

OS DESAFIOS
VENCIDOS E A
VENCER NOS
MODELOS DE
LINGUAGEM: COMO
A INTELIGÊNCIA
ARTIFICIAL TEM
AUXILIADO
O SEGMENTO
JURÍDICO



THE CHALLENGES OVERCOME AND TO BE
OVERCOME IN LANGUAGE MODELS: HOW ARTIFICIAL
INTELLIGENCE HAS HELPED THE LEGAL SEGMENT



Este trabalho está licenciado sob uma Licença
Creative Commons Atribuição-NãoComercial-
SemDerivações 4.0 Internacional.

Data de Submissão: 28/01/2024
Data de Aprovação: 07/05/2024

Elaine Guimarães Restier Gonçalves¹
erestier@organizador.com.br

Carlos Eduardo Reimão Machado²
carlos.machado@docwise.com.br

RESUMO

A tecnologia exerce um papel fundamental na tomada de decisão humana. Com o intuito de minimizar os riscos e aumentar a assertividade das escolhas, pesquisadores do mundo inteiro se debruçaram sobre modelos matemáticos que elevassem o controle sobre este processo. Estes modelos foram a semente das redes neurais nos anos de 1940. A coleta e a geração automática de dados, originou o *Big Data*, definindo o que conhecemos como *Machine Learning*. Ou seja, a própria máquina aprende com os resultados, sem a necessidade da intervenção humana para aprimorar o modelo. A combinação da linguística com modelos estatísticos permite que os computadores não só compreendam o significado das palavras, mas assimilem sentimentos e intenções. Até as redes neurais, os algoritmos de inteligência artificial eram um conjunto de regras e códigos baseados na matemática e na estatística sendo, portanto, modelos universais. Porém, os modelos de linguagem são formados por parâmetros que definem o significado das palavras, em diferentes idiomas, e pela estrutura da linguagem. Ao se predispor a assimilar sentimentos e intenções, o uso de Processamento da Linguagem Natural (PLN) ultrapassa a hermenêutica, sendo necessário uma exegese dos textos. A partir de uma revisão narrativa o objetivo deste artigo é mostrar como chegamos à tecnologia *Generative Pre-trained Transformer* (GPT) e seus desafios futuros. O segmento jurídico será utilizado como um exemplo sobre a influência do léxico e quais os fatores limitantes para o uso da IA Generativa, por outro lado será apresentado os benefícios da IA Preditiva.

Palavras-chave: inteligência artificial; modelos de linguagem; processamento de linguagem natural; tecnologia GPT; jurimetria.

ABSTRACT

Technology plays a fundamental role in human decision-making. In order to minimize risks and increase the assertiveness of choices, researches from all over the world have focused on mathematical models that increase control over this process. These models were the seed of neurais networks in 1940s. The automatic collection and generation of data gave rise to Big Data, defining what we know as Machine Learning. In other words, the machine itself learns from the result, without the need for human intervention to improve the model. Combining linguistics with statistical models allows computers to not only understand the meaning of words, but to assimilate feelings and intentions. Until neurais networks, artificial intelligence algorithms were a set of rules and codes based on mathematics and statistics and were, therefore, universal models. However, language models are formed by parameters that define the meaning of words, in diferente languages, and by the structure of the language. By predisposing to assimilate feelings and intentions, the use of NLP goes beyond hermeneutics, requiring exegeses of the texts. From a narrative review, the objective of this article is to show how we arrived at GPT (Generative Pre-trained Transformer) technology and its future challenges. The legal segment will be used as an example of the influence of the lexicon and what are the limiting factors for the use of Generative AI, on the other hand the benefits of Predictive AI will be presented.

Keywords: artificial intelligence; language models; natural language processing; GPT technology; jurimetry.

1 Economista (UGF/RJ) com MBA em Business Intelligence pelo Senac- SP. Sócia-diretora da Organizator Consultoria especializada em Gestão de Documentos Eletrônicos.
<https://orcid.org/0009-0009-6912-8575>
erestier@organizator.com.br

2 Formado em Administração de Empresas (PUC-SP), com pós-graduação em Administração (FGV) e Gestão de Projetos (IPT/USP). Sócio da Docwise Consultoria especializada na implantação de GED para o mercado jurídico.
<https://orcid.org/0009-0005-8407-9696>
carlos.machado@docwise.com.br

1 INTRODUÇÃO

A partir de uma revisão narrativa o objetivo deste artigo é mostrar como chegamos à tecnologia GPT (*Generative Pre-trained Transformer*) e seus desafios futuros. O segmento jurídico será utilizado como um exemplo sobre a influência do léxico e quais os fatores limitantes para o uso da IA Generativa, por outro lado será apresentado os benefícios da IA Preditiva.

As redes neurais artificiais, *Artificial Neural Networks* (ANN), são um sistema computacional inspirado no cérebro humano, que usa nós interconectados imitando a maneira como os neurônios biológicos enviam sinais uns para os outros. Usando algoritmos, elas podem reconhecer padrões e correlações em dados brutos, agrupá-los e classificá-los, incorporando essas “normas” e aprendendo com elas.

O processo de aprendizado por experiência é o cerne das redes neurais, que emula o modelo do neurônio interconectado. O modelo matemático denominado “Lógica de Limiar”, criado pelos cientistas americanos Warren McCulloch e Walter Pitts, em 1943, foi o início da aplicação das redes neurais à inteligência artificial. Mas o modelo só viria a se tornar algo concreto na segunda metade da década de 1950.

Tempos depois, em 1949, Donald Hebb, em sua obra “*The Organization of Behavior*”, ressaltava que as sinapses, os impulsos entre os neurônios, fortalecem o aprendizado. É como se fosse a ginástica para o cérebro, você exercita os neurotransmissores para melhorar o aprendizado. Mas a necessidade de inúmeras iterações tornava o processo lento, o que frustrou aqueles que esperavam a mesma velocidade do cérebro humano.

A ideia de uma máquina capaz de “pensar” apareceu pela primeira vez no artigo “Computadores e Inteligência”, publicado em 1950 pelo matemático Alan Turing, no qual ele discorria sobre como construir máquinas inteligentes. Turing ficou conhecido por ter criado o teste para verificar a inteligência de um computador. O termo Inteligência Artificial (IA) só viria a aparecer na Conferência do Dartmouth College¹, em 1956, com o desenvolvimento da linguagem de programação LISP, por John McCarthy. Nesse mesmo ano, os pesquisadores Allen Newell, JC Shaw e Herbert Simon criaram o *Logic Theorist*, considerado o primeiro software de IA.

Em 1958, o modelo de rede neural saiu do papel com a criação do Perceptron, por Frank Rosenblatt, que implementou o modelo em um computador da época, chamado de *Mark I Perceptron machine*.

A partir de então, instituições renomadas se debruçaram sobre modelos para máquinas pensantes, mas sem muito avanço. As discussões sobre ética e o impacto da IA na vida humana na década de 1960 arrefeceram os investimentos e deram origem ao *AI Winter* (ou inverno da Inteligência Artificial) que durou até o início dos anos 1980. Um dos poucos avanços neste período foi a criação do primeiro chatbot batizado ELIZA (1964), e na área de Processamento da Linguagem Natural (PLN), a elaboração de alguns léxicos como General Inquirer (GI), com 11 mil palavras distribuídas em 183 categorias.

O tema só voltou a aquecer a partir de 1985 com eventos científicos, tais como a reunião anual “Redes Neurais para Computação”, do Instituto Americano de Física e a Conferência Internacional sobre Redes Neurais², do *Institute of Electrical and Electronic Engineers* (IEEE)³.

