue resolver problemas globais. O engenheiro de produção pode atuar em diversas áreas do mercado de trabalho, desde o mercado tradicional (fábricas e empresas de grande porte) até o mercado simples (empresas de administração, contabilidade, informática, finanças, etc). O mercado simples, vendo a instabilidade do mercado e dos setores, procuram engenheiros de produção das mais conceituadas universidades para resolver grandes problemas. Os engenheiros de produção que vão para o mercado simples, em sua maioria, já cursaram disciplinas em suas universidades que possibilitam ter conhecimentos em várias áreas, o que torna possível o dinamismo. Os setores de finanças, telecomunicações, portuária e informática são os mais promissores para o engenheiro de produção atuar no futuro (UFSM, 2010).

Segundo o Fórum Econômico Mundial (2020), em seu relatório chamado "Futuro do Emprego 2027 ", diz que 1/3 das tarefas atualmente já são realizadas por robôs. A evolução da automação robótica e a implementação dos robôs destruirá cerca de 85 milhões de empregos, especialmente aqueles manuais e de repetição de tarefas, nas quais são feitos por pessoas de baixa qualificação técnica e acadêmica. Porém, a automação deve criar 97 milhões de empregos em 15 setores estudados, considerando as 26 economias do mundo, desde países com alto desenvolvimento até a brasileira. A maioria dos empregos novos vão surgir nos

seguintes setores: saúde, tratamento de dados (*Big data*), comércio eletrônico (*ecommerce*), computação em nuvem e engenharia do produto. Empregos de administração e processamento de dados são os que tem maior probabilidade de deixar de existir num futuro próximo.

2.5 Impactos da Inteligência Artificial

O uso da IA está mudando o cotidiano das pessoas e para um uso responsável dessas técnicas, fazem-se necessários estudos sobre impactos sociais e éticos da IA, assim como estudos sobre seus riscos, seus impactos, seus benefícios - evitando receios infundados e problemas reais.

A IA pode gerar impactos bons e ruins. A IA pode evitar que o ser humano se exponha a tarefas perigosas, tarefas que já podem ser realizadas por máquinas. A IA pode eliminar a necessidade de tarefas automáticas serem executadas por humanos e, com isso, sobrar tempo para que os humanos lidem com tarefas mais instigantes e prazerosas.

O uso da IA vem trazendo muitos benefícios, tais como: melhorias nos serviços de saúde; Processamento de Linguagem Natural: voz para texto, tradução; melhorias na educação; energia limpa e barata; detecção de fraudes; meios de transportes mais seguros (aplicativos de transporte), rápidos (rota otimizadas) e limpos.

A IA também tem impactos negativos. Perda de vagas de trabalho é um desses impactos negativos. Vagas de empregos menos qualificados que aumentam as desigualdades sociais. Serão necessários planejamento e ações de governo para minimizar os impactos negativos da IA.

Além das preocupações sociais, o uso de IA envolve inúmeras questões éticas e morais, entre elas: a possibilidade de uso de armas poderosas e automáticas, a invasão da nossa privacidade, a falta de transparência de como as nossas informações estão sendo utilizadas, a falta de explicações de como os sistemas de IA chegam as suas conclusões. Alguns desses problemas já estão sendo tratados mundialmente com os códigos de privacidade de dados, mas ainda estão longe de serem resolvidos.

O *Institute of Electrical and Electronic Engineers* (IEEE), a *Association for Computing Machinery* (ACM), a Comunidade Comum Europeia, entre outros, já têm diretrizes para um uso responsável da IA (Hagendorff, 2020). No Brasil temos projetos de lei na câmara dos deputados (Projetos de Lei n.21/20 e 240/20, que remetem ao cumprimento da Lei Geral de Proteção de Dados (LGPD) e outros no senado federal (Projetos de Lei n.5051/2019 e 5691/2019).

Um aspecto legal que precisa ser resolvido é quem será responsabilizado pelos erros e acertos dos algoritmos de IA em sistemas críticos, como na utilização de carros autônomos. Serão os desenvolvedores ou os usuários dos sistemas? Há um interesse crescente de pesquisadores e profissionais em desenvolver e implantar modelos e algoritmos de Aprendizado de Máquina que não são apenas precisos, mas são também explicáveis, justos, que preservam a privacidade, são causais e robustos. Essa ampla área de pesquisa é comumente referida como Aprendizado de Máquina Confiável.

