

PONTIFÍCIA UNIVERSIDADE CATÓLICA DE SÃO PAULO04F

Moisés Zylbersztajn

Aproximações possíveis (e necessárias) entre Inteligência Artificial e Escola

MESTRADO EM TECNOLOGIAS DA INTELIGÊNCIA E DESIGN DIGITAL

**São Paulo
2023**

Pontifícia Universidade Católica de São Paulo

Moisés Zylbersztajn

Aproximações possíveis (e necessárias) entre Inteligência Artificial e Escola

Dissertação apresentada à Banca Examinadora da Pontifícia Universidade Católica de São Paulo, como exigência parcial para obtenção do título de MESTRE em Tecnologias da Inteligência e Design Digital, na linha de pesquisa Inteligência Artificial e Gestão, sob a orientação da Profa. Dra. Dora Kaufman

**São Paulo
2023**

Sistemas de Bibliotecas da Pontifícia Universidade Católica de São Paulo -
Ficha Catalográfica com dados fornecidos pelo autor

Zylbersztajn, Moisés

Aproximações possíveis (e necessárias) entre Inteligência Artificial e Escola / Moisés Zylbersztajn. -- São Paulo: [s.n.], 2023. 136 p. ; cm.

Orientador: Dora Kaufman.

Dissertação (Mestrado) -- Pontifícia Universidade Católica de São Paulo, Programa de Estudos Pós-Graduados em Tecnologias da Inteligência e Design Digital.

1. inteligência artificial. 2. educação. 3. aprendizado de máquina. 4. metacognição. I. Kaufman, Dora. II. Pontifícia Universidade Católica de São Paulo, Programa de Estudos Pós-Graduados em Tecnologias da Inteligência e Design Digital. III. Título.

Moisés Zylbersztajn

Aproximações possíveis (e necessárias) entre Inteligência Artificial e Escola

Dissertação apresentada à Banca Examinadora da Pontifícia Universidade Católica de São Paulo, como exigência parcial para obtenção do título de MESTRE em Tecnologias da Inteligência e Design Digital, na linha de pesquisa Inteligência Artificial e Gestão, sob a orientação da Profa. Dra. Dora Kaufman

Aprovado em: ___ / ___ / _____

Banca examinadora

Prof^ª Dr^ª Dora Kaufman (presidente)
PUC-SP

Prof^ª Dr^ª Rosa Maria Vicari
Universidade Federal do Rio Grande do Sul

Prof^ª Dr^ª Maria Elizabeth Bianconi Almeida (membro interno)
PUC-SP

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) - Processo 88887.702111/2011-00

This study was financed in part by the Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Finance Code 88887.702111/2022-00

AGRADECIMENTOS

Sinto-me realizado por ter podido dar prosseguimento à minha carreira acadêmica, mais de 30 anos depois de concluir minha graduação, aproximando minha experiência profissional dos rigores da pesquisa acadêmica, em área do conhecimento que requer, para sua efetiva contribuição ao trabalho escolar, da mistura destes componentes.

Preciso agradecer profundamente minha orientadora, Dora Kaufman, pela sua generosidade em debruçar-se sobre minha pesquisa iluminando-a com seu conhecimento e pela sua tenacidade em manter-me sempre motivado e capaz de conjugar minhas inquietudes profissionais com a necessidade de produzir pesquisa científica de qualidade.

Agradeço ao TIDD, da PUC, que represento aqui no nome da Profa. Lucia Santaella, que me mobilizou a contribuir na produção de conhecimento sob a ótica da multidisciplinaridade. Embora pareça óbvia e necessária construção colaborativa e coletiva do conhecimento, desfrutar da companhia de mestres em áreas tão distintas, produzindo juntos, é realidade naquele departamento e foi fundamental para o desenvolvimento deste trabalho e meu desenvolvimento profissional.

Agradeço também aos meus colegas do Colégio Santa Cruz, em especial ao Núcleo de Educação Digital, pelo apoio e especialmente, pelos inúmeros momentos de reflexão sobre cultura digital e pela prática conjunta de atividades de formação de docentes e discentes no campo das tecnologias digitais.