1 Dartmouth Summer Research Project on Artificial Intelligence, Hanover, New Hampshire, 1956.

2 Neural Networks for Computing Conference; Snowbird, Utah, 1986.

3 IEEE First International Conference on Neural Networks; San Diego, California, June, 1987.

2 DESAFIOS VENCIDOS E A VENCER

Nesta época, já estávamos na 4ª geração dos processadores e conforme previu Gordon Moore, fundador da empresa norte-americana Intel, a capacidade dos microprocessadores dobraria a cada 18 meses. Os desafios representados pelo tamanho das máquinas e seu aquecimento impulsionaram as pesquisas para tornar os equipamentos menores e mais ágeis. No início dos anos 2000, a tecnologia multicore permitiu ao computador fazer trabalhos simultâneos em núcleos distintos, proporcionando interconexões de alta velocidade, mais próximas do ritmo de processamento do cérebro humano.

2.1 Resolvido o desafio da velocidade, chegava a hora de encarar o volume

Os dados são os principais insumos para as decisões. A coleta de dados remonta à década de 1960, mas foi a partir de 2005 que os cientistas perceberam a necessidade de tratar dados não estruturados, ou seja, não armazenados em banco de dados, mas espalhados em páginas na internet, reproduzidos em áudio & vídeo, registrados em documentos, gerados por máquinas etc.

O acúmulo de dados exige uma grande capacidade de armazenamento e é justamente neste cenário que a computação em nuvem colabora. Escalar rapidamente o volume de dados e formar cluster (grupos) para testar modelos específicos são benefícios valiosos no desenvolvimento da IA.

A IA permitiu que passássemos a ‘ensinar’ as máquinas e não apenas programá-las, este é o conceito do *Machine Learning*. Porém, isto depende diretamente de imensos volumes de dados confiáveis e classificados.

As metodologias de *Machine Learning* variam da classificação dos dados já rotulados e sua regressão (Aprendizado Supervisionado), até o agrupamento e associação livre (Não Supervisionado). Independentemente do método, o que se pretende é descobrir uma “fórmula” a partir de resultados.

Com o aumento exponencial do volume de dados estruturados e não-estruturados disponíveis, o chamado ‘*big data*’, foram desenvolvidos os sistemas de *deep learning*, que são redes neurais com muitas camadas. O *deep learning* possibilita a captura e a mineração de mais e maiores volumes de dados, incluindo dados não-estruturados, aumentando a possibilidade de obter modelos preditivos.

Além de muito mais veloz do que o aprendizado humano, o aprendizado de máquina sofre melhoria contínua. Ou seja, com base nas iterações (repetições) o modelo se ajusta constantemente na busca da maior precisão.

O uso e o benefício da IA Preditiva são absorvidos mais facilmente, uma vez que permeiam todo o nosso cotidiano, como alguns exemplos apresentados na figura 1.

Figura 1 – Exemplos de uso da IA Preditiva

Uma instituição financeira ao coletar o momento do uso de uma caixa eletrônico para retirada de recursos numa determinada cidade, prevê que você não poderia fazer o uso do cartão de crédito em outra cidade.

Ao registrar os dados de um equipamento, aquecimento do motor, consumo de energia acima da média, uma indústria pode evitar a parada da sua operação e garantir sua produtividade.

O uso de ração adequada, combinada com vacinas e dados do clima, ajudam a prever quando o gado de uma fazenda atingirá o peso ideal para abate.

Fonte: elaborado pelos autores

2.2 Jurimetria - usos e benefícios no segmento jurídico

O segmento jurídico foi um dos que se debruçou sobre as possibilidades da IA com a conhecida Jurimetria. Divulgada como a estatística aplicada aos processos jurídicos, a Jurimetria a partir de “casos” anteriores pode oferecer:

- (i) o prazo médio de um processo;
- (ii) o valor provável de uma indenização e
- (iii) a possibilidade de um “argumento” ser aceito pelo juiz; entre outros dados.

A análise de grandes volumes de processos judiciais, jurisprudências e doutrinas, permite que sejam identificados padrões e tendências que podem gerar “insights” importantes para tomadas de decisões, que considerem o interesse do cliente, de forma consciente e estratégica.

É importante ressaltar que não basta um grande volume de peças processuais para indicar um “argumento” como tendência positiva. É necessário um padrão. E, no caso da justiça brasileira, nem mesmo a jurisprudência, assegura uma sentença. Cada processo possui suas peculiaridades e os magistrados, suas convicções.

A segurança da informação é uma preocupação de todas as empresas, mas atinge especialmente os escritórios de advocacia e departamentos jurídicos. Por armazenar informações sensíveis, confidenciais e dados pessoais, essas equipes se tornam alvos de cibercriminosos e agentes mal-intencionados. Sendo assim, proteger os dados de seus clientes se torna um fator estratégico para essas organizações.

Tradicionalmente a forma de proteger os ambientes é por meio de ferramentas tecnológicas,

como firewalls, antivírus, anti-spams etc. O problema é que os ataques estão sempre mudando seus métodos e se tornam cada vez mais sofisticados. Uma boa estratégia de proteção deve considerar o que pode ser feito para impedir um ataque, mas também o que fazer quando isso acontecer.

Dados apresentados nas figuras 2 e 3 demonstram que 74% dos usuários remotos acessam dados sensíveis e, após a pandemia e com o crescimento do *home office*, foi necessário aprimorar os sistemas de segurança para garantir a proteção dos dados em múltiplas localidades e dispositivos.

Figura 2 – Acesso a dados sensíveis



Figura 3 – Quem é o dono do documento



Fonte: iManage - EUA⁴, 2023.

No ramo jurídico, especificamente o monitoramento de repositórios de documentos com base na estatística do comportamento dos usuários, explora a IA para antecipar a possibilidade de um vazamento de dados. Ou seja, a emissão de relatórios com atividades passadas já não é mais eficiente, os sistemas precisam ser proativos.

Uma ferramenta de proteção proativa, que permite alertar o escritório sobre atividades incomuns

4 Protect wath maters. iManage, Chicago, 2023.

no sistema em tempo real, é o Threat Manager® da empresa norte-americana iManage. Esta ferramenta utiliza algoritmos de IA e *machine learning* para definir padrões de comportamento para cada usuário do sistema e monitora os eventos em busca de mudanças de comportamento.

O Threat Manager® é uma ferramenta desenvolvida exclusivamente para monitorar o iManage Work, repositório de documentos embarcado com o conjunto de tecnologias conhecidas como GED (Gerenciamento Eletrônico de Documentos). De acordo com o Woodbridge, M. et al. (2021), a empresa iManage é posicionada como fornecedor de nicho específico no Quadrante Mágico para plataformas de serviço de conteúdo.

Como o sistema GED já possui um histórico de eventos e atividades realizadas em todos os arquivos armazenados, o Threat Manager® indexa essas informações e aplica seus algoritmos para calcular padrões de comportamento em diferentes níveis:

- **Individual:** é definido o padrão de comportamento para cada usuário, com base nas ações existentes no sistema. Por exemplo, quantos documentos cada usuário cria por dia, edita, exporta, imprime, envia por e-mail etc..
- **Grupo:** o mesmo conceito é aplicado para cada grupo de atuação do escritório.
- **Escritório:** novamente, o mesmo conceito é aplicado para todo o escritório.

A partir desse momento são criadas regras para monitorar as atividades do sistema e classificá-las de acordo com a gravidade do alerta. Se um usuário executa atividades que fogem do seu comportamento padrão, é emitido um alerta. Se as atividades também fogem do comportamento padrão do grupo desse usuário, ou até mesmo de todo o escritório, o alerta se torna mais prioritário.

O tamanho do desvio é outro atributo que escala o nível do alerta, indicando sua prioridade. Essa metodologia permite que o escritório priorize os alertas mais urgentes e minimiza a possibilidade de falsos positivos.

O uso desta ferramenta torna o trabalho remoto mais eficiente, em conformidade com as melhores práticas de *Data Loss Prevention* (DLP), e permite inclusive bloquear automaticamente o usuário no sistema, impedindo o roubo ou vazamento de dados.

O monitoramento de cada evento (download, impressão, envio por e-mail) é muito importante porque alguns usuários se sentem ‘donos’ do documento, uma vez que são os produtores do mesmo. Uma pesquisa recente mostra que 53% dos usuários acredita que por terem trabalhado em um documento, o mesmo é de sua propriedade.

2.3 O desafio da linguagem

Qualquer aplicabilidade da IA busca: precisão nos resultados, maior previsibilidade, eficácia na execução das tarefas e minimização de desvios, todos objetivos para maximização dos resultados. Porém, para as empresas, um ponto seguia vulnerável: melhorar a comunicação entre empresa e cliente, tornando esta experiência mais humana e personalizada.

O PLN se debruça sobre como os humanos se comunicam, seja pela palavra escrita ou falada, na busca pela interpretação mais precisa e sem ambiguidades. E para isto é fundamental a criação de léxicos que descrevam os conceitos dos termos. A gramática de uma palavra impacta no significado e na intensidade do sentimento envolvido no texto.

A avaliação de um produto no comércio eletrônico é fundamental para o direcionamento do pós-venda. A publicação de uma avaliação positiva

pode ser utilizada para uma ação de remarketing, assim como uma avaliação negativa aciona protocolos do Serviço de Atendimento ao Cliente (SAC).

O desafio é: qual metodologia será usada para identificar a polaridade de uma expressão? Imagine um cliente que escreve “Não gostei amei”, sem pontuação. Para a máquina identificar com certo grau de confiabilidade a avaliação positiva é preciso explorar de mais de uma metodologia. Além do léxico, a heurística e processamento são explorados para uma maior precisão no entendimento.

A tecnologia de aprendizado de máquina demanda muito investimento porque depende de uma base de dados rotulada, ou seja, previamente classificada. Já os métodos léxicos dependem de um dicionário associado a sentimentos. Ou seja, cada palavra é associada à sua polaridade -1 (negativa) a +1 (positiva).

Vale ressaltar que a maior parte dos dicionários léxicos são no idioma inglês. Usar tradutores na análise dos textos pode comprometer sua interpretação.

2.4 O desafio do idioma

Tratar a linguagem não é uma coisa recente, em 1940, na 2ª Guerra Mundial, surge a primeira máquina de tradução baseada em modelos estatísticos. Desde então, a evolução para a tradução automática neural, *Neural Machine Translation* (NMT), suportada por altos investimentos de gigantes como Google (Grupo Alphabet), a partir de 2015, se tornou uma técnica bem promissora. Mesmo assim, em 2017 um estudo de Koehn e Knowles, da Universidade Johns Hopkins, apontou seis desafios importantes para este tratamento de linguagem:

1. Incompatibilidade de domínio.
2. Quantidade de dados de tratamento.

3. Palavras raras.
4. Frases longas.
5. Alinhamento de palavras.
6. Pesquisa de Feixes.

O desafio do domínio é antigo, palavras têm traduções diferentes e seu significado é expresso de forma diferente. Para pares de idioma como inglês-espanhol ou alemão-inglês estão disponíveis grandes conjuntos de dados, o que permite maior acurácia na abordagem de tradução automática neural. Mas outras metodologias de tradução, como modelos baseados em sintaxe, demonstraram oferecer desempenho superior para pares de idiomas, como chinês-inglês.

A tradução automática neural tem uma qualidade menor em sentenças muito longas (mais de 60 palavras) e com palavras de baixa frequência de uso, principalmente, quando estas possuem muitas inflexões, tais como os verbos.

O modelo NMT busca um conjunto de palavras com maior probabilidade de tradução na sentença trabalhada, o tamanho deste feixe de pesquisa, impacta diretamente na qualidade da tradução, especialmente quando não se normaliza as pontuações em frases compridas.

Estes modelos são desenvolvidos em um domínio e treinados para outros domínios, sendo natural uma certa degradação de performance. A conclusão do estudo de Koehn e Knowles (2017) é que a tradução automática neural precisa de mais robustez quando confrontada com condições significativamente diferentes das condições de treinamento.

Assim como o processamento de dados, o PLN também possui cinco etapas.

Análise lexical e morfológica - na primeira fase é feita a análise das palavras e a separação de acordo com a sua estrutura dividindo-as em morfemas e

depois a interpretação do significado de cada palavra usada na interação com a máquina.

Análise sintática – a sintaxe analisa a disposição das palavras em uma frase e busca o sentido entre elas para entender o significado, além de verificar se a frase está gramaticalmente correta.

Análise semântica – a análise semântica busca encontrar o significado da frase, verificando o significado literal das palavras e as estruturas para identificar o sentido.

Integração discursiva – o objetivo da integração discursiva é fazer uma análise completa do que foi falado ou escrito, buscando interpretar o texto de acordo com o contexto.

Análise pragmática – Na última fase é feita a interpretação do texto e a identificação da mensagem. Além da extração de informações que podem ser úteis em outros momentos.

Os avanços nas tecnologias de processamento de linguagem, que abrange NMT e PLN, na combinação de linguística computacional (modelagem baseada em regras de linguagem) e nos modelos estatísticos de machine learning e deep learning podem levar a IA a ultrapassar uma das últimas fronteiras: a capacidade de as máquinas compreenderem a linguagem humana.

2.5 Tecnologia GPT: todo texto tem um contexto e um pretexto

A tecnologia GPT (*Generative Pre-trained Transformer*) é uma rede neural chamada Transformer apoiada em grandes bases de dados textuais em vários domínios e não apenas em traduções. O GPT se baseia em um léxico criado, definido e conceituado por pessoas. A questão que se põe é quem está definindo estes parâmetros

linguísticos? São historiadores, filólogos, profissionais de tecnologia, bibliotecários?

A *Conference on Machine Translation* (WMT) é um evento anual que divulga o avanço nos sistemas de tradução automática. Os diferentes sistemas de tradução (DeepL, Google Translate, Microsoft Translator, OpenNMT entre outros), têm os resultados da tradução apresentados segundo as métricas internacionais. Uma das métricas utilizadas pelo WMT é o *Language Modeling Bias*, ou Viés de Modelação de Linguagem, que se refere aos vieses inerentes ou implícitos que podem estar presentes nos modelos de linguagem. O viés de modelação de linguagem é oriundo de diversos fatores, por exemplo:

- **Seleção dos dados treinados** – a amostra selecionada pode não representar a diversidade de experiência necessária.
- **Dados treinados** – os dados treinados espelham os vieses presentes na sociedade, tais como preferências culturais, estereótipos, desigualdades sociais etc.
- **Reforço de viés existente** – os modelos de linguagem podem amplificar certos vieses, devido a forma como a linguagem é modelada e as respostas são geradas.

Dependendo do idioma utilizado para explicar os movimentos populares ocorridos em Hong Kong, em 2003, por exemplo, o Chat GPT pode responder que foi um movimento popular legítimo em busca de mais liberdade (inglês) ou uma rebelião subversiva contra o governo chinês (mandarim). Diferentes textos e resumos foram utilizados no idioma selecionado para “formar” este conceito.

Da mesma forma, o léxico criado deverá significar palavras, contextos e suas relações. Estruturar uma ontologia é fundamental para estabelecer os

conceitos. O que diferencia pão de forma de forma de pão? A palavra “pão” faz parte uma classe distinta da palavra “forma”, mas juntas formam um conceito que deve ser previsto.

O volume explosivo de dados, gerados e publicados na internet, faz com que somente a busca não atenda os usuários. Uma série de informações é disponibilizada, sem qualidade e autoridade reconhecida e, muitas vezes, impertinentes. Até o início dos anos 2000 estes motores de busca tradicionais usavam apenas a sintaxe como parâmetro de pesquisa e respondiam com links para consulta. Em 2001, a Berners-Lee cunha o termo Web Semântica, para uma web onde a informação recebe um significado bem definido. Desde esta época os agentes inteligentes são perseguidos de forma a facilitar a busca pela informação correta.

A identificação da fonte é fundamental para credibilizar a informação, é a partir dela que é conferida autoridade ao texto. Fabris em “As cartas de Paulo” (1992), apresenta a ideia da importância do vocabulário ao analisar as cartas do apóstolo Paulo, a partir da identificação de cerca de 40 termos utilizados em 3 cartas pastorais (2 para Timóteo e 1 para Tito), que nunca haviam sido utilizados nas cartas anteriores, é que se questionou sua autoria. Ou seja, a definição do estilo da escrita é determinante para indicar sua autoria. Contudo, no uso da tecnologia GPT não há autoria, e esta nos parece ser a grande questão.

3 CONCLUSÃO

Neste artigo mostramos que nos últimos 80 anos muitos desafios foram vencidos pela IA, por mais que a tecnologia moderna permita evoluções rápidas, ainda temos, pelo menos, dois desafios importantes a serem vencidos pela IA Generativa.

A questão Ética é um desafio antigo, data de 1960, e ainda não temos respostas para algumas questões. Apesar da intensidade dos debates atuais, será possível regular a ética? Será que a IA na busca da maximização dos resultados da política econômica de um Estado sacrificaria investimentos na área de saúde e educação a favor de um superávit das contas públicas? Qual o risco da IA na área de saúde sugerir tratamentos caros para doenças simples, em prol do lucro financeiro das farmacêuticas? Estas perguntas demandam um debate amplo envolvendo governo, empresários e toda a sociedade civil.

Um desafio mais recente é o da linguagem. Apesar de dicionários de léxicos, ontologias e outras ferramentas da arquivística terem evoluído, os conceitos dos termos e seus vieses necessitam ser aperfeiçoados. A IA preditiva parece ter um caminho mais fácil e deve seguir contribuindo para otimizar processos e mitigar riscos.

Concluindo, apesar da grande evolução das soluções tecnológicas, pesquisadores, técnicos, empresas, governos e a sociedade civil ainda terão muitos desafios para o pleno uso delas em benefício das tarefas humanas.

REFERÊNCIAS

- FABRIS, Rinaldo. As cartas de Paulo, III.** São Paulo: Loyola, 1992.
- HEBB, Donald. The organization of behavior: A neuropsychological theory.** Wiley, 1949.
- KOEHN, P.; KNOWLES, R. Six challenges for neural machine translation.** Proceedings of the First Workshop on Neural Machine Translation. Association for Computational Linguistics, 2017.
- MCCULLOCH, W. S. ; PITTS, W. A logical calculus of the ideas immanente in nervous activity. Bulletin of Mathematical Biophysics, 1943.** Disponível em <https://link.springer.com/article/10.1007/BF02478259>. Acesso em: 10 de outubro de 2023.
- STONE, P. J.; DUNPHY, D.; SMITH, M. S.; OGILVIE, D. M. The general inquirer, a computer approach to content analysis.** The MIT Press, 1966.
- TURING, Alan Mathison. Computing Machinery and intelligence. Mind, England, v. 59, n. 236, 1950.**
- WOODBRIGE, M. et al. Magic Quadrant for Content Service Plataforms.** Gartner Inc., 18 out. 2021. Licenciado para distribuição. ID G00040125.

NOTAS

Conflito de interesse: Declaro que não há nenhum conflito de interesse financeiro ou de outra natureza, com respeito à publicação do artigo.

Contribuição dos autores: informo que o artigo se classifica como Concepção e elaboração do manuscrito. **Ambos os autores participaram da elaboração e revisão do artigo.**

Informar se a publicação é oriunda de uma dissertação ou tese: Declaro ainda que este artigo não é oriundo de nenhuma tese ou dissertação.

Aprovação Ética: Não se aplica.

Agradecimentos: Agradecemos à Claudio Roberto Guimarães Restier Gonçalves que, com sua visão crítica, nos ajudou a não fugir do tema proposto. Um agradecimento especial a Márcia Avruch que colaborou na revisão do artigo para que garantíssemos um texto limpo e preciso.