Os sistemas de IA precisam ser explicáveis porque as pessoas devem entender as soluções sugeridas pelos modelos. As explicações dos modelos de IA também servem para se descobrir possíveis erros no próprio modelo, por exemplo, talvez uma das variáveis utilizadas não esteja ajudando na solução ou até esteja atrapalhando. Algumas pesquisas estão sugerindo explicar os modelos complexos de IA pelo uso de modelos mais simples. Outras pesquisas estão usando Técnicas de Explicações Definidas *a Posteriori* (do inglês, *Post Hoc Explanations Techniques*), mas as explicações obtidas com essas soluções ainda não são confiáveis.

Como mencionado anteriormente, parte do sucesso da IA é oriunda da quantidade de dados disponíveis atualmente e do poder computacional das máquinas modernas. Em relação à quantidade e complexidade dos dados, as máquinas precisam de uma quantidade muito maior de exemplos que os humanos para aprender. Não se sabe ainda quantos exemplos são necessários para a máquina aprender uma tarefa complexa. É também necessário reduzir a necessidade de tantos exemplos nos algoritmos de Aprendizado de Máquina porque com dados mais complexos, máquinas melhores serão necessárias. Por outro lado, os humanos aprendem também por correlação com o que já sabem para resolver novos problemas, um mecanismo semelhante a esse dos humanos precisa ser desenvolvido para as técnicas de IA. Na área de Processamento de Linguagem Natural, para reduzir o tempo de treinamento dos algoritmos, foram desenvolvidos sistemas pré-treinados, como Bert (*Bidirectional Encoder Representations from Transformers*) e GPT (*Generative Pre-Training Transformer*), que foram treinados com enormes conjuntos de dados de linguagem geral, como por exemplo o *Corpus* da *Wikipédia*, e podem ser ajustados para tarefas de linguagens específicas (Devlin et. al., 2019).

Existem pesquisas que utilizam Aprendizado Autossupervisionado (do inglês, *Self-Supervised Learning*) para realizar o aprendizado com um menor número de exemplos (Ravanelli et. al, 2020).

Além da necessidade de muitos exemplos no processo de treinamento, alguns

exemplos das tarefas reais podem ser letais e a experiência, limitada e custosa. Não existem disponíveis bons simuladores da vida real para gerar dados de treinamento, e muitos conceitos de alto nível e o conhecimento sobre o mundo são fornecidos por seres humanos, que rotulam dados de treinamento que serão apresentados aos algoritmos de Aprendizado de Máquina. Os conjuntos de treinamento fornecidos aos algoritmos podem não ser uma boa representação do mundo real, e as amostras podem estar enviesadas. Por exemplo, um sistema pode ser desenvolvido para distinguir gatos de cachorros, mas no conjunto de treinamento apresentado ao algoritmo, todos os cachorros são pretos e todos os gatos são brancos, então o sistema pode aprender a distinguir preto de branco e não gato de cachorro. Nesses casos, é necessária a experiência dos humanos para descobrir e solucionar o problema.

Outro aspecto relacionado aos dados é que muitos problemas reais são dinâmicos e dados são gerados continuamente, como, por exemplo no gerenciamento de transportes e monitoramento por redes de sensores. Para resolver problemas dinâmicos são necessárias técnicas de aprendizado em ambientes dinâmicos de fluxos contínuos de dados (**Gama, 2012**).

A resolução de problemas complexos utilizando técnicas de AM necessita do *design* automático, eficiente e correto do sistema. Escolhas eficientes de pré-processamento dos dados, seleção da família de algoritmos apropriados, escolha dos hiperparâmetros dos algoritmos, seleção de atributos e pós-processamento. Para uma maior aplicabilidade das técnicas de AM, a resolução dos problemas com AM precisa ser mais automática. Uma possibilidade é usar Meta-Aprendizado (**Hospedales et al., 2020**). No Meta-aprendizado temos algoritmos que aprendem quais algoritmos e que valores de parâmetros devem ser utilizados para se alcançar bons desempenhos de forma automática.