Finalmente, quero dedicar esta dissertação à minha esposa, Gisele, colega de profissão e de vida, que me estimulou desde o início a mergulhar nessa trilha, ajudou a superar o cansaço e desânimo em algumas etapas do processo e renunciou a incontáveis horas de convivência para que eu pudesse dar conta deste desafio.

ZYLBERSZTAJN, Moisés. **Aproximações possíveis (e necessárias) entre Inteligência Artificial e Escola.** 139 f. Dissertação (Mestrado em Tecnologias da Inteligência e Design Digital) – Pontifícia Universidade Católica de São Paulo, São Paulo, 2023.

RESUMO

Parece imperativo que a escola, assim como as demais instituições humanas, considere o desafio urgente de compreender, preparar-se e participar do desenvolvimento das aplicações de inteligência artificial (IA) que podem contribuir para a gestão do ensino e o aprimoramento da aprendizagem. Por meio da análise de documentos, publicações e estudos recentes, esta dissertação procura aproximar escola e IA, baseada em: a. conceituação técnica do desenvolvimento desta área de experimentação, apresentando inclusive alguns modelos matemáticos que embasam o aprendizado de máquina; b. estudos de casos de aplicativos educacionais, que permitam reconhecer o potencial das possíveis soluções baseadas em IA e c. análise crítica sobre a implantação histórica de tecnologias na escola brasileira para servir como insumo para a reflexão que se faz necessária neste momento.

Palavras-chave: educação, inteligência artificial, aprendizado de máquina, metacognição.

ZYLBERSZTAJN, Moisés. **Aproximações possíveis (e necessárias) entre Inteligência Artificial e Escola.** 139 f. Dissertação (Mestrado em Tecnologias da Inteligência e Design Digital) – Pontifícia Universidade Católica de São Paulo, São Paulo, 2023.

ABSTRACT

It seems imperative that schools, like any other institution, consider the urgent challenge of understanding, preparing for and participating in the development of artificial intelligence (AI) applications that can contribute to the management of teaching and the improvement of learning. Through the analysis of documents, publications and recent studies, this dissertation seeks to bring school and AI closer together, based on: a. technical conceptualization of the development of this area of experimentation, presenting mathematical models that support machine learning; b. case studies of educational applications, which allow recognizing the potential of possible solutions based on AI and c. critical analysis of the historical implementation of technologies in Brazilian schools to serve as input for the reflection that is necessary at this time.

Keywords: Education, Artificial Intelligence, Machine Learning, Metacognition

LISTA DE ABREVIATURAS E SIGLAS

IA – Inteligência Artificial
MOOC's – Massive Online Open Courseware
PLN – Processamento de Linguagem Natural
TPACK – Technological Pedagogical Content Knowledge
STIA – Sistema Tutor Inteligente e Adaptativo
LLM – Large Language Models
RRN – Redes Neurais Recorrentes
CNN – Redes Neurais Convolucionais
ENEM – Exame Nacional do Ensino Médio
AVA – Ambiente Virtual de Aprendizagem
LGPD – Lei Geral de Proteção de Dados
INEP – Instituto Nacional de Estudos e Pesquisas Educacionais
GPT – Generative PreTrained Transformer
TIC – Tecnologias da Informação e Comunicação
DDDM – Data-driven Decision Making

LISTA DE FIGURAS

Figura 1 – Eventos relacionados à evolução do campo de estudo da IA
Figura 2 - Inteligência artificial e subáreas
Figura 3 – Programação convencional e aprendizado de máquina
Figura 4 – Reconhecimento de imagem manuscrita
Figura 5: Tela do aplicativo Photomath
Figura 6 – Modelo de interpretação textual – Transformer
Figuras 7a, 7b, 7c e 7d– Iteração sobre texto Tolstói
Figura 8 – Intersecção entre os campos da ciência de dados, inteligência artificial e aprendizado de máquina
Figura 9 – Tipos de aprendizado de máquina
Figura 10 – Modelos algorítmicos do aprendizado de máquina
Figura 11 – Exemplo de função estatística usando Regressão Linear
Figura 12 – Classificação de documentos por tópico
Figura 13 – Árvore de decisão – sobrevivência no Titanic
Figura 14 – O modelo do Perceptron
Figura 15– Esquema da rede neural composta de várias camadas de neurônios digitais
Figura 16– Rede neural processando o reconhecimento progressivo de caracteres manuscritos
Figura 17 - Estado de “excitação” dos neurônios artificiais na geração de palavras
Figura 18 – Rede neural de aprendizado profundo processando análise de viabilidade de seguro médico
Figura 19 – Incidência de modelos algorítmicos em aplicação educacional de IA
Figura 20 – Tendências nas aplicações de IA em educação
Figura 21 – O triângulo dourado
Figura 22 – O processo da Metacognição
Figura 23 – Modelo de STIA
Figura 24 – Sequência didática recomendada, a partir do diagnóstico

- Figura 25 – Diálogo socrático no Korbit
- Figura 26 – Um diálogo ilustrativo
- Figura 27 – PLN na formação de uma dica
- Figura 28 – SimStudent – modelo de IA como aprendiz
- Figura 29 – Betty’s Brain
- Figura 30 – A tutoria no Betty’s Brain
- Figura 31 – Tela eNeuron – aplicação baseada em IA para revisão de textos
- Figura 32 – Tela eNeuron – revisão conceito ENEM
- Figura 33 – Tela do LightSide da Carnegie Melon
- Figura 34 – O TeachGPT em ação
- Figura 35 – Ondas tecnológicas na escola brasileira
- Figura 36 – TPACK
- Figura 37 – Modelo de análise de impacto de sistemas de IA

LISTA DE QUADROS

- Quadro 1 – Etapas do processo de mineração de dados (data mining)
- Quadro 2 – Aplicações de IA na educação
- Quadro 3 – Aplicações educacionais com evidências do uso de técnicas de IA
- Quadro 4 – Sucesso a partir da dica personalizada
- Quadro 5 - competências consideradas críticas para uma alfabetização em IA.
- Quadro 6 – Framework ações de preparação para IA na escola

SUMÁRIO

1. INTRODUÇÃO	13
1.1. A pesquisa e o pesquisador	13
1.2. Por que estudar a IA?	15
2. SOBRE A ORGANIZAÇÃO DA DISSERTAÇÃO	19
2.1. O estado da arte	19
2.2. Metodologia de pesquisa	21
2.3. Organização da pesquisa	22
3. CONHECENDO UM POUCO MELHOR A IA	25
3.1. Termos gerais da IA	25
3.2. Discutindo inteligência de máquina – podem as máquinas pensar?	28
3.3. A história do desenvolvimento da IA	33
3.4. Como as máquinas “aprendem” – o aprendizado de máquina	35
3.5. Da IA preditiva para a generativa	38
3.6. Ciência de dados – evolução e impacto	42
3.7. Paradigmas de aprendizado de máquina	44
3.7.1. O aprendizado supervisionado	45
3.7.2. O aprendizado não supervisionado	46
3.7.3. O aprendizado por reforço	46
3.7.4. Outros tipos de aprendizado	47
3.8. Modelos algorítmicos	49
3.8.1. Regressão linear	51
3.8.2. <i>K-Means</i>	52
3.8.3. Árvore de decisão	53
3.8.4. Redes neurais	55
3.9. Incidência dos modelos algorítmicos em aplicações educacionais	62
4. ESTUDOS DE CASO – APLICAÇÕES DA IA NA EDUCAÇÃO	65
4.1. Tendências	65
4.2. Critérios para os estudos de caso apresentados	66
4.3. Metacognição e autorregulação	73
4.4. Estudo de caso – aplicações	75
4.4.1. Aplicações centradas no aluno	75
4.4.1.1. Aplicações centradas no aluno – IA aprendiz	85
4.4.2. Aplicações centradas no professor	89
4.4.2.1. Aplicações centradas no professor – IA aprendiz	95
4.4.3. A IA e os grandes modelos de linguagem	97
4.4.3.1 O ChatGPT como aprendiz	97

5. MUITO SKINNER E POUCO PAPERT... UM INÍCIO PROMISSOR, UM CAMINHO NEM TANTO	101
5.1. Premissas	101
5.2. Cinquenta anos de tecnologias na escola	105
5.3. Recomendações e perguntas que podem orientar educadores e instituições a pensarem em como utilizar tecnologias baseadas em IA	115
5.3.1. Reflexões para as instituições escolares	115
5.3.2. Reflexões para educadores	119
6. CONCLUSÃO	127
7. REFERÊNCIAS BIBLIOGRÁFICAS	130

1. INTRODUÇÃO:

1.1.A pesquisa e o pesquisador

Em 1977, logo após entrar no curso de Engenharia da Escola Politécnica da USP, ainda com 17 anos, recebi um convite de um amigo da família, para ministrar aulas de física em um curso supletivo. Embora tímido e muito reservado, fui aprovado, para minha surpresa, no teste de uma aula simulada e tornei-me educador de um modo bastante acidental. Se não fosse ser um curso supletivo, onde aquele que subia no tablado era respeitado incondicionalmente, minha trajetória profissional teria sido outra. E o fato é que a educação não saiu mais de mim. Em 1981, após ter largado o curso de engenharia, eu dava aulas de física no colégio e cursinho do Colégio Objetivo, na Av. Paulista. Referência de inovação no ensino, o Objetivo procurava dar escala, no ensino médio, ao modelo bem-sucedido de ensino preparatório para vestibulares, o chamado “cursinho”. Era um sistema de ensino e produzia um trabalho pioneiro no Brasil. Esse sistema mantinha, com um currículo apostilado, a garantia de uniformidade do trabalho docente em todas as unidades da rede. Apesar do sucesso do sistema na época, fui ficando cada vez mais cético ao ministrar aulas de acordo com esse modelo. Tínhamos pouca liberdade de criação como docentes e se induzia pouco protagonismo ao aluno. Fui estudar Pedagogia na busca de saídas que pudessem funcionar como um contraponto à essa experiência docente padronizada. Esta busca por um ensino autoral, mais livre e dinâmico, permanece viva no meu trabalho e dá significado ao objeto desta pesquisa, que questiona a padronização do ensino, risco iminente na implementação das tecnologias baseadas em inteligência artificial (IA) na educação, quando não acompanhada de intensa pesquisa e apoiada na ampla conscientização dos diversos agentes educacionais.

Na Faculdade de Educação, também na USP, outras coincidências: havia ali, em 1983, um laboratório de formação de monitores na linguagem LOGO. Essa linguagem de programação especialmente desenhada para crianças, foi obra do matemático Seymour Papert, um dos mais importantes pesquisadores, com Marvin Minsky, sobre IA nas décadas de 1950 e 1960 no MIT. Era um ativista da cibercultura que via computadores “como instrumentos para trabalhar e pensar, como meios de realizar projetos, como fonte de conceitos para pensar novas ideias” (Papert, 1980, p.158).

Papert propunha, entre vários princípios, os apresentados a seguir.

a. que o primeiro contato das crianças com os computadores já as deve colocar como autoras, programadoras, para que compreendam desde cedo a lógica de funcionamento dessas máquinas e o modo como elas nos ajudam a resolver problemas.

b. a computação permite que, ao se resolver um problema por meio de programação, pela sua lógica de execução e depuração, o aluno veja de imediato o resultado de seu pensamento explicitado, e isso possibilita que ele possa depurá-lo continuamente. O erro vira parte importante do aprendizado.

Aprendi, então, que a abstração reflexiva permite a projeção daquilo que é extraído de um nível mais baixo para um nível cognitivo mais elevado, ou seja, reorganização do conhecimento em termos de conhecimento prévio (Valente, 2005). Participar dessa experiência de tornar-me um professor de LOGO marcou profundamente minha carreira. Percebi como os computadores poderiam potencializar o trabalho de um professor, ampliando seu repertório didático e possibilitando novas estratégias para a construção de suas práticas. Aprendi que o computador precisava ser apresentado às crianças (e aos adultos) como uma plataforma aberta e autoral. Passei, desde então, a trabalhar com educação e tecnologia, sempre nesta ordem, considerando-me um profissional da educação com um olhar mais aprofundado sobre o campo das tecnologias digitais.

Durante vários anos, trabalhei no desenvolvimento, na localização e na comercialização de software educacional para escolas. Aprendi que as plataformas mais abertas e autorais, que permitiam ao professor e ao aluno intervenção sobre o que poderia ser produzido nelas, sempre traziam melhores resultados. O trabalho epistêmico, a experimentação e o olhar reflexivo sobre a própria produção sempre me pareceram mais promissores no processo de formação humana.

Em seguida, tive uma longa experiência com *e-learning*, na gestão da produção de conteúdo para cursos on-line em uma editora. Aprendi que o ensino híbrido possibilitava uma real emancipação do aluno em relação à atuação direta e presencial do professor e compõe uma solução ideal para o *lifelong learning*, gerando a autonomia indispensável ao homem contemporâneo diante da evolução na produção e no acesso ao conhecimento.

Hoje coordeno o núcleo de educação digital de um grande colégio paulistano, onde atuo com uma equipe de educadores de tecnologia junto à cerca de 300 professores e 3.000 alunos da Educação Infantil até o Ensino de Jovens e Adultos. Tenho buscado, com intensidade, um olhar transversal sobre as possibilidades das tecnologias aplicadas a

todos os campos do conhecimento. O conhecimento específico da técnica só tem relevância quando alcança uma aplicação, quando impacta efetivamente algo que podemos fazer de modo distinto por meio dessa técnica. Daí a luta permanente para que todos os professores consigam carregar em seus planejamentos a responsabilidade por essa camada de conhecimento relativa ao digital. Da escolha do editor de textos como instrumento de produção de uma redação ao uso de uma impressora 3D na construção de uma maquete, é preciso clareza sobre a intencionalidade didática dessa opção digital e seu impacto no processo de produção pedagógica. Luto para que tecnologia não seja uma disciplina em si, mais uma caixinha na grade horária, mas parte do trabalho de todos. Olhando especificamente para o aluno, meu trabalho tem sido o de tornar as tecnologias digitais um objeto de estudo em sala de aula, revirá-las, desconstruí-las, debatê-las, para que não sejam adotadas de modo alienante por cada um de nós.

1.2. Por que estudar a IA?

Tecnologias têm apoiado o desenvolvimento do trabalho pedagógico desde o aparecimento da escola como instituição. Elas potencializam a capacidade didática e ampliam o repertório dos professores e o desenvolvimento da capacidade de aprendizagem do aluno. Uma esferográfica ampliou o acesso das populações ao registro sistemático em sala de aula. A computação em nuvem permitiu o acesso ubíquo a produções individuais e coletivas. O livro didático organizou o conteúdo específico de uma disciplina para apoio ao estudo individual e coletivo. Softwares de simulação, no campo das ciências, ampliaram a possibilidade de compreensão, por meio da manipulação, por parte do aluno, de fenômenos naturais. Um aplicativo digital de apoio ao ensino de matemática, que reúne centenas de situações-problema com soluções e feedbacks programados, pode contribuir para um maior domínio conceitual e operativo do conteúdo estudado. Um sistema de gestão de provas com questões objetivas, programado para oferecer feedback imediato ao aluno e produzir painéis de análise para o professor, pode contribuir para o aprimoramento das práticas de ensino-aprendizagem.

Todas essas soluções educacionais existem sem que seja necessário utilizar-se de inteligência artificial (IA) e são todas muito úteis às práticas pedagógicas. Por que então propor que se introduzam soluções baseadas em IA nessas práticas? O que essas soluções impregnadas de aprendizado de máquina trazem de benefício adicional às soluções

digitais existentes? O que há de novo? Por que escrever uma dissertação sobre as perspectivas de IA na escola brasileira?

As aplicações baseadas em IA estão provocando transformações em todas as áreas, mas as que se aproximam cada vez mais das escolas devem impactar inicialmente na automação do processo de avaliação e na personalização da aprendizagem (Luckin, 2019). Será, portanto, importante que os educadores se mantenham atentos aos mecanismos que produzem essa automação e essa personalização tanto para avaliarem seus benefícios como para evitar uma excessiva mecanização do ensino e da aprendizagem. Será preciso reconhecer os recursos que permitirão, a professores e alunos, encontrar na IA um assistente relevante disponível para aprender conosco, mais do que um instrumento pronto para nos ensinar. Como tirar proveito dessa tecnologia sem sucumbir à sua lógica?

São pelo menos três as razões que me levam a dedicar-me a esta dissertação. Inicialmente, acredito que o papel da educação e da escola deve ser o de transformar a vida, em toda a sua complexidade, em objeto permanente de estudo. A escola permite esse recuo excepcional (Masschelein, 2020) que retira a criança e o jovem do convívio familiar e laboral, para fruir, decifrar e construir compreensão e possibilidade de transformação sobre a vida, o conhecimento e o mundo. Portanto, trazer a IA para a escola significa torná-la um conteúdo a ser estudado. É imperativo que possamos todos compreender sua formulação, seu desenvolvimento e seus possíveis impactos. Antes de usá-la ou, ou pelo seu uso, é preciso desmistificá-la. Para evitar-se um uso instrumental das tecnologias digitais no ensino, entendendo-as como neutras e impedindo uma apropriação crítica é preciso, sobretudo, aprender sobre elas (Buckingham, 2022).

Em seguida, acredito que a IA poderá contribuir para um ensino voltado à autonomia do aluno enquanto estudante, um ensino que privilegia a autorregulação da aprendizagem, que possibilita ao aluno reconhecer seu processo cognitivo, construir estratégias para avançar e consolidar esse caminho usando metacognição, “a capacidade de todo ser humano de monitorar e autorregular os próprios processos cognitivos” (Flavell, 1987), como modo natural de aprendizagem ao longo de toda a vida. Conhecimento robusto, que se transfere para novas situações, dura ao longo do tempo e pode facilitar o aprendizado futuro (Aleven; Azevedo, 2013). Soluções baseadas em IA poderão se apresentar como assistentes capazes de acompanhar o raciocínio e a produção de alunos e professores e interagirem dinamicamente com essa produção, ampliando-a, revelando novas nuances, ajustando e sugerindo ideias.

E finalmente, este trabalho se apresenta como importante quando reconheço ter encontrado, no departamento de Tecnologias da Inteligência e Design Digital da PUC, sob a orientação das professoras Lucia Santaella e Dora Kaufman, um ambiente estimulante e aberto para questionar as certezas advindas do modo como as mídias e o senso comum tratam deste campo do conhecimento denominado IA. Ao longo de minha trajetória como educador de tecnologia, conhecia muito pouco do assunto até inscrever-me em uma extensão com a Professora Dora, feita no ambiente remoto, durante a pandemia, em que percebi o alcance que esta tecnologia já tinha nas nossas práticas diárias, o desconhecimento do público escolar sobre seu funcionamento e possível impacto e a iminência de sua chegada na escola. Encontrei no TIDD a disposição para olhar esse fenômeno por tal variedade de pontos de vista que me impeliu a encontrar o sentido necessário para seguir avançando na minha trajetória pessoal e para contribuir com meus colegas, professores de todas as áreas e níveis de ensino.

Importante citar que iniciei meu mestrado em agosto de 2021, ainda durante as restrições acadêmicas e sanitárias decorrentes da pandemia. Construí, com minha orientadora, a profa. Dora Kaufman, o projeto da dissertação ao longo de 2022 e iniciei a escrita em dezembro de 2022, exatamente na semana em que o ChatGPT entrou em cena. Se seu advento propiciou uma aproximação inédita da população em geral e do educador escolar com a IA, também produziu muita indefinição em relação aos princípios que havíamos estabelecido para a pesquisa. Seja pela tentação inicial de usar o modelo de linguagem para consultas sistemáticas de pontos da pesquisa, seja pela sensação de que as aplicações escolhidas para os estudos de caso haviam perdido o encanto, diante do impacto de uma IA que dialoga sobre tudo em linguagem natural, seja pela prolixidade dos debates, asserções e inovações produzidas ao longo de 2023, que sistematicamente pareciam tornar minhas ideias e pesquisas datadas, ultrapassadas. Busquei transformar essas incertezas em desafio estando certo de que o advento do ChatGPT torna ainda mais importante estimular educadores a conhecerem os processos por detrás desta aplicação e das demais que agora surgem em abundância.

2. SOBRE A ORGANIZAÇÃO DA DISSERTAÇÃO:

2.1. O Estado da Arte

Aprofundando as hipóteses de que as tecnologias digitais têm papel decisivo na aprendizagem humana, com o avanço das técnicas de aprendizado de máquina, subárea da inteligência artificial, multiplicam-se aplicações e possibilidades.

Observam-se, pelo mundo, análises e estudos de experiências bem-sucedidas no ensino superior, no segmento da educação corporativa e no ensino tecnológico. Em alguns países, há bons estudos sobre o uso da IA em instituições educacionais, inclusive de educação básica (Zhai et al. 2021). Constata-se também que, embora a escola brasileira já esteja utilizando de soluções baseadas em IA, temos uma incipiente produção de pesquisa acadêmica, especialmente a que deveria ser produzida nas faculdades de educação, sobre o advento da IA como solução para a educação básica brasileira. A maior parte dos estudos de IA aplicados ao ensino no Brasil e no mundo provém de pesquisadores da ciência da computação (Lopes; Netto, 2020). Embora mais voltados para o ensino da computação e, em geral focados no ensino superior, esses estudos tornaram-se fundamentais nesta pesquisa, aproximando aplicações e resultados de IA ao contexto pedagógico geral e brasileiro.

No campo das técnicas de aprendizado de máquina e, especialmente, de redes neurais de aprendizado profundo, que impactaram o desenvolvimento recente da IA, existem bons estudos técnicos capazes de traduzir para o profissional de educação a concepção mais geral e o alcance dessas soluções, permitindo que o profissional possa construir uma visão mais clara e crítica sobre o potencial delas (Taulli, 2020). Há alguns estudos que buscam compreender as possibilidades de aplicação dessas tecnologias na escola. De modo geral, eles são descritivos e não apresentam evidências referentes ao impacto dessas aplicações, que ainda são raras e restritas (Holmes et al., 2019).

Por sua vez, as empresas desenvolvedoras ou fornecedoras de soluções educacionais baseadas em IA avançam mais rapidamente. Segundo estatísticas da Google, esse mercado atingirá um volume de U\$ 400 bilhões em 2025. Entretanto, a maioria dos desenvolvedores de IA comercial sabe pouco sobre a pesquisa em ciências da aprendizagem; na verdade, eles geralmente sabem pouco sobre aprender ou ensinar (Luckin, 2019).

No campo da apropriação pouco crítica, pelas escolas brasileiras de educação básica, de tecnologias aplicadas ao ensino em geral, há um robusto trabalho de pesquisa crítica que analisa desde a interpretação instrumental do papel da tecnologia pela escola sem o diálogo da escola com a cultura digital vigente, até o fenômeno da adoção indiscriminada de tecnologias inovadoras, como soluções para questões sem o devido debate pedagógico. São estudos de pesquisadores como Evgeny Morozov, Neil Selwin e Neil Postman (Morozov, 2013); (Selwin, 2016); Postman (1993), ampliados no Brasil por trabalhos como os dos professores Giselle Ferreira e Márcio Lemgruber, da PUC-RJ (Ferreira; Lemgruber, 2022), que discutem esse ímpeto acrítico de consumo digital, presente tanto na universidade quanto na educação básica.

As limitações na formação e na interação com as novas tecnologias digitais da maior parte dos professores brasileiros da educação básica, ou seja, sua deficiente fluência digital, comprometem sua conscientização e conseqüente protagonismo sobre o impacto da mediação digital na aprendizagem, na cultura, na comunicação, no comportamento, enfim em quase toda atividade humana. Comprometem, inclusive, as escolhas que o docente faz entre as múltiplas ofertas de artefatos e soluções digitais de apoio à aprendizagem e às atividades docentes. Isso produz uma atitude pouco crítica e fragilidades na gestão educacional frente ao mercado derivado do sistema escolar brasileiro, composto por um milhão de professores e mais de 50 milhões de alunos. Torna-se importante estimular mais pesquisas acadêmicas e mais investigação a ser feita pela própria escola, voltadas para a reflexão e a crítica do processo de apropriação das tecnologias digitais no âmbito escolar e seu diálogo com o currículo contemporâneo. Em uma perspectiva freiriana, o educador precisa estar à altura do seu tempo e é preciso que se criem mecanismos políticos que permitam que todos ganhem poder crítico e protagonismo sobre a produção e consumo das tecnologias.

Como consequência do quadro apresentado, há bastante desconