



Universidade de Brasília – UnB
Instituto de Ciências Humanas – IH
Departamento de Filosofia

Elder Alexandre Machado Araujo

Uma análise Kuhniana da Inteligência Artificial

Brasília - DF

2023

Elder Alexandre Machado Araujo

Uma análise Kuhniana da Inteligência Artificial

Monografia apresentada à Universidade
de Brasília como requisito de conclusão
para obtenção de título de Bacharel em
Filosofia

Orientador: Prof. Dr. Samuel José Simon

Brasília - DF

2023

Elder Alexandre Machado Araujo

Uma análise Kuhniana da Inteligência Artificial

Monografia apresentada à Universidade
de Brasília como requisito de conclusão
para obtenção de título de Bacharel em
Filosofia

Orientador: Prof. Dr. Samuel José Simon

**Aprovado em 21, de Dezembro, de 2023, pela Banca
Examinadora constituída
pelos professores:**

Prof. Dr. Samuel José Simon – Orientador
Universidade De Brasília – UnB

Profa. Dra. – Maria Cecília Pedreira de Almeida - Avaliadora
Universidade De Brasília – UnB

A663 Araujo, Elder Alexandre Machado.

Uma análise Kuhniana da Inteligência Artificial / Elder Alexandre Machado Araujo. - Brasília, 2023.

43 f.

Monografia (Bacharelado em Filosofia) - Universidade de Brasília, 2023.

Área de concentração: Filosofia da Ciência.

Orientador: Samuel José Simon

1. Inteligência Artificial. 2. Progresso da Ciência. 3. Thomas Kuhn. 4. Mudança de Paradigma. I. Simon, Samuel José. II. Universidade de Brasília. III. Título.

CDD 001.53

RESUMO

Esse trabalho explora o impacto da Inteligência Artificial (IA) na ciência à luz da filosofia da ciência de Thomas Kuhn. Inicialmente, o texto contextualiza o progresso oriundo das revoluções científicas, de acordo com Kuhn, abrindo a discussão para a contextualização da Inteligência Artificial (IA). Os conceitos de paradigma e matriz disciplinar são explicados, seguidos por uma discussão sobre a importância da técnica na criação de modelos. A IA é então introduzida, tanto historicamente quanto tecnicamente, e suas aplicações são discutidas. O trabalho aborda ainda os desafios apresentados pela grande quantidade de dados necessários para a criação de modelos de IA. Em seguida, explora o conceito do Quarto Paradigma e da e-Science, apresentando a questão de uma possível mudança de paradigma nas ciências. A Ciência de Dados é introduzida como uma ferramenta potencial para lidar com a grande quantidade de dados, e a relação entre a Ciência de Dados e a IA é explorada. Finalmente, o trabalho então examina o impacto das técnicas de IA no progresso da medicina, como um exemplo de sua aplicação prática e aponta para as questões éticas relacionadas ao uso da IA e a necessidade de confiabilidade nos sistemas de IA.

Palavras-chave: Inteligência Artificial. Progresso da Ciência. Thomas Kuhn. Mudança de Paradigma.

ABSTRACT

This work explores the impact of Artificial Intelligence (AI) on science in light of Thomas Kuhn's philosophy of science. Initially, the text contextualizes the progress stemming from scientific revolutions, according to Kuhn, opening the discussion for the contextualization of Artificial Intelligence (AI). The concepts of paradigm and disciplinary matrix are explained, followed by a discussion about the importance of technique in model creation. AI is then introduced, both historically and technically, and its applications are discussed. The work also addresses the challenges presented by the large amount of data needed to create AI models. It then explores the concept of the Fourth Paradigm and e-Science, presenting the question of a possible paradigm shift in the sciences. Data Science is introduced as a potential tool to deal with the large amount of data, and the relationship between Data Science and AI is explored. Finally, the work examines the impact of AI techniques on the progress of medicine, as an example of its practical application and points to the ethical issues related to the use of AI and the need for reliability in AI systems.

Keywords: Artificial Intelligence. Progress of Science. Thomas Kuhn. Paradigm Shift.

Sumário

I- INTRODUÇÃO	7
II- Considerações acerca dos termos paradigma e matriz disciplinar	9
III- A importância da técnica na criação de modelos	11
IV- Explicação da inteligência artificial e suas aplicações	16
V- Os desafios que compõe a tecnologia para a criação de modelos de IA.....	22
VI- O Futuro da Ciência: Uma Exploração do Quarto Paradigma e da e-Science.....	24
VI.1- Os desafios em decorrência da imensa quantidade de dados	25
VI.2- As novas formas de se fazer ciência: 4º paradigma e E-Science.....	28
VII- Ciência de dados e sua relação com a inteligência artificial	31
VIII- A importância das técnicas de inteligência artificial para o progresso da medicina.....	34
IX- A ética e a confiabilidade do uso da inteligência artificial	36
Conclusão	39
Referências	41

Introdução

Thomas Kuhn é uma figura central na filosofia e na história da ciência. Seu livro, *A Estrutura das Revoluções Científicas*, publicado em 1962, foi um marco que influenciou tanto círculos acadêmicos quanto populares, especialmente com a noção de paradigma. Kuhn forneceu uma nova metodologia para entender o desenvolvimento da ciência, fundada, em grande parte, na história da ciência e na noção de comunidade científica. Além disso, cunhou o conceito de ‘ciência normal’, que significa sucessos científicos passados que os cientistas reconheceram como base para o progresso científico futuro.

No contexto de outros estudiosos de sua época, Kuhn se destacou por sua abordagem única. Enquanto muitos filósofos estavam focados em questões epistemológicas, Kuhn estava mais interessado em como as comunidades científicas operam e como elas contribuem para o progresso científico. Sua influência se estendeu muito além da filosofia da ciência, para a história da ciência, a sociologia da ciência e para a cultura, de maneira mais ampla, especialmente com a noção de paradigma.

Nesse trabalho, com adiantado acima, examinaremos alguns aspectos da Inteligência Artificial (IA), no contexto da Filosofia da Ciência de Thomas Kuhn. À medida que nos preparamos para mergulhar nesta discussão fascinante, é importante considerar o potencial revolucionário da Inteligência Artificial (IA) no campo da ciência. A IA, com suas técnicas avançadas e capacidades de aprendizado, tem o poder de impulsionar e até mesmo revolucionar a maneira como a ciência é conduzida. No entanto, a questão que se coloca é: essa transformação constitui uma revolução no sentido proposto por Thomas Kuhn? Kuhn, em sua obra seminal *A Estrutura das Revoluções Científicas*, argumenta que o progresso científico ocorre através de “revoluções” ou mudanças de paradigma. Portanto, ao explorar o impacto da IA na ciência, devemos em um primeiro momento expor como se dá o progresso da ciência na visão de Thomas Kuhn e depois contextualizar a IA nesse progresso; em um segundo momento, considerar se a IA está simplesmente acelerando o progresso dentro dos paradigmas existentes ou se está, de fato, catalisando uma mudança completa de paradigma. Esta é uma questão complexa e multifacetada, que exige uma análise cuidadosa e reflexiva, e tentaremos responder parte dela.

Ao discorrer sobre a história da ciência, Kuhn delineia uma trajetória caracterizada por elementos distintos, fases específicas, e desafios inerentes ao progresso. Ele postula que o

avanço científico é catalisado por meio de revoluções científicas. Esta trajetória pode ser resumida da seguinte maneira:

Durante o período de ciência normal, os pesquisadores trabalham dentro do paradigma estabelecido, resolvendo quebra-cabeças e aprofundando o entendimento dentro desse quadro. No entanto, quando surgem anomalias, ou seja, fenômenos que não podem ser explicados ou resolvidos pelo paradigma atual, isso pode levar a uma crise. A crise abre caminho para a descoberta científica e a formação de uma nova teoria – ou paradigma –, levando em consideração o aperfeiçoamento de técnicas científicas que possam resolver a anomalia. Esta nova teoria, ou modelo, se aceita pela comunidade científica, pode se tornar a base para um novo paradigma. A transição de um paradigma para outro é o que Kuhn chama de revolução científica.

É crucial enfatizar que a transição de um paradigma para outro implica na renúncia de um paradigma existente. Isso ocorre na medida em que o novo paradigma demonstra sua capacidade de resolver não apenas os novos problemas emergentes das anomalias, mas também os problemas previamente solucionados pelo paradigma antigo. Esta capacidade de abordar efetivamente ambos os conjuntos de problemas é um critério fundamental para a aceitação de um novo paradigma pela comunidade científica.

Após a revolução científica, a ciência retorna a um estado de normalidade, agora dentro do novo paradigma. Este ciclo de ciência normal, anomalia, crise, descoberta científica, teoria científica, resposta à crise, revolução científica e retorno à ciência normal é uma característica distintiva da dinâmica científica, e o progresso, segundo Kuhn, é capacidade de os paradigmas – ou teorias – subsequentes resolverem os velhos e novos problemas). Portanto, o paradigma desempenha um papel crucial na orientação da pesquisa científica, na construção de modelos e na evolução da ciência.

As mudanças de paradigma, marcos fundamentais na dinâmica do progresso da ciência, ocorrem quando anomalias inexploradas pelo paradigma atual se acumulam a tal ponto que a comunidade científica é forçada a questionar e, eventualmente, substituir o paradigma existente. Na física, por exemplo, a transição do modelo mecanicista de Isaac Newton para as teorias da relatividade de Albert Einstein e a mecânica quântica de Niels Bohr e Heisenberg – entre outros - representou uma mudança de paradigma significativa.

II- Considerações acerca dos termos paradigma e matriz disciplinar

O paradigma, conforme discutido por Kuhn, refere-se a um conjunto de crenças, valores, métodos, teorias e práticas compartilhadas por uma comunidade científica em um determinado período. Em um primeiro momento, Kuhn na *A Estrutura das Revoluções Científicas* define paradigma como realizações científicas dentro de uma certa comunidade capaz de fazer esforços para solucionar problemas e quebra-cabeças em uma determinada área. "Considero 'paradigmas' as realizações científicas universalmente reconhecidas que, durante algum tempo, fornecem problemas e soluções modelares para uma comunidade de praticantes de uma ciência." (KUHN, 2013, p. 52).

Este conceito de paradigma é semelhante ao usado no ensaio de Kuhn "Tensão Essencial: Tradição e Inovação na Pesquisa Científica", no qual o conceito de solução de problemas é repetido, utilizando o termo "paradigma", para se referir a "soluções de problemas concretos" (KUHN, 2009, p. 265). Considerando a necessidade de resolver problemas concretos, podemos perceber que tanto o paradigma apresentado no Posfácio de Thomas Kuhn quanto a matriz disciplinar compartilham um objetivo comum: a solução de problemas concretos. Isso se aplica mesmo ao Posfácio da *Estrutura*, indicando que a exigência de 'solução de problemas' está presente em ambas as noções. Mais adiante, na mesma obra, Kuhn também ressalta que o termo paradigma pode ter o sentido de "técnica".

A polissemia do termo paradigma é significativa, como Kuhn ressalta no Posfácio (KUHN, 2013, p. 271-272), onde irá descartar o termo em favor da matriz disciplinar. No entanto, é importante ressaltar que o paradigma – noção presente em toda a *Estrutura* - é fundamental para entender a natureza das revoluções científicas e o crescimento da ciência. Um paradigma, dentro da filosofia da ciência de Thomas Kuhn, pode ser visto como um modelo ou exemplo a ser seguido dentro de uma determinada disciplina. Ele representa um conjunto de conceitos, métodos, e teorias que são aceitos e compartilhados pelos membros de uma comunidade científica. No Posfácio da *Estrutura*, Kuhn revisa o conceito de paradigma, apresentando-o tanto como uma matriz disciplinar quanto como um componente intrínseco dessa matriz.

"Percebe-se rapidamente que na maior parte do livro o termo paradigma é usado em dois sentidos diferentes. De um lado, indica toda a constelação de crenças, valores, técnicas etc., partilhadas pelos membros de uma comunidade determinada. De outro, denota um tipo de elemento dessa constelação: as soluções concretas de

quebra-cabeças que, empregadas como modelos ou exemplos, podem substituir regras explícitas como base para a solução dos restantes quebra-cabeças da ciência normal." (KUHN, 2013, p.263).

O paradigma orienta os pesquisadores nas suas pesquisas, proporcionando regras, modelos e técnicas que possam liderar o trabalho científico das comunidades científicas. Essas orientações fornecidas pelo paradigma ajudam a estabelecer um consenso dentro da comunidade científica, permitindo que os pesquisadores compartilhem uma linguagem comum e abordem problemas de pesquisa de maneira sistemática. Dessa forma, o paradigma desempenha um papel fundamental na evolução e no avanço da ciência.

É uma estrutura conceitual que estabelece os fundamentos e diretrizes para a pesquisa e a prática científica em uma determinada área. O paradigma fornece um quadro de referência comum para a comunidade científica, orientando a formulação de perguntas, a interpretação de dados e a resolução de problemas científicos.

A importância do paradigma na construção de modelos é inegável. Os modelos, que são representações simplificadas da realidade, são construídos com base nos paradigmas que prevalecem em uma determinada época e contexto. Eles refletem as crenças, valores, métodos e teorias que são aceitos e compartilhados pelos membros de uma comunidade científica.

No Posfácio, como adiantamos acima, Kuhn privilegia a noção de matriz disciplina. Além de conter os aspectos teóricos e conceituais do paradigma, a matriz disciplinar também inclui vocabulário especializado (generalizações simbólicas); todos esses elementos guiam a pesquisa em uma disciplina científica. A matriz disciplinar representa o conjunto de práticas, convenções e conhecimentos específicos que definem uma determinada disciplina científica em um dado momento. Ela inclui não apenas as teorias e modelos científicos aceitos, mas também as ferramentas e abordagens práticas que os cientistas utilizam para realizar pesquisas e investigações.

“Para os nossos propósitos atuais, sugiro “matriz disciplinar”: “disciplinar” porque se refere a uma posse comum aos praticantes de uma disciplina particular; “matriz” porque é composta de elementos ordenados de várias espécies, cada um deles exigindo uma determinação mais pormenorizada” (KUHN, 2013, p.228-229)

Enquanto o paradigma está mais relacionado às estruturas conceituais e teóricas que orientam a pesquisa científica, a matriz disciplinar abrange um escopo mais amplo, incluindo aspectos práticos, instrumentais e metodológicos. A matriz disciplinar pode influenciar as técnicas experimentais, os métodos de coleta de dados, as formas de análise e até mesmo as convenções de comunicação científica dentro de uma disciplina específica. Apesar de ter abandonado o termo paradigma ele ainda pode ser utilizado com os sentidos de “modelo” ou “exemplares”.

Na obra de Thomas Kuhn, a técnica é um elemento intrínseco tanto ao paradigma quanto à matriz disciplinar. No paradigma, a técnica é vista como uma parte integrante, ajudando a moldar as normas e convenções que orientam a pesquisa científica. Ela fornece os métodos e procedimentos que os cientistas usam para investigar fenômenos e validar teorias.

Na matriz disciplinar, a técnica também desempenha um papel crucial. A técnica, neste contexto, ajuda a estabelecer os critérios para o que é considerado um trabalho científico válido e relevante para se trabalhar em um contexto de disciplinas. Portanto, a técnica é um elemento fundamental na estrutura da ciência, conforme concebida por Kuhn.

III- A importância da técnica na criação de modelos

Quando falamos em técnica, podemos pensar em vários sentidos. Kuhn, como vimos anteriormente, já disse que o paradigma era também uma técnica. Agora, esse sentido é usado como um elemento dentro de um paradigma, e é usado como podendo ser ferramentas que junto ao empenho em criar soluções com os equipamentos que estão dispostos no seu tempo faz com que exista um progresso na ciência e na criação de modelos. A técnica, nesse contexto, é fundamental para a construção de modelos científicos.

Na literatura, temos explicações acerca do conceito do termo técnica além da relação com o termo tecnologia. Feenberg (2003), por exemplo, ressalta a importância que os gregos tiveram com a criação e uso do termo. A palavra “técnica” tem origem no grego “technikós”, que se refere àquele que cria ou desenvolve, associado a “téchnē”, interpretado como arte ou habilidade no contexto criativo. A palavra “tecnologia” também tem suas raízes no grego, combinando “téchnē” com “logos”, que pode ser interpretado como estudo ou argumento

É mencionado que os gregos antigos faziam uma distinção entre “physis” (natureza) e “poiêsis” (a atividade prática de fazer). A “techne” era vista como o conhecimento ou a

disciplina associada a uma forma de “poiêsis”. Cada “techne” incluía um propósito e um significado para os artefatos cuja produção ela orientava (FEENBERG, 2003, p. 2).

Embora os artefatos dependam da atividade humana, o conhecimento contido nas “technai” não é matéria de opinião ou intenção subjetiva. Até mesmo parte dos propósitos dos instrumentos compartilham dessa objetividade, na medida que estão definidas pelas “technai”. As palavras modernas “técnica” e “tecnologia”, nas línguas ocidentais, têm suas raízes na palavra grega “techne”, embora tenham um significado um pouco diferente.

Como vimos, a ciência, em sua essência, é um empreendimento que prospera na resolução de problemas dentro de um paradigma estabelecido, segundo Thomas Kuhn. E o progresso, daí resultante, é frequentemente visto como uma característica intrínseca da atividade científica, levando à questão: um campo de estudos progride porque é uma ciência ou é uma ciência porque progride? (KUHN, 2013, p.247-248)

A tecnologia desempenha um papel crucial neste processo. Ela serve como alicerce entre o progresso e o aperfeiçoamento de técnicas, facilitando as melhorias nas condições para a produção de ciência. A tecnologia, assim como a ciência, é marcada pelo progresso contínuo, o que pode às vezes obscurecer as diferenças fundamentais entre os dois campos.

No entanto, é importante lembrar que a ciência não opera no vácuo. Ela é conduzida dentro de comunidades científicas maduras que geralmente trabalham a partir de um único paradigma ou conjunto de paradigmas estreitamente relacionados. Este paradigma orienta a pesquisa e define os problemas que são considerados significativos. (KUHN, 2013, p.247-248)

Portanto, a ciência e a tecnologia estão intrinsecamente ligadas, com a tecnologia fornecendo as ferramentas e técnicas que permitem à ciência avançar. Este progresso, por sua vez, alimenta novos desenvolvimentos tecnológicos, criando um ciclo de inovação e descoberta. É este ciclo que tem permitido a ciência e a tecnologia transformar o mundo em que vivemos.

Nesse sentido, a ciência e a tecnologia estão intrinsecamente ligadas, com a tecnologia fornecendo as ferramentas e técnicas que permitem à ciência avançar. Este progresso, por sua vez, alimenta novos desenvolvimentos tecnológicos, criando um ciclo de inovação e descoberta. É este ciclo que tem permitido a ciência e a tecnologia transformar o mundo em que vivemos.

A técnica, para Thomas Kuhn, é um dos componentes essenciais do paradigma científico, que orienta a pesquisa normal dos cientistas dentro de uma determinada área. A técnica envolve tanto os métodos experimentais, quanto os conceituais que permitem aos cientistas observar, medir, manipular e interpretar os fenômenos naturais. Esses métodos e técnicas são desenvolvidos e aprimorados ao longo do tempo, por meio da colaboração entre os cientistas e da acumulação de conhecimento científico. Além disso, a técnica também desempenha um papel fundamental na comunicação e na replicação dos resultados científicos, permitindo que outros pesquisadores reproduzam os experimentos e verifiquem a validade das descobertas.

Kuhn expressa a ideia de que a ciência avança por meio de paradigmas que orientam a escolha dos problemas e dos métodos de investigação. A pesquisa normal é aquela que segue o paradigma dominante em uma determinada época e área do conhecimento. A pesquisa normal não visa a revolucionar a ciência, mas a consolidar o conhecimento acumulado. Por isso, ela depende da seleção de fenômenos que sejam compatíveis com as técnicas conceituais e instrumentais já existentes, evitando aqueles que possam colocar em xeque o paradigma vigente. A técnica, nesse sentido, é um elemento fundamental para a continuidade e a estabilidade da pesquisa normal, pois ela permite a aplicação e a verificação das teorias científicas.

“A pesquisa normal, que é cumulativa, deve seu sucesso à habilidade dos cientistas para selecionar regularmente fenômenos que podem ser solucionados através de técnicas conceituais e instrumentais semelhantes às já existentes. (É por isso que uma preocupação excessiva com problemas úteis, sem levar em consideração sua relação com os conhecimentos e as técnicas existentes, pode facilmente inibir o desenvolvimento científico.)” (KUHN, 2013, p.166)

Nesse contexto, para ser considerado um cientista, um integrante da comunidade científica deve levar em consideração seus empenhos em refinar suas técnicas de observação e de atividades práticas, assim como articulação de suas teorias (KUHN, 2013, p.95-96). Esse é um contexto em que técnica é empregada tanto quanto experimental, quanto teórica. Além disso, é importante ressaltar que a busca pela excelência na prática científica requer uma constante atualização e aprimoramento das habilidades técnicas, tanto na realização de

experimentos quanto na formulação de hipóteses e teorias. Portanto, um cientista deve estar sempre empenhado em desenvolver suas habilidades práticas e teóricas para contribuir de forma significativa para o avanço do conhecimento.

A técnica também está relacionada com a formação e a educação dos cientistas, que devem dominar as habilidades e os instrumentos necessários para realizar sua atividade; ela é um fator crucial na criação de modelos científicos, que são representações simplificadas e idealizadas da realidade, baseadas em hipóteses, leis e teorias. Ou seja, o desenvolvimento da ciência está intimamente ligado com o desenvolvimento das técnicas esotéricas, seja técnicas teóricas ou experimentais. (KUHN, 2013, p.123). Essas técnicas esotéricas são fundamentais para a obtenção de resultados confiáveis e replicáveis, permitindo que os cientistas testem suas hipóteses e validem suas teorias. Além disso, o avanço tecnológico tem possibilitado o desenvolvimento de novas técnicas cada vez mais precisas e sofisticadas, ampliando as possibilidades de investigação científica.

Kuhn critica a visão tradicional de que a ciência é um acúmulo linear e cumulativo de conhecimentos, baseado em observações e experimentos objetivos. Ele defende que a ciência é uma atividade social, histórica e dinâmica que envolve mudanças de perspectiva e de critérios de avaliação. Os paradigmas são as concepções compartilhadas pelos cientistas de uma determinada época, que orientam suas pesquisas e definem seus problemas. Os manuais de história da ciência, que apresentem a ciência como um conjunto de fatos e leis estabelecidos, ignoram as controvérsias, as revoluções e as transformações que ocorrem na prática científica. Assim, eles transmitem uma imagem distorcida e simplificada da ciência que não reflete sua complexidade e sua evolução.

A ciência é um campo em constante evolução, onde as perspectivas e critérios de avaliação estão sempre mudando. Os paradigmas – ou modelos – são fundamentais nesse processo, pois são as concepções compartilhadas pelos cientistas de uma determinada época, que guiam suas pesquisas e definem os problemas a serem investigados. No entanto, esses manuais muitas vezes apresentam a ciência como um conjunto de fatos, por vezes ignorando o papel histórico, e todo o progresso é reduzido a acumulação de conhecimento transformados em um conjunto de regras.

Essa visão implica que a ciência é uma construção humana e histórica, que depende dos contextos sociais, culturais e políticos em que se desenvolve. Implica também que a ciência não é um reflexo fiel da realidade, mas sim uma interpretação possível, que pode ser

questionada e substituída por outras visões e modelos de ciência. Implica ainda que a ciência não é um progresso contínuo e linear, mas sim um processo descontínuo e conflituoso, que envolve rupturas e crises entre paradigmas incompatíveis.

Kuhn destaca que a técnica sofre mudanças significativas durante as revoluções científicas, que são períodos de crise e conflito entre paradigmas rivais. Nesses momentos, os cientistas devem questionar e revisar as técnicas vigentes que se mostram inadequadas ou insuficientes para resolver os problemas ou as anomalias que surgem na ciência. Assim, novas técnicas são desenvolvidas ou adaptadas para explorar novos domínios da natureza, testar novas hipóteses ou construir novos modelos. Essas mudanças técnicas são fundamentais para impulsionar o progresso científico, permitindo avanços e descobertas que não seriam possíveis com as técnicas anteriores. Além disso, as revoluções científicas também têm um impacto significativo na forma como a ciência é conduzida, levando a uma reavaliação dos métodos e práticas utilizados pelos cientistas.

Atualmente, os buracos negros estão sendo confirmados através de diferentes métodos e técnicas científicas. Essas confirmações têm sido possíveis graças aos avanços tecnológicos e às novas abordagens experimentais. Ou seja, as técnicas usadas durante períodos pós-paradigmáticos, podem ser o efeito de possível ocorrência de revoluções científicas. (KUHN, 2013, p.53). Isso explica a importância do registro de feitos nos aprimoramentos de técnicas na história da ciência. Cada revolução científica traz consigo uma mudança de perspectiva que afeta a estrutura das publicações de pesquisa e dos manuais do período pós-revolucionário. Isso é evidenciado pela alteração na distribuição da literatura técnica citada nas notas de rodapé dos relatórios de pesquisa (KUHN, 2013, p.53).

Essa mudança é crucial porque reflete a evolução do pensamento e do conhecimento científico. Os manuais são atualizados para incorporar novas descobertas e teorias, o que por sua vez influencia a direção futura da pesquisa científica. Portanto, o registro de feitos históricos científicos não é apenas uma questão de manter um registro do passado, mas também uma ferramenta para moldar o futuro da ciência. A análise dessas mudanças pode servir como um índice possível da ocorrência de revoluções, ajudando a entender melhor a dinâmica da ciência e seu progresso.

Um exemplo histórico de mudança de técnica é a introdução da luneta na astronomia, que permitiu a observação de novos fenômenos celestes e a corroboração do modelo heliocêntrico de Copérnico por Galileu. Essa mudança de técnica revolucionou a forma como

os astrônomos estudavam o universo, pois o telescópio possibilitou a visualização de corpos celestes que não eram visíveis a olho nu. Além disso, essa nova ferramenta permitiu uma maior precisão nas medições e observações, contribuindo para o avanço da ciência astronômica.

Portanto, pode-se afirmar que a técnica é um elemento fundamental na estrutura das revoluções científicas, segundo Kuhn. A técnica não só define o modo como os cientistas realizam sua pesquisa normal dentro de um paradigma estabelecido, mas também possibilita a emergência e a consolidação de novos paradigmas, através da criação de novos modelos científicos. Esses novos modelos científicos surgem quando os cientistas desenvolvem técnicas inovadoras que permitem a observação e a compreensão de fenômenos antes desconhecidos. Além disso, as técnicas também desempenham um papel crucial na aceitação e na difusão dos novos paradigmas, uma vez que possibilitam a replicação e a validação dos resultados obtidos.

IV- Explicação da inteligência artificial e suas aplicações

A inteligência artificial (IA) é um campo da ciência da computação que visa criar sistemas capazes de realizar tarefas que normalmente exigem inteligência humana, como raciocínio, aprendizagem, percepção e criatividade. A ideia de simular a inteligência em máquinas remonta aos primórdios da história da computação, mas foi formalizada pela primeira vez no projeto de pesquisa de verão da Universidade de Dartmouth em 1955, proposto por John McCarthy, Marvin Minsky, Nathaniel Rochester e Claude Shannon (McCarthy, Minsky, Rochester, & Shannon, 2006).

Nesse projeto, os autores definiram a IA como a capacidade de uma máquina imitar ou reproduzir a inteligência humana em suas diversas formas. Desde então, a IA tem evoluído rapidamente, impulsionada por avanços tecnológicos e pela disponibilidade de grandes quantidades de dados. Atualmente, a IA é aplicada em diversos campos, como medicina, finanças, e nas ciências, e continua a se desenvolver com novas técnicas e algoritmos.

A proposta desenvolvida em Dartmouth abriu caminho para o desenvolvimento de diversas áreas da IA introduzindo ideias que levariam às técnicas hoje conhecidas como o processamento de linguagem natural (PLN), que busca compreender e gerar linguagem humana, e as redes neurais artificiais (RNA), que são modelos computacionais inspirados no funcionamento do cérebro humano. Essas áreas têm aplicações práticas em diversos

domínios, como tradução automática, reconhecimento de voz, reconhecimento de imagens, jogos e robótica. Além disso, a IA tem potencial para automatizar o trabalho humano em vários setores, aumentando a produtividade, a eficiência e a qualidade dos serviços.

No entanto, a IA também enfrenta desafios teóricos e práticos que limitam o seu avanço. Um deles é o problema da complexidade computacional, que estuda os recursos necessários para resolver um problema em termos de tempo e espaço. Alguns problemas são intratáveis, ou seja, não podem ser resolvidos em tempo razoável por nenhum algoritmo conhecido.

Outro desafio é o problema de a inteligência artificial ter a possibilidade de aperfeiçoar a si mesma, consistindo em máquinas capazes de melhorar o seu próprio desempenho sem intervenção humana¹.

Para fins de definição da inteligência artificial existe um teste que é o de Turing que é utilizado para avaliar a capacidade de uma máquina em imitar o comportamento humano de forma indistinguível (RUSSELL, 2021, p 2). A importância desse teste consiste em estabelecer se uma máquina possui inteligência artificial, sendo capaz de replicar e executar ações humanas. Além disso, o teste de Turing também ajuda a identificar os limites e os riscos da IA, especialmente no que diz respeito ao autoaperfeiçoamento das máquinas. Portanto, o teste de Turing desempenha um papel fundamental na compreensão e no desenvolvimento da inteligência artificial.

“O teste de Turing, proposto por Alan Turing (1950), foi concebido como um experimento de pensamento que iria esquivar a vaguidade filosófica da pergunta “Uma máquina pode pensar?”. Um computador passa o teste se um interrogador humano, depois de fazer algumas perguntas escritas, não conseguir dizer se as respostas escritas vêm de uma pessoa ou de um computador. [...].

O computador precisaria das seguintes capacidades:

- **processamento de linguagem natural** para se comunicar com sucesso em uma língua humana;

¹Mais tarde seria introduzida na inteligência artificial teórica o termo AGI (Artificial General Intelligence) que pode entender, aprender e aplicar conhecimento, raciocinar e resolver problemas, perceber o ambiente, planejar e se comunicar em linguagem natural. Ela pode realizar qualquer tarefa intelectual que um ser humano possa. A AGI também é conhecida como “IA forte” porque possui a gama completa de habilidades cognitivas humanas. Isso significa que ela pode superar os humanos na maioria dos trabalhos economicamente valiosos. IBM Technology. (2023) The 7 Types of AI - And Why We Talk (Mostly) About 3 of Them [Vídeo]. Youtube. [https://www.youtube.com/watch?v=XFZ-rQ8eeR8&t=4s&ab_channel=IBMTechology]

- **representação do conhecimento** para armazenar o que sabe ou ouve;
- **raciocínio automatizado** para responder a perguntas e tirar novas conclusões;
- **aprendizagem automática** para se adaptar a novas circunstâncias e detectar e extrapolar padrões.

Turing viu a simulação física de uma pessoa como desnecessária para demonstrar inteligência. No entanto, outros pesquisadores propuseram um teste total de Turing, que requer interação com objetos e pessoas no mundo real.

Para passar no teste total de Turing, um robô precisará de:

- **visão computacional** e reconhecimento de fala para perceber o mundo;
- **robótica** para manipular objetos e se mover.” (Russell, S. J., & Norvig, P. (2021), p 2. tradução minha)

A Inteligência Artificial (IA) é um campo vasto e em constante evolução, com diversas subáreas. Aqui estão alguns dos principais tipos de IA conforme discutido em *Os 3 Tipos de Inteligência Artificial*, (BALDISSERA, 2023):

- **Inteligência Artificial Limitada (ANI):** Esta é a forma mais comum de IA que vemos hoje. Ela é projetada para realizar uma tarefa específica, como recomendar músicas, reconhecer voz ou dirigir um carro. No entanto, essas máquinas operam sob um conjunto limitado de restrições e são focadas em tarefas muito específicas.
- **Inteligência Artificial Geral (AGI):** Este tipo de IA é capaz de entender, aprender e aplicar o conhecimento em uma ampla variedade de tarefas, ao nível de um ser humano. No entanto, a AGI ainda está em fase de pesquisa e desenvolvimento.
- **Superinteligência Artificial (ASI):** Este é um tipo de IA teórica que não apenas replica a inteligência humana, mas também a supera em todos os aspectos relevantes, desde a criatividade até a resolução de problemas. A ASI ainda é um conceito teórico e está muito além do nosso alcance atual.

As aplicações da IA são diversas e abrangem diferentes áreas, como produção, gestão, saúde e transporte. Elas envolvem tecnologias que simulam habilidades humanas, como percepção, raciocínio, análise e ação. Elas podem monitorar, corrigir, diagnosticar, identificar, prever e sugerir soluções para problemas e processos.

Dentro da Inteligência Artificial, existem várias áreas de estudo e aplicação, incluindo:

Processamento de Linguagem Natural (PLN): É um recurso que possibilita que computadores compreendam e interpretem a linguagem humana. Assim, a proposta é que as máquinas possam lidar com textos escritos por interlocutores humanos, a partir da análise de contexto e da identificação de diferentes linguagens.

Aprendizado de máquina: É um campo da inteligência artificial que visa explorar estudos e construções de algoritmos que possibilitam compreender de maneira autônoma. É possível ser capaz com o Machine Learning de reconhecer e extrair padrões de um grande volume de dados, construindo dessa maneira um modelo de aprendizado.

Aprendizado profundo: É uma subárea da inteligência artificial que utiliza redes neurais para aprender a partir de dados brutos e realizar tarefas complexas. Neste campo, as redes são compostas por várias camadas, permitindo que o algoritmo aprenda representações de alto nível dos dados à medida que passa por elas.

Visão Computacional: É uma área da inteligência artificial que permite que máquinas reconheçam e interpretem imagens e vídeos. Algumas aplicações atuais da visão computacional são: segurança, serviços públicos, marketing, indústria, saúde, agricultura, entre outros.

Robótica: É um ramo da engenharia que envolve a concepção, projeto, fabricação e operação de robôs. O objetivo da robótica é criar máquinas inteligentes que possam auxiliar o ser humano de diversas maneiras em vários setores.

Vamos nos deter em uma subárea específica da IA: o aprendizado de máquina. O aprendizado de máquina é um campo da inteligência artificial que visa explorar estudos e construções de algoritmos que possibilitam compreender de maneira autônoma. É possível ser capaz com o aprendizado de máquina de reconhecer e extrair padrões de um grande volume de dados, construindo dessa maneira um modelo de aprendizado.

Analisamos o seguinte trecho: “Nós chamamos isso de aprendizado de máquina: um computador observa alguns dados, constrói um modelo baseado nos dados e usa o modelo como uma hipótese sobre o mundo e um pedaço de software que pode resolver problemas” (RUSSELL; NORVIG, 2021, p. 1201, tradução minha).

Ele é um método de análise de dados que automatiza a construção de modelos analíticos. É um ramo da inteligência artificial baseado na ideia de que sistemas podem aprender com dados, identificar padrões e tomar decisões com o mínimo de intervenção humana. No contexto deste trabalho, examinaremos exclusivamente nas técnicas de aprendizado de máquina. Essa abordagem permitirá uma discussão mais aprofundada e detalhada dessas técnicas específicas.

É crucial estabelecer uma distinção precisa entre termos e conceitos que, por vezes, podem ser confundidos ou considerados intercambiáveis. O aprendizado de máquina, por exemplo, é um subconjunto da inteligência artificial. Este campo se concentra na utilização de métodos e modelos de autoaprendizado com o objetivo de transformar dados brutos em conhecimento útil. Este conhecimento, por sua vez, é empregado para realizar previsões bem precisas. Portanto, embora o aprendizado de máquina esteja intrinsecamente ligado à inteligência artificial, ele possui características e objetivos específicos que o distinguem dentro do amplo espectro da IA.

Uma das principais características do aprendizado de máquina é a capacidade de analisar grandes quantidades de dados e identificar padrões e tendências, permitindo que os algoritmos se ajustem e melhorem suas previsões ao longo do tempo. Além disso, o aprendizado de máquina também pode ser aplicado em diversas áreas, como medicina, biologia, física e química, para auxiliar na análise de dados complexos e na tomada de decisões. Na medicina, por exemplo, o uso de aprendizado de máquina pode ajudar a identificar padrões em exames médicos e históricos do paciente, auxiliando no diagnóstico de doenças e na escolha do tratamento mais adequado (PAIXÃO et al, 2023). Na biologia, pode ser utilizado para analisar sequências genéticas e identificar genes relacionados a determinadas características ou doenças (PASSARINI, 2020). Já na física e química, o aprendizado de máquina pode ser aplicado para otimizar processos de produção e descobrir novos materiais com propriedades específicas (SCHLEDER e FAZZIO, 2023). Além disso, em áreas como a astronomia, o aprendizado de máquina pode ser usado para analisar grandes volumes de dados e identificar padrões que levem a descobertas importantes sobre o universo (SODRÉ, 2021).

O aprendizado de máquina é uma disciplina que se baseia em algoritmos e técnicas para treinar máquinas a aprender a partir de dados e melhorar seu desempenho ao longo do tempo. Essa abordagem é frequentemente utilizada em tarefas como reconhecimento de

padrões, processamento de linguagem natural e recomendações personalizadas. Além disso, o aprendizado de máquina também pode ser dividido em duas categorias principais: aprendizado supervisionado e aprendizado não supervisionado. Enquanto o primeiro envolve o uso de dados rotulados para treinar um modelo, o segundo se baseia em encontrar padrões e estruturas ocultas nos dados sem a necessidade de rótulos.

O aprendizado supervisionado é comumente usado quando se deseja prever ou classificar dados com base em exemplos pré-existentes, enquanto o aprendizado não supervisionado é útil para descobrir insights e agrupar dados de forma automática. Ambas as abordagens têm suas vantagens e desvantagens, e a escolha entre elas depende do problema em questão e dos recursos. Esse aprendizado tem a vantagem de poder prever ou classificar dados com base em exemplos existentes. Isso o torna particularmente útil quando há um objetivo claro, como prever a rotatividade de clientes ou classificar e-mails de spam. No entanto, o aprendizado depende fortemente de dados rotulados, que podem ser caros e demorados para obter.

O aprendizado não supervisionado, por outro lado, não requer dados rotulados e pode descobrir automaticamente padrões ocultos nos dados. Isso o torna útil para tarefas como agrupamento ou detecção de anomalias. No entanto, o aprendizado não supervisionado pode ser mais desafiador para interpretar e avaliar, pois não há um objetivo claro ou verdade fundamental para comparar os resultados. A escolha entre aprendizado supervisionado e não supervisionado depende do problema específico e dos recursos disponíveis.

O aprendizado de máquina desempenha um papel crucial na resolução de problemas complexos e de grande escala que seriam impraticáveis ou impossíveis de resolver manualmente. Com a capacidade de analisar grandes volumes de dados e identificar padrões que podem não ser aparentes para analistas humanos, os algoritmos de aprendizado de máquina podem descobrir insights e fazer previsões precisas. Isso é especialmente valioso em campos como a modelagem climática, onde grandes volumes de dados precisam ser processados para entender e prever padrões climáticos complexos. Além disso, o aprendizado de máquina pode ser usado em cibersegurança para detectar e prevenir ataques cibernéticos, analisando grandes volumes de dados de rede em busca de padrões suspeitos. Ao aproveitar o poder do aprendizado de máquina, pesquisadores e profissionais podem enfrentar desafios que antes eram intransponíveis.

V- Os desafios que compõe a tecnologia para a criação de modelos de IA

A IA é um campo fascinante e promissor que busca entender e reproduzir a inteligência em máquinas. Desde a sua origem no projeto de Dartmouth, em 1955, a IA evoluiu e se ramificou em diversas áreas que têm impacto na sociedade e nas ciências. No entanto, a IA também enfrenta desafios que exigem entendimento das suas técnicas, assim como novas abordagens teóricas e práticas, bem como uma reflexão crítica sobre as suas implicações.

A criação de modelos de Inteligência Artificial (IA) é uma tarefa complexa e desafiadora que requer uma compreensão profunda de várias disciplinas, incluindo ciência da computação, matemática, estatística e teoria da informação. Além disso, a criação de modelos de IA eficazes também exige uma compreensão dos desafios e limitações associados à tecnologia.

Um dos principais desafios na criação de modelos de IA é a necessidade de grandes volumes de dados de alta qualidade. Esses dados são essenciais para treinar os modelos de IA e garantir que eles sejam capazes de tomar decisões precisas e confiáveis. Além disso, a qualidade dos dados também é crucial, pois informações imprecisas ou incompletas podem levar a resultados incorretos ou viés nos modelos de IA. Portanto, a coleta e o processamento adequados dos dados são etapas fundamentais na criação de modelos de IA eficientes.

Os modelos de aprendizado de máquina, em particular, dependem fortemente de dados rotulados para treinamento. No entanto, a coleta e o rotulamento de dados podem ser caros e demorados, e nem sempre é possível obter dados representativos para todas as situações que o modelo pode encontrar. Além disso, a privacidade dos dados também é uma preocupação importante ao lidar com grandes volumes de informações. É necessário garantir que as informações coletadas sejam tratadas de forma ética e em conformidade com as regulamentações de proteção de dados.

Conforme discutido em *Inteligência Artificial e Aprendizado de Máquina: estado atual e tendências* (LUDERMIR, 2023), a complexidade computacional associada ao treinamento de modelos de IA é um desafio significativo. À medida que os modelos se tornam mais complexos e os conjuntos de dados se tornam maiores, o tempo e os recursos computacionais necessários para treinar os modelos aumentam exponencialmente. Isso pode ser um obstáculo significativo, especialmente para organizações com recursos limitados. A

falta de interpretabilidade também é um problema dos modelos de IA que pode levar à desconfiança por parte dos usuários e à dificuldade em compreender e corrigir possíveis erros ou vieses. Portanto, é fundamental desenvolver métodos e técnicas que permitam a compreensão e explicação das decisões tomadas pelos modelos de IA garantindo assim maior confiabilidade e aceitação dessas tecnologias em áreas críticas.

Como mencionado em *A Inteligência Artificial no Contexto da Ciência da Informação* (SILVA, 2023), dados imprecisos ou incompletos podem levar a modelos de IA tendenciosos ou incorretos. A qualidade dos dados é um aspecto crucial na construção de modelos de Inteligência Artificial (IA). Por exemplo, se um conjunto de dados de treinamento para um modelo de IA é tendencioso ou não representa adequadamente a população que o modelo pretende servir, o modelo pode produzir resultados tendenciosos ou imprecisos (ATAMAN, 2023). Um exemplo disso pode ser visto em sistemas de reconhecimento facial. Se o conjunto de dados de treinamento é composto principalmente por imagens de indivíduos de um determinado grupo demográfico, o sistema pode não funcionar tão bem para indivíduos de outros grupos demográficos. Isso pode levar a erros de identificação e outros problemas.

De acordo com *Inteligência Artificial e sociedade: avanços e riscos* (SICHMAN, 2023), a interpretabilidade e a transparência são aspectos cruciais dos modelos de IA. Portanto, a falta de interpretabilidade e transparência dos modelos de IA tem sido uma questão importante. Isso pode ser problemático em muitos contextos, especialmente em áreas como medicina e direito, onde a tomada de decisões precisa ser justificada. Por exemplo, um modelo de IA pode ser usado para ajudar os médicos a diagnosticarem doenças com base em imagens médicas. No entanto, se o modelo não for capaz de explicar como chegou ao seu diagnóstico, os médicos podem hesitar em confiar em suas previsões. Da mesma forma, se um modelo de IA é usado para tomar decisões que afetam a vida das pessoas, como decidir quem recebe um empréstimo ou como os recursos são alocados, a falta de transparência pode levar a questões de justiça e responsabilidade. Portanto, é crucial que os modelos de IA sejam não apenas precisos, mas também transparentes e interpretáveis. Isso não apenas melhorará a precisão e a justiça das previsões do modelo, mas também aumentará a confiança e a aceitação dos modelos de IA.

Mas, apesar desses desafios, temos visto avanços significativos na criação de modelos de IA graças ao rápido crescimento das tecnologias de computação. Por exemplo, o

crescimento exponencial na capacidade de memória e no número de transistores em chips de computador, conforme previsto pela Lei de Moore, permitiu o desenvolvimento de algoritmos de aprendizado de máquina mais sofisticados e poderosos. A Lei de Moore (MOORE, 1965), proposta por Gordon E. Moore, cofundador da Intel, é uma previsão fundamental que tem orientado o desenvolvimento da tecnologia de semicondutores por mais de cinco décadas. Segundo essa lei, a densidade de transistores em um chip de computador dobraria aproximadamente a cada dois anos. Esta previsão tem se mantido notavelmente precisa, apesar dos desafios crescentes associados à miniaturização dos componentes do chip.

No entanto, é importante notar que a Lei de Moore não é uma lei física, mas sim uma observação empírica e uma meta de fabricação. À medida que a indústria de semicondutores se aproxima dos limites físicos da miniaturização, a manutenção do ritmo previsto pela Lei de Moore torna-se cada vez mais desafiadora. A Lei de Moore tem implicações significativas para muitos aspectos da tecnologia da informação, incluindo o desempenho do processador, a capacidade de memória e até mesmo a eficiência energética dos computadores. Entretanto, à medida que nos aproximamos dos limites físicos da Lei de Moore, é provável que novas abordagens e tecnologias sejam necessárias para continuar a avançar a capacidade de processamento dos computadores.

Para resumir, a Lei de Moore tem sido uma força motriz por trás do rápido avanço da tecnologia de semicondutores, mas enfrenta desafios significativos à medida que a indústria se aproxima dos limites físicos da miniaturização. A superação desses desafios provavelmente exigirá inovações significativas em design de chips, fabricação de semicondutores e arquitetura de computadores. Além do mais, o advento de tecnologias como a computação em nuvem e o hardware de processamento gráfico (GPU) tornou possível treinar modelos de IA em escalas anteriormente inimagináveis.

Por fim, a criação de modelos de IA é uma tarefa complexa e desafiadora que requer uma compreensão profunda de várias disciplinas e uma apreciação dos desafios e limitações associados à tecnologia. No entanto, graças ao rápido crescimento das tecnologias de computação, estamos cada vez mais capazes de superar esses desafios e criar modelos de IA cada vez mais poderosos e eficazes.

VI- O Futuro da Ciência: Uma Exploração do Quarto Paradigma e da e-Science

VI.1- Os desafios em decorrência da imensa quantidade de dados

Vivemos em uma era de crescimento exponencial de dados. A cada dia, bilhões de dispositivos digitais geram uma quantidade imensa de dados, desde mensagens de texto e postagens em redes sociais até registros médicos e transações financeiras. Essa explosão de dados, muitas vezes referida como “Big Data”, apresenta oportunidades e desafios sem precedentes. Essas oportunidades incluem a possibilidade de descobertas científicas revolucionárias e avanços tecnológicos significativos. Por outro lado, também enfrentamos o desafio de como lidar com essa quantidade massiva de dados e extrair informações úteis dele.

A oportunidade reside na riqueza de informações que esses dados podem fornecer. Se devidamente analisados, eles podem revelar padrões e tendências que podem informar tudo, desde decisões de negócios até avanços científicos. Mas, a quantidade maciça de dados também apresenta um desafio significativo: como podemos gerenciar, analisar e utilizar efetivamente esses dados? Aqui reside a urgência das técnicas e tecnologias de gerenciamento de dados. À medida que a quantidade de dados continua a crescer, também deve crescer nossa capacidade de gerenciar e utilizar esses dados de maneira eficaz. Isso envolve não apenas o armazenamento de dados, mas também a garantia de que eles sejam facilmente acessíveis e utilizáveis.

Técnicas como a mineração de dados, que busca encontrar padrões e informações valiosas em grandes conjuntos de dados, são cada vez mais importantes. Da mesma forma, tecnologias como bancos de dados em nuvem e inteligência artificial desempenham um papel crucial na gestão e análise de dados. No entanto, o uso correto de dados vai além da mera gestão e análise. Isso inclui proteger a privacidade dos indivíduos e garantir que os dados não sejam usados para fins prejudiciais. Em suma, à medida que entramos nesta nova era de Big Data, é imperativo que desenvolvamos e implementemos técnicas e tecnologias eficazes de gerenciamento de dados. Ao fazer isso, podemos aproveitar o poder dos dados para impulsionar o progresso e a inovação, ao mesmo tempo em que garantimos que esses dados sejam usados de maneira responsável e ética.

A ciência lida com a grande quantidade de dados de várias maneiras. Uma delas é através do uso de técnicas de mineração de dados e aprendizado de máquina. Essas técnicas permitem que os cientistas analisem grandes conjuntos de dados para identificar padrões e tendências. Por exemplo, um cientista pode usar essas técnicas para analisar dados de sequenciamento genético para identificar genes associados a uma determinada doença. Outra

maneira pela qual a ciência lida com grandes quantidades de dados é através do uso de infraestruturas de dados robustas. Isso inclui o uso de bancos de dados em nuvem e outras tecnologias que permitem o armazenamento, gerenciamento e recuperação eficientes de grandes volumes de dados.

Além disso, a ciência também está se voltando para abordagens colaborativas e interdisciplinares para lidar com grandes volumes de dados. Isso é evidente no movimento em direção à ciência aberta², onde os dados são compartilhados abertamente e podem ser acessados e utilizados por pesquisadores de diferentes campos. Isso não apenas permite uma análise mais ampla dos dados, mas também promove a colaboração e a inovação.

Parte dos cientistas está preocupada com a questão da ética dos dados. Isso inclui garantir que os dados sejam coletados e usados de maneira responsável, protegendo a privacidade dos indivíduos e garantindo que os dados sejam usados para o bem. A ciência está abordando o desafio dos grandes volumes de dados através de uma combinação de técnicas de análise de dados, infraestruturas de dados robustas, colaboração e considerações éticas. O artigo *Trustworthy AI: A Computational Perspective* (LIU et al, 2021) destaca a importância da IA confiável, concentrando-se em seis dimensões cruciais: Segurança & Robustez, Não-discriminação & Justiça, Explicabilidade, Privacidade, Responsabilidade & Auditabilidade e Bem-estar Ambiental. Este trabalho é um recurso valioso que orienta o desenvolvimento e a implementação responsável, justa e transparente da IA, promovendo a confiança do público na tecnologia e garantindo benefícios significativos para a sociedade. Cada um desses elementos desempenha um papel crucial em permitir que a ciência não apenas gerencie grandes volumes de dados, mas também os utilize de maneira eficaz e responsável.

-
- ² Ciência Aberta é um movimento mundial que visa tornar o conhecimento científico aberto e compartilhado para a comunidade científica de diferentes países e para toda a sociedade. A maior acessibilidade ao conhecimento científico proporciona mais cooperação, reutilização de dados e maior inclusão de todas as partes interessadas, promovendo um avanço mais rápido do conhecimento científico e um maior retorno de benefícios para a sociedade. A UNESCO define a Ciência Aberta como uma construção inclusiva que combina vários movimentos e práticas com o objetivo de tornar o conhecimento científico multilíngue disponível abertamente, acessível e reutilizável para todos, para aumentar as colaborações científicas e o compartilhamento de informações para o benefício da ciência e da sociedade, e para abrir os processos de criação de conhecimento científico, avaliação e comunicação aos atores sociais além da comunidade científica tradicional. (Ciência Aberta USP. (n.d.). O que é Ciência Aberta? Recuperado de <https://cienciaaberta.usp.br/sobre-o-projeto/>

A ciência enfrenta vários desafios em relação aos dados. O volume de dados, como já vimos, está crescendo exponencialmente, criando desafios significativos em termos de armazenamento e processamento. Nem todos os dados são de alta qualidade ou relevantes para uma determinada investigação, portanto, métodos para avaliar e garantir a qualidade dos dados são necessários. Além disso, a diversidade dos dados também é um desafio, pois eles podem ser estruturados ou não estruturados, provenientes de diferentes fontes e em diferentes formatos. Portanto, é fundamental desenvolver técnicas e ferramentas que possam lidar com essa variedade e integrar os dados de forma eficiente.

Os dados muitas vezes vêm de várias fontes e em vários formatos, tornando a integração desses dados um desafio significativo. Com o aumento da quantidade de dados, as preocupações com a privacidade e a segurança também aumentam. A ciência deve garantir que os dados sejam coletados, armazenados e usados de maneira ética e segura. Além disso, a análise e interpretação dos dados também são desafios importantes. É necessário desenvolver métodos e algoritmos avançados para extrair insights significativos e tomar decisões informadas com base nos dados disponíveis. A colaboração entre especialistas em ciência de dados, ética e segurança da informação é essencial para enfrentar esses desafios de forma eficaz. A simples existência de dados não é suficiente, portanto, métodos para interpretar e extrair significado desses dados são necessários. Embora o compartilhamento de dados possa levar a avanços científicos, também apresenta desafios, incluindo questões de propriedade, privacidade e garantia de que os dados sejam usados de maneira responsável.

A medida que os volumes de dados aumentam, os métodos e infraestruturas existentes podem não ser capazes de escalar de acordo, portanto, novas abordagens e tecnologias que possam lidar com esses volumes crescentes de dados são necessárias. Uma possível solução para lidar com esses desafios é a implementação de técnicas de análise de dados avançadas, como inteligência artificial e aprendizado de máquina, que podem ajudar a extrair insights valiosos desses grandes volumes de dados. Além disso, é importante estabelecer regulamentações e políticas claras para garantir a proteção da privacidade dos indivíduos e o uso ético dos dados. Esses desafios são complexos e interconectados, exigindo uma abordagem multifacetada e colaborativa para resolvê-los. Entretanto, ao enfrentar esses desafios, a ciência tem a oportunidade de impulsionar a inovação e o progresso. Ao adotar uma abordagem responsável, os cientistas podem garantir que os benefícios da análise de grandes volumes de dados sejam maximizados, ao mesmo tempo em que minimizam os

riscos potenciais. Além disso, é importante considerar questões éticas e de privacidade ao lidar com dados em larga escala.

VI.2- As novas formas de se fazer ciência: 4º paradigma e E-Science

“Foi o assistente de Tycho Brahe, Johannes Kepler, que pegou o catálogo de observações astronômicas sistemáticas de Brahe e descobriu as leis do movimento planetário. Isso estabeleceu a divisão entre a mineração e análise de dados experimentais capturados e cuidadosamente arquivados e a criação de teorias. Essa divisão é um aspecto do Quarto Paradigma.” (BELL, Gordon. Foreword. In: *The Fourth Paradigm: Data-Intensive Scientific Discovery*. Redmond: Microsoft Research, 2009. p. xi-xv)

O “Quarto Paradigma” é um termo usado para descrever a nova era da ciência que é impulsionada pelos dados. Na citação, a “divisão” refere-se à separação entre a coleta de dados (ou “mineração”) e a análise desses dados para criar teorias. Esse Paradigma tem como base a ideia que a ciência está passando por uma nova mudança de paradigma, além dos paradigmas experimentais, teóricos e computacionais, para um paradigma baseado na exploração e análise de grandes conjuntos de dados gerados por instrumentos, sensores e simulações.

A ciência intensiva em dados é uma mudança significativa na maneira como a ciência é conduzida. Tradicionalmente, a ciência computacional, que envolve o uso de simulações e modelagem computacional, tem sido um pilar da pesquisa científica. Mas, com o advento do *Big Data*, estamos vendo o surgimento de um novo paradigma: a ciência intensiva em dados. Este novo paradigma é tão diferente e único que o autor argumenta que ele deve ser considerado uma categoria própria, distinta da ciência computacional. Isso reflete o impacto transformador que o Big Data está tendo na ciência e na pesquisa.

“As técnicas e tecnologias para uma ciência tão intensiva em dados são tão diferentes que vale a pena distinguir a ciência intensiva em dados da ciência computacional como um novo, quarto paradigma para a exploração científica.” (Gray, J. (2007). Jim Gray on eScience: A Transformed Scientific Method.)

A urgência do gerenciamento e compreensão dos dados está forçando a comunidade científica a compartilhar esses dados. Isso permite que problemas sejam abordados de uma perspectiva interdisciplinar, o que pode levar a soluções mais eficazes e rápidas. Em outras

palavras, ao compartilhar dados, diferentes campos da ciência podem colaborar e contribuir com suas próprias perspectivas e habilidades únicas, potencialmente levando a avanços mais rápidos e eficazes. Isso é particularmente relevante no Quarto Paradigma, onde a ciência é cada vez mais impulsionada por dados. Nesse paradigma, a quantidade de dados gerados é enorme e crescente, tornando o compartilhamento de dados ainda mais crucial para avanços científicos significativos. Além disso, ao compartilhar dados, também é possível evitar a duplicação de esforços e maximizar o uso eficiente dos recursos disponíveis.

Já o termo "E-science"³ refere-se ao uso de tecnologias digitais para facilitar a colaboração e o compartilhamento de dados entre cientistas em todo o mundo. Isso permite que pesquisadores acessem conjuntos de dados maiores e mais diversos, aumentando as chances de descobertas inovadoras e acelerando o progresso científico. Além disso, a "E-Science" também promove a transparência e a reprodutibilidade dos resultados.

O quarto paradigma tem como base o pensamento de que a ciência está passando por uma nova mudança de paradigma, além dos paradigmas experimentais, teóricos e computacionais, para um paradigma baseado na exploração e análise de grandes conjuntos de dados gerados por instrumentos, sensores e simulações.

A ideia do "Quarto Paradigma" como um novo paradigma na ciência, pode ser vista sob a luz das revoluções científicas de Thomas Kuhn. Segundo Kuhn, uma revolução científica ocorre quando há uma mudança de um paradigma para outro. No entanto, a noção do "Quarto Paradigma" não parece implicar necessariamente uma rejeição dos paradigmas anteriores, mas sim uma evolução ou expansão deles.

O Quarto Paradigma representa uma nova maneira de conduzir a ciência, com foco na exploração e análise de grandes conjuntos de dados. Isso não significa necessariamente abandonar os métodos científicos antigos, mas sim aprimorar as técnicas existentes para lidar com a imensidão dos novos dados disponíveis. Portanto, o Quarto Paradigma pode ser visto como um aperfeiçoamento das técnicas científicas, permitindo resultados mais eficientes e uma maior capacidade de resolver problemas. Nesse sentido, o Quarto Paradigma pode ser visto como uma extensão dos paradigmas anteriores –ou métodos –, incorporando novas técnicas e tecnologias para extrair insights e conhecimento dos dados. Portanto, embora o

³ Hey, T., Tansley, S., & Tolle, K. (2009). *The Fourth Paradigm: Data-Intensive Scientific Discovery*. Microsoft Research.

termo “paradigma” possa sugerir uma ruptura com o passado, no caso do Quarto Paradigma, parece ser mais uma questão de construir sobre o que já existe e expandir as fronteiras do que é possível na ciência.

Esse novo paradigma, chamado de ciência intensiva em dados, apresenta desafios e oportunidades para a pesquisa científica. Entre os desafios estão a necessidade de ferramentas genéricas e eficientes para capturar, curar, armazenar e visualizar os dados, bem como a importância de preservar e compartilhar os dados e a literatura científica em bibliotecas digitais públicas e acessíveis.

Entre as oportunidades, estão os exemplos de projetos e iniciativas que estão avançando na ciência intensiva em dados, como o PubMed Central, o Project Neptune, o Sloan Digital Sky Survey, o Large Hadron Collider, entre outros. Esses projetos demonstram o potencial dos dados para impulsionar a descoberta científica em diversas áreas do conhecimento.

Um projeto que indica esse novo tipo de pesquisa é a *Open Science* que visa promover a transparência e a colaboração na pesquisa científica, disponibilizando dados, métodos e resultados de forma aberta e acessível. Através dessa abordagem, espera-se acelerar o progresso científico, permitindo que pesquisadores de diferentes áreas possam utilizar os dados disponíveis para realizar novas descobertas e avançar em suas próprias pesquisas.

A interdisciplinaridade, nesse contexto, indica um possível progresso nas ciências, na medida em que possibilitam a troca de conhecimentos e a colaboração entre pesquisadores das mais variadas áreas, tendo em vista o acesso e compartilhamento de artigos e trabalhos acadêmicos. Além do mais, o uso de dados em larga escala permite uma análise mais abrangente e precisa, contribuindo para a resolução de problemas complexos e o desenvolvimento de soluções inovadoras.

A ciência intensiva em dados requer o surgimento de um novo perfil profissional: o cientista de dados. O cientista de dados é um profissional que combina conhecimentos de informática, estatística, matemática e domínios específicos para gerenciar e analisar os dados científicos. Esse cientista é capaz de extrair insights valiosos dos dados, bem como comunicar e visualizar os resultados de forma eficaz. O cientista de dados é, portanto, um agente fundamental para a ciência intensiva em dados.

Em conclusão, a ciência intensiva em dados é uma área promissora e excitante que requer cooperação interdisciplinar e interorganizacional, bem como apoio e financiamento das agências e políticas públicas. A ciência intensiva em dados representa uma nova forma de fazer ciência, que pode levar a avanços significativos e inovações.

VII- Ciência de dados e sua relação com a inteligência artificial

A Ciência de Dados⁴ é um campo interdisciplinar que utiliza métodos científicos, processos, algoritmos e sistemas para extrair conhecimento e insights de dados estruturados e não estruturados. Ela é usada para resolver problemas complexos e tomar decisões informadas com base em dados. Quando se trata de resolver problemas relacionados à quantidade de dados, a ciência de dados desempenha um papel crucial. Ela permite abordar problemas que exigem a compreensão e exploração de uma variedade de soluções, motivando o desenvolvimento de teorias e técnicas para explicar e interpretar os resultados.

No contexto de Thomas Kuhn, a ciência de dados pode ser vista tanto como um paradigma quanto uma matriz disciplinar. Um paradigma, de acordo com Kuhn, é um conjunto de práticas que definem uma disciplina científica durante um período específico. A ciência de dados, com seus métodos e técnicas específicas para lidar com grandes volumes de dados, certamente se encaixa nessa definição.

Além disso, a ciência de dados também pode ser considerada uma matriz disciplinar, que é um conjunto mais complexo de elementos inter-relacionados que orientam uma disciplina científica. Por exemplo, a ciência de dados, por ser uma área interdisciplinar, contém elementos e *generalizações simbólicas* de áreas como a lógica e a matemática. As *crenças em modelos* podem ser exemplificadas pela confiança nos modelos de algoritmos de programação. Esses modelos, quando funcionam para uma determinada ocasião, podem se tornar *soluções de problemas concretos*, outro elemento da matriz disciplinar. Portanto, a ciência de dados não apenas se encaixa na definição de um paradigma, mas também demonstra os elementos de uma matriz disciplinar.

⁴ IBM. (n.d.). O que é ciência de dados? Recuperado de <https://www.ibm.com/br-pt/topics/data-science>

"A ciência de dados tornou-se um instrumento indispensável para a tomada de decisões em uma variedade de indústrias e domínios. A ciência de dados é uma disciplina em constante evolução, com novas técnicas e aplicações surgindo frequentemente. Com o desenvolvimento exponencial dos dados disponíveis, a ciência de dados tornou-se uma disciplina indispensável que permite às organizações extrair insights valiosos dos dados e tomar decisões mais informadas."(Chinthamu, N., & Karukuri, M. (2023). Data Science and Applications. Journal of Data Science and Intelligent Systems, 00(00), 1-9.)

A Ciência de Dados é uma disciplina interdisciplinar que emprega métodos científicos, processos e sistemas para extrair conhecimento ou percepções de dados em várias formas, sejam elas estruturadas ou não. E o ciclo de vida da ciência de dados é dado da seguinte forma: O processo começa com a definição clara do problema em questão, compreendendo o problema, formulando as perguntas corretas e definindo os objetivos do projeto. Em seguida, os dados são coletados de várias fontes, como bancos de dados, arquivos de texto, APIs⁵, web scraping⁶, entre outros. A qualidade e a quantidade de dados coletados nesta fase terão um impacto significativo na qualidade dos insights gerados posteriormente.

Os dados coletados são então preparados através de um processo de limpeza e transformação para remover ruídos, lidar com valores ausentes, converter tipos de dados, etc. Isso é feito para garantir que os dados estejam em um formato que possa ser facilmente analisado e interpretado pelos algoritmos de aprendizado de máquina.

A análise exploratória de dados é realizada em seguida, onde os dados são explorados usando várias técnicas estatísticas e de visualização para entender as tendências, padrões e relações nos dados. A modelagem de dados é o próximo passo, onde os algoritmos de aprendizado de máquina são aplicados aos dados para criar modelos preditivos. Isso pode envolver a seleção de recursos, a escolha do algoritmo, o ajuste de parâmetros, etc.

Cada etapa do processo de ciência de dados é iterativa e pode exigir várias rodadas de refinamento para obter os resultados desejados. Além disso, a ciência de dados é um campo em constante evolução, com novas técnicas e ferramentas sendo desenvolvidas regularmente para melhorar a eficiência e a precisão do processo. A ciência de dados tem uma ampla

⁵ APIs, ou Interfaces de Programação de Aplicativos, são um conjunto de regras e protocolos que permitem a interação entre diferentes softwares e plataformas. Elas facilitam a troca de informações e a integração de funcionalidades entre sistemas distintos (IBM. (n.d.). O que é uma API? Recuperado de <https://www.ibm.com/br-pt/topics/api>)

⁶ University of Wisconsin-Madison. (n.d.). An Introduction to Web Scraping for Research. Recuperado de <https://researchdata.wisc.edu/news/an-introduction-to-web-scraping-for-research/>

aplicabilidade em diversas indústrias e domínios. Com o constante avanço da disciplina, novas técnicas e aplicações estão surgindo regularmente. O crescimento exponencial dos dados disponíveis faz com que a ciência de dados seja cada vez mais indispensável, pois permite que as organizações extraiam insights valiosos dos dados e tomem decisões mais informadas.

Na medicina – como veremos a seguir -, a ciência de dados tem sido utilizada para melhorar o diagnóstico e o tratamento de doenças. Por exemplo, algoritmos de aprendizado de máquina podem ser aplicados para analisar grandes conjuntos de dados médicos e identificar padrões que possam ajudar os médicos a fazer diagnósticos mais precisos. Além disso, a ciência de dados também pode ser usada para prever o risco de certas doenças em indivíduos com base em seus dados demográficos e histórico médico. Essas informações podem auxiliar os profissionais de saúde na personalização dos cuidados e no desenvolvimento de estratégias preventivas.

No entanto, a ciência de dados também enfrenta vários desafios. Um dos maiores é a inescrutabilidade⁷, pois muitas vezes não sabemos como ou o que os modelos de ciência de dados aprendem ou inferem a partir dos dados. No entanto, anos de pesquisa proporcionaram avanços na superação de aspectos anteriormente desconhecidos, como soluções padronizadas, modelos de base e melhor compreensão dos modelos e representações de dados por meio de estudos empíricos.

Outro desafio importante é o uso ético da ciência de dados. A ciência de dados tem um escopo de questões éticas que excede o de todos os outros paradigmas de pesquisa, como o uso responsável e justo dos dados, a transparência e a explicabilidade dos modelos, o impacto social e ambiental das aplicações, e o equilíbrio de poder entre as organizações que controlam a ciência de dados.

⁷ A inescrutabilidade, no contexto da ciência de dados, alude à complexidade ou impossibilidade de discernir integralmente como um modelo de aprendizado de máquina sofisticado, tal como uma rede neural profunda, realiza suas decisões. Em termos mais explícitos, mesmo que o modelo seja capaz de produzir previsões acuradas, pode não ser evidente quais características dos dados o modelo está empregando para fazer tais previsões, ou como ele está combinando essas características para chegar a uma decisão. Esta questão pode ser particularmente problemática em situações em que é necessário compreender o raciocínio do modelo, como em aplicações médicas ou financeiras. A inescrutabilidade é um dos desafios mais significativos na ciência de dados e é um tópico de pesquisa ativamente explorado. (Weber, M., Engert, M., Schafer, N., Weking, J., & Krcmar, H. (2022). Organizational Capabilities for AI Implementation—Coping with Inscrutability and Data Dependency in AI. *Information Systems Frontiers*. [doi:10.1007/s10796-022-10297-y](https://doi.org/10.1007/s10796-022-10297-y))

VIII- A importância das técnicas de inteligência artificial para o progresso da medicina

A Inteligência Artificial (IA) e o Aprendizado de Máquina (ML) têm desempenhado um papel cada vez mais importante na medicina, oferecendo novas oportunidades para melhorar o diagnóstico e o tratamento de doenças. Como (PARVA et al, 2017) discutem em seu artigo *The Necessity of Data Mining in Clinical Emergency Medicine; A Narrative Review of the Current Literature*, a mineração de dados, uma subárea do ML, pode ser usada para analisar grandes conjuntos de dados clínicos e descobrir relações ocultas que podem levar a diagnósticos mais precisos e tratamentos mais eficazes. Essas técnicas podem ser particularmente úteis em situações de emergência, onde a rápida identificação e tratamento de condições médicas podem salvar vidas. As técnicas de ML, que são uma subcategoria da IA, são particularmente úteis para analisar grandes volumes de dados estruturados, como imagens médicas, dados genéticos e dados de eletrofisiologia. Esses métodos podem ajudar a identificar padrões e tendências que podem não ser facilmente perceptíveis para os humanos, permitindo diagnósticos mais precisos e prognósticos mais informados. A aplicação de técnicas de ML na medicina também pode auxiliar na descoberta de novos medicamentos e terapias personalizadas, levando a avanços significativos no campo da saúde. Por sua vez, a análise de dados em larga escala permite identificar correlações e relações complexas entre variáveis, contribuindo para a compreensão das causas e mecanismos subjacentes às doenças. Isso

Além disso, os métodos de Processamento de Linguagem Natural (PLN), outra subcategoria da IA, são úteis para extrair informações de dados não estruturados, como notas clínicas e periódicos médicos (JIANG et al, 2017). Essas técnicas podem transformar textos em dados estruturados legíveis por máquina, que podem então ser analisados por técnicas de ML (Machine Learning). Isso pode enriquecer os dados médicos estruturados existentes e fornecer insights adicionais que podem melhorar a assistência ao paciente.

Apesar do potencial dessas técnicas, também é importante reconhecer os desafios associados à sua implementação. Isso inclui questões como a qualidade e a privacidade dos dados, a interpretabilidade dos modelos de ML e a necessidade de validação rigorosa antes da implementação clínica. Além disso, a falta de padronização nos protocolos de coleta de dados

e a dificuldade em integrar as técnicas de ML aos sistemas existentes também são desafios a serem considerados. Portanto, é fundamental abordar essas questões para garantir que as técnicas de ML sejam utilizadas com segurança e eficácia na prática clínica.

A IA (inteligência artificial) têm o potencial de transformar a medicina, permitindo análises mais profundas e precisas dos dados do paciente. No entanto, é crucial que essas técnicas sejam implementadas de maneira ética e responsável, com consideração adequada para os desafios associados. Isso inclui questões como a privacidade dos dados dos pacientes, a transparência nos algoritmos utilizados e a necessidade de validação e supervisão humana para evitar resultados prejudiciais. Além disso, é importante garantir que a IA seja acessível e utilizado de forma equitativa, para que não haja exclusão de certos grupos ou disparidades no acesso aos benefícios dessas tecnologias.

Uma técnica bastante usada na medicina clínica para diagnósticos é a mineração de dados, como vimos acima, central da inteligência artificial, que pode ter um valor inestimável na medicina clínica. Esta técnica permite a extração de conhecimento oculto de grandes conjuntos de dados, usando algoritmos de aprendizado de máquina, sistemas especialistas, estatística, entre outros.

Na medicina clínica, a mineração de dados pode ser usada para analisar uma variedade de dados, desde imagens médicas e dados genéticos até registros eletrônicos de pacientes. Ao identificar padrões e tendências nesses dados, a mineração de dados pode ajudar os médicos a tomar decisões mais informadas sobre o diagnóstico e o tratamento de doenças. Por exemplo, na medicina de emergência, a mineração de dados pode ser usada para prever o tratamento necessário para os pacientes e fornecer as medidas necessárias antes que os pacientes entrem em situação crítica. Isso pode melhorar significativamente os resultados de saúde e salvar vidas.

A mineração de dados também pode ser aplicada na área da saúde para prever a propensão de um paciente a desenvolver certas doenças com base em seus históricos médicos e fatores de risco. Isso permite uma abordagem mais proativa na prevenção e tratamento de doenças, melhorando assim os resultados clínicos. Por exemplo, um estudo (PARVA et al, 2017) utilizou a técnica de mineração de dados chamada “classificação” com um algoritmo

específico conhecido como “árvore de decisão⁸”. O objetivo desse estudo era prever a ocorrência de doenças cardíacas. O estudo foi bem-sucedido em usar essas técnicas para identificar padrões nos dados que poderiam indicar um risco aumentado de doença cardíaca.

Um outro estudo no mesmo artigo utilizou uma técnica de mineração de dados chamada “agrupamento” com um algoritmo conhecido como “K-means⁹”. O objetivo desse estudo era agrupar pacientes com características semelhantes para melhor entender os padrões de doença e tratamento. Este estudo foi capaz de identificar grupos de pacientes com perfis de doença semelhantes, o que poderia ajudar os médicos a personalizarem os planos de tratamento.

Esses são apenas dois exemplos de como diferentes técnicas e algoritmos de mineração de dados podem ser aplicados para extrair insights valiosos de dados médicos. Esses insights podem, por sua vez, informar a tomada de decisões clínicas e melhorar os resultados dos pacientes.

Em resumo, a mineração de dados é uma técnica promissora e poderosa para a medicina clínica. Com a implementação ética e responsável dessas técnicas, podemos esperar ver melhorias significativas na precisão do diagnóstico e na eficácia do tratamento na medicina moderna.

IX- A ética e a confiabilidade do uso da inteligência artificial

Embora não seja o objetivo principal desse trabalho, julgamos que uma rápida observação sobre o aspecto da regulação do uso da IA seja importante. Se para a inteligência artificial, um dos seus objetivos no início do seu desenvolvimento era aprimorar a eficiência e a precisão das tarefas e além disso a automação do trabalho humano, hoje em dia, a ética e a confiabilidade também se tornaram fundamentais. Com o avanço da tecnologia, surgiram preocupações sobre como os sistemas de inteligência artificial são projetados, implementados e utilizados. É necessário garantir que esses sistemas sejam imparciais, transparentes e responsáveis, para evitar discriminação ou danos à sociedade.

⁸ É um algoritmo de aprendizado supervisionado usado para classificação e regressão. Ele cria um modelo que prevê o valor de uma variável de destino, aprendendo regras de decisão simples inferidas a partir das características dos dados.

⁹ É um algoritmo de agrupamento iterativo que divide um grupo de **n** conjuntos de dados em **k** subgrupos não sobrepostos. Cada conjunto de dados pertence ao grupo com a média mais próxima, servindo como protótipo do grupo.

Um grande problema quando pensamos em automação do trabalho humano é a sua óbvia substituição do homem pela máquina gerando desemprego. Como uma faca de dois gumes, a automação pode trazer benefícios ao aumentar a eficiência e produtividade, mas também pode resultar na perda de empregos e desigualdade social. Portanto, é importante encontrar um equilíbrio entre a automação e a preservação dos empregos, por meio de políticas de requalificação profissional e incentivo à criação de novas oportunidades de trabalho.

Um outro problema é em relação à privacidade e como os nossos dados estão desprotegidos. Esses dados podem ser coletados e utilizados de forma indevida, o que levanta preocupações sobre a segurança e o uso ético da tecnologia. É necessário estabelecer regulamentações e mecanismos de proteção para garantir a privacidade dos indivíduos e evitar abusos por parte das empresas ou governos. Além disso, é importante conscientizar as pessoas sobre os riscos envolvidos no compartilhamento de dados, sobretudo na internet.

Com o avanço das tecnologias de inteligência artificial nos vem a preocupação também com a confiabilidade (Trustworthy) dos sistemas e algoritmos utilizados. É fundamental que essas tecnologias sejam desenvolvidas de forma transparente e responsável, com a inclusão de mecanismos de explicabilidade e auditoria. Segundo (LIU et al, 2021, p. 5), “A IA confiável envolve seis dimensões cruciais: Segurança e Robustez, Não-discriminação e Justiça, Explicabilidade, Privacidade, Responsabilidade e Auditabilidade, e Bem-estar Ambiental”. Além disso, é necessário investir em pesquisas e estudos para entender melhor os impactos sociais, econômicos e éticos da inteligência artificial, a fim de tomar decisões informadas sobre seu uso.

É ressaltado a relevância dessas seis dimensões com exemplos como a explicabilidade que ao evitar as "black boxes"¹⁰ permite que as decisões tomadas por sistemas de inteligência artificial sejam compreendidas e justificadas, garantindo transparência e confiança. Já, segurança e robustez são fundamentais para evitar falhas e vulnerabilidades que possam ser exploradas por agentes maliciosos. Enquanto a privacidade e a proteção de dados são

¹⁰ O termo é frequentemente empregado para descrever modelos de aprendizado de máquina cujos processos internos e lógica de tomada de decisão são inacessíveis ou ininteligíveis para os usuários. Esses modelos, embora possam produzir resultados precisos, não fornecem uma explicação clara ou intuitiva de como chegaram a esses resultados. A natureza opaca desses sistemas pode ser problemática, especialmente em contextos em que a transparência e a compreensibilidade são cruciais para a confiança e a aceitação do usuário.

essenciais para garantir que as informações pessoais dos usuários sejam devidamente protegidas e não sejam utilizadas de maneira indevida ou tenham seus dados vazados.

Além disso, a equidade e a imparcialidade são aspectos cruciais para evitar viés e discriminação na tomada de decisões automatizadas, enquanto a responsabilidade social visa garantir que os impactos negativos da inteligência artificial tenham seus fatores responsabilizados sejam pelo uso que causou danos a sociedade ou pelo desenvolvimento de tecnologias que possam ser prejudiciais.

Conclusão

O estudo do presente trabalho mostra o valor da Teoria da Ciência de Thomas Kuhn, na medida em que a técnica, como um dos elementos do paradigma, ou mesmo da matriz disciplinar, constitui um aspecto central no desenvolvimento científico.

A importância da técnica, especialmente dos instrumentos, ganha destaque a partir do século XVII, com a Física, mas se constitui, hoje, como um recurso central nas ciências naturais.

Entendo a Inteligência Artificial como técnica, seu valor é inegável nas ciências, como vimos anteriormente. De toda maneira, uma análise aprofundada desse novo “instrumento” mostra-se necessária, pois estamos em face de uma nova técnica com características muito peculiares, que busca simular o próprio pensamento humano!

É evidente que a Inteligência Artificial desempenha um papel crucial no avanço das ciências. No entanto, a questão de se isso constitui uma mudança de paradigma à luz da filosofia da ciência de Thomas Kuhn é mais complexa.

Primeiramente, é inegável que a IA está revolucionando a maneira como conduzimos a pesquisa e interpretamos os dados. Ela tem o potencial de acelerar descobertas, de fornecer novas perspectivas e até mesmo questionar suposições existentes em várias disciplinas científicas.

No entanto, ao considerar a filosofia da ciência de Kuhn, uma mudança de paradigma implica não apenas em avanços, mas também em um movimento distinto de um paradigma estabelecido para outro. Isso geralmente envolve o abandono de teorias, conceitos ou práticas anteriores que são incompatíveis com o novo paradigma.

Nesse sentido, embora a IA esteja certamente influenciando a maneira como a ciência é conduzida, não está até o momento, substituindo ou invalidando métodos científicos existentes. Em vez disso, a IA pode ser vista como uma ferramenta poderosa que complementa e aprimora esses métodos.

Portanto, pode-se argumentar que estamos testemunhando não uma mudança de paradigma no sentido estrito de Kuhn, mas sim uma evolução significativa na prática científica. A IA está expandindo nossas capacidades e transformando a maneira como fazemos ciência, mas sem descartar completamente os paradigmas existentes.

Cada vez mais, as técnicas de inteligência artificial são peças fundamentais para a prática científica, na medida em que certas áreas só podem fazer ciência com o uso dessas ferramentas. Substituindo por certas vezes os métodos tradicionais e adotando abordagens baseadas em IA, os cientistas estão conseguindo obter resultados mais precisos e rápidos em suas pesquisas. Isso demonstra que a inteligência artificial não apenas complementa, mas também impulsiona a prática científica, abrindo novas possibilidades e desafios para os pesquisadores.

A IA – vista como um “instrumento”, como a luneta de Galileu - pode acelerar a mudança teórica e, na terminologia, kuhniana, levar de maneira mais rápida a novas revoluções científicas. A IA pode ser considerada como um dos elementos do paradigma ou da matriz disciplinar. Nesse sentido, teria o mesmo status que as demais técnicas.

No entanto, se a AGI realmente se consolidar, não poderia se criar uma comunidade artificial autônoma, parafraseando Thomas Kuhn no conceito de comunidade científica, e produzir não somente ciência independente do ser humano, mas também máquinas pensantes? Como as regulamentações do uso da IA podem fazer frente a isso? São questões perturbadoras, mas não parecem irrealis.

Referências

ATAMAN, A. (2023). **Data Quality in AI: Challenges, Importance & Best Practices.**

AIMultiple. Disponível em: [<https://research.aimultiple.com/data-quality-ai/>].

BELL, Gordon. Prefácio. In: HEY, T., TANSLEY, S., & TOLLE, K. **The Fourth Paradigm: Data-Intensive Scientific Discovery.** Redmond, WA: Microsoft Research, 2009. p. xi-xv.

CHINTHAMU, N.; KARUKURI, M. **Data Science and Applications.** *Journal of Data Science and Intelligent Systems*, v. 00, n. 00, p. 1-9, 2023. Disponível em: [[Data Science and Applications | Journal of Data Science and Intelligent Systems](#)]

FAZZIO, Adalberto; SCHLEDER, Gabriel R. **Machine Learning na Física, Química, e Ciência de Materiais: Descoberta e Design de Materiais.** São Paulo: SciELO, 2023. Disponível em: [<https://www.scielo.br/j/rbef/a/qzcfSKw4nzBK5Mddr8ZXy4v/>].

FEENBERG, Andrew. **O que é Filosofia da Tecnologia.** Tradução de Agustín Apaza, com revisão de Newton Ramos-de-Oliveira e Franco Nero Antunes Soares. Komaba, 2003.

GRAY, Jim. **Jim Gray on eScience: A Transformed Scientific Method.** Redmond, WA: Microsoft Research, 2007.

HEY, T., TANSLEY, S., & TOLLE, K. **The Fourth Paradigm: Data-Intensive Scientific Discovery.** Redmond, WA: Microsoft Research, 2009.

JIANG, F.; JIANG, Y.; ZHI, H.; et al. **Artificial intelligence in healthcare: past, present and future.** *Stroke and Vascular Neurology*, v. 2, 2017. Disponível em [[Artificial intelligence in healthcare: past, present and future](#)]

KUHN, Thomas S. **Tensão Essencial: Tradição e Inovação na Pesquisa Científica.** Tradução de Marcelo Amaral Penna-Forte. 1ª edição. São Paulo: Editora Unesp, 2009.

KUHN, Thomas S. **A estrutura das revoluções científicas/Thomas S. Kuhn; tradução Beatriz Vianna Boeira e Nelson Boeira.** — 12. ed. São Paulo: Perspectiva, 2013.

LIU, Haochen; WANG, Yiqi; FAN, Wenqi; LIU, Xiaorui; LI, Yaxin; JAIN, Shaili; LIU, Yunhao; JAIN, Anil K.; TANG, Jiliang. **Trustworthy AI: A Computational Perspective.**

AI Magazine, v. 27, n. 4, p. 12-14, 2021. Disponível em [[\[2107.06641\] Trustworthy AI: A Computational Perspective \(arxiv.org\)](#)]

LUDERMIR, Teresa Bernarda. **Inteligência Artificial e Aprendizado de Máquina: estado atual e tendências**. Recife: SciELO, 2023. Disponível em: [[SciELO - Brasil - Inteligência Artificial e Aprendizado de Máquina: estado atual e tendências Inteligência Artificial e Aprendizado de Máquina: estado atual e tendências](#)].

McCARTHY, J.; MINSKY, M. L.; ROCHESTER, N.; SHANNON, C. E. **A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence**. AI Magazine, v. 27, n. 4, p. 12-14, 2006.

MOORE, G. E. **Cramming more components onto integrated circuits**. Electronics Magazine, v. 38, n. 8, 1965.

PASSARINI, Guilherme Matos. **As aplicações de IA na biologia**. IA Expert Academy, 2020. Disponível em: [[As aplicações de IA na biologia | IA Expert Academy](#)].

PAIXÃO, Gabriela Miana de Mattos et al. **Machine Learning na Medicina: Revisão e Aplicabilidade**. Recife: SciELO, 2023. Disponível em: [[SciELO - Brasil - Machine Learning na Medicina: Revisão e Aplicabilidade Machine Learning na Medicina: Revisão e Aplicabilidade](#)].

PARVA, E.; BOOSTANI, R.; GHAHRAMANI, Z.; PAYDAR, S. **The Necessity of Data Mining in Clinical Emergency Medicine; A Narrative Review of the Current Literature**. Bulletin of Emergency and Trauma, v. 5, n. 2, p. 79-85, 2017. Disponível em [[Bull Emerg Trauma 2017 5 2 90 95.pdf \(who.int\)](#)]

BALDISSERA, Olívia. **Os 3 Tipos de Inteligência Artificial**. Curitiba: PUCPR, 2023. Disponível em: [[Os 3 Tipos de Inteligência Artificial \(pucpr.br\)](#)].

RUSSELL, S., & NORVIG, P. (2021). **Artificial Intelligence: A Modern Approach (4th ed.)**. Englewood Cliffs, NJ: Pearson.

SILVA, Roberta Jerônimo da. **A INTELIGÊNCIA ARTIFICIAL NO CONTEXTO DA CIÊNCIA DA INFORMAÇÃO**. Recife: UP, 2023. Disponível em: [[A Inteligência Artificial no Contexto da Ciência da Informação](#)].

SICHMAN, Jaime Simão. **Inteligência Artificial e sociedade: avanços e riscos**. São Paulo: SciELO, 2023. Disponível em: [[SciELO - Brasil - Inteligência Artificial e sociedade: avanços e riscos Inteligência Artificial e sociedade: avanços e riscos](#)].

SODRÉ JR., Laerte. AGA 0505- **Análise de Dados em Astronomia I 9. Aprendizado de Máquina: Princípios Gerais**. São Paulo: USP, 2021. Disponível em: [[AGA 0505- Análise de Dados em Astronomia I 9. Aprendizado de Máquina: Princípios Gerais \(usp.br\)](#)].