Um desafio importante de longo prazo é descobrir princípios simples e poderosos que expliquem a inteligência humana. Esses princípios simples e poderosos ajudarão na construção das máquinas inteligentes, da mesma forma que a descoberta das leis de aerodinâmica trouxe o avanço na aviação.

As narrativas dominantes sobre IA tendem a invisibilizar o trabalho humano presente no processo de produção de dados para automação, o que [Ekbja e Nardi \(2017\)](#) chamam "heteromação". Conforme mostram Woodcock e [Graham \(2019, p. 58\)](#), "há tarefas que podem, em teoria, ser realizadas por IA, mas é mais barato e/ou mais rápido simplesmente terceirizar para trabalhadores humanos".

Empresas como Amazon Mechanical Turk (AMT), Appen, Lionbridge, Mighty AI, Clickworker e Spare5 desempenham um papel importante como produtores de dados para a IA, com uma variedade de atividades de trabalho em suas plataformas, incluindo a produção

de dados para o treinamento de carros autônomos. Os discursos dessas plataformas costumam circular sentidos de futuro e progresso. O slogan da Appen, por exemplo, é: "confiança para desenvolver IA com dados de excelência - a inteligência artificial vai melhorar o mundo". Isso ajuda a consolidar, entre os trabalhadores, imaginários positivos de IA e dataficação ([Soriano e Cabanes, 2019](#); [Beer, 2019](#)).

O trabalho por trás da IA é denominado "trabalho fantasma" ([Gray e Suri, 2019](#)), "trabalho do clique" ([Casilli, 2019](#)) e "microtrabalho" ([Tubaro e Casilli, 2019](#)). Essas metáforas são tentativas de nomear atividades de trabalho para produzir dados para a IA. Seja qual for o nome, essas pessoas trabalham para plataformas globais de IA. O caráter global desses sistemas aponta para um fator importante na complexificação do trabalho humano por trás da IA: a dimensão geopolítica das plataformas. O trabalho em plataformas globais de IA difere do circuito de trabalho que envolve o iPhone, por exemplo ([Qiu, Gregg e Crawford, 2014](#)). Naquelas, não há divisão entre a produção de baterias de lítio em um local e a produção de *software* em outro, mas há algumas empresas do Norte Global gerenciando e controlando uma multidão de trabalhadores de vários países, principalmente do Sul Global. As plataformas globais de IA não eliminam espaços físicos e dependem de infraestruturas materiais ([Milan, 2018](#)). A IA é, portanto, "a manifestação do capital altamente organizado e amparado por vastos sistemas de extração e logística, com cadeias produtivas que envolvem todo o planeta" (Crawford, 2021, pp. 18-19). Mais do que apenas uma indústria global, a IA também é um modo de ver e agir sobre a realidade, como uma nova forma de exercício do poder ([Crawford, 2021](#)).

As empresas e os trabalhadores da IA podem estar localizados em diferentes regiões, e os trabalhadores geralmente trabalham em suas casas. Mas isso não significa necessariamente que as tarefas realizadas pelos trabalhadores sejam globais. Às vezes, eles estão localizados no bairro, na cidade ou no país do trabalhador, como análise de publicidades ou tarefas de tradução de texto. Além disso, os métodos de pagamento variam. A AMT, por exemplo, paga apenas aos trabalhadores americanos e indianos em dinheiro. No Brasil, os trabalhadores recebem créditos na loja da Amazon. Outras empresas, como *Appen* e *Lionbridge*, pagam aos trabalhadores em dólares, o que faz com que eles se vejam como parte de uma "classe trabalhadora mundial" ([Soriano e Cabanes, 2019](#)). Isso significa que não há homogeneidade nas práticas nas plataformas globais de IA. Ou seja, não há um universalismo com relação ao trabalho em plataformas ou uma noção homogênea e única da força de trabalho global, portanto há diversos cenários para a relação entre IA e trabalho.

Metodologia

O presente trabalho baseou-se no referencial da pesquisa bibliográfica, que consiste no exame da literatura científica para levantamento e análise do que já se produziu sobre determinado tema. Envolveu as atividades básicas de identificação, compilação, fichamento, análise e interpretação.

Primeiramente foi feita uma revisão bibliográfica das produções científicas em saúde no Brasil, através de um levantamento na biblioteca eletrônica SciELO, que abarca uma compilação selecionada de periódicos científicos brasileiros.

Considerações Finais

A utilização e o desenvolvimento científico em IA têm oportunidades de pesquisa e trabalho em muitas áreas, não somente em Aprendizado de Máquina, mas em outras subáreas, como representação de conhecimento e tomada de decisão. Nos próximos anos haverá o aperfeiçoamento de muitas aplicações que já estão sendo resolvidas parcialmente, tais como: análise de Sentimentos; personalização de ensino, saúde, lazer, investimentos; robôs domésticos, veículos autônomos; detecção de posicionamento; captura de ironia, humor, sarcasmo; interpretação de tom e intenção de fala.

Referências

- Arbix, G., Salerno, M.S., Zancul, E., Amaral, G. e Lins, L.M., 2017. “O Brasil e a Nova Onda de Manufatura Avançada”. Centro Brasileiro de Análise e Planejamento, v.36(03), pp.29-49.
- BISPO, S. C.et al.Inteligência artificial.São Paulo: GrupoA, 2019.
- Cambolm, W.L.L., Silva, S.A. e Gomes, H.P., 2014. “Aplicação de Técnicas Fuzzy no Controle de Pressão em Sistemas de Abastecimento de Água”. Eng Sanit Ambient. v.19(01), pp.67-77.
- Devlin, J. et al. Bert: Pre-training of Deep Bidirectional Transformers for Language Understanding. arXiv:1810.04805, 2019. Disponível em: <https://arxiv.org/abs/1810.04805>.
- Feng, S. et al. Intelligent driving intelligence test for autonomous vehicles with naturalistic and adversarial environment. Nat Commun, v.12, p.748, 2021. Disponível em: <https://doi.org/10.1038/s41467-021-21007-8>

- Gama, J. A survey on learning from data streams: current and future trends. *Progress in Artificial Intelligence*, v.1, n.1, p.45-55, 2012.
- Hospedales, T. et al. A. Meta-Learning in Neural Networks: A Survey. arXiv:2004.05439, 11 Abr. 2020. Disponível em: <https://arxiv.org/abs/2004.05439>
- Junior Puhl, Flávio L. Robótica. São Paulo: Grupo A, 2019. Disponível em: <https://integrada.minhabiblioteca.com.br/#/books/9788595029125/>. Acesso em: 05 nov.2020. MARINHO, David Lima, Aperfeiçoamento de um robô sumo autônomo. 2017. Trabalho de Conclusão de Curso (Bacharelado em engenharia de computação) - Universidade Tecnológica Federal do Paraná, Pato Branco, 2017
- Parreiras, Pedro. Descubra qual o futuro do profissional de engenharia de produção. *Nomus*, 2021. Disponível em: <https://www.nomus.com.br/blogindustrial/descubra-qual-o-futuro-profissional-de-engenharia-de-producao>.
- Ravanelli, M. et al. Multi-task self-supervised learning for robust speech recognition. In: *ICASSP 2020-2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. Barcelona, 2020. p.6989-93.
- Roggia, Leandro; Fuentes, Rodrigo Cardozo. *Automação industrial*. Santa Maria: E-tec Brasil, 2016.
- Rossi, Cristiano. Inversor de frequência modulação senoidal PWM unipolar. Trabalho de Conclusão de Curso (Bacharelado em Engenharia Elétrica) – Universidade Estadual de Londrina, Londrina, 2011.
- Stevan junior, Sergio Luiz; Leme, Murilo Oliveira; Santos, Max Mauro Dias. *Indústria 4.0: fundamentos, perspectivas e aplicações*. São Paulo: Érica, 2018.
- Santos, Jessica da Silva. Modelo de Sistema Fuzzy para o apoio á tomada de decisão em ambientes acadêmicos dinâmicos. Trabalho de Conclusão de Curso (Bacharel em Sistemas de Informação) - Universidade Federal de Sergipe, Itabaiana, 2013.
- Turing, A. M. Computing Machinery and Intelligence. *Mind*, LIX, v.236, p.433-460, doi:10.1093/mind/LIX.236.433, ISSN 0026-4423, October 1950.
- Thomazini, Daniel; Albuquerque, Pedro Urbano Braga de. *Sensores industriais: fundamentos e aplicações*. 8. ed. São Paulo: Érica, 2011.

Submetido em: 08.12.2023

Aceito em: 09.01.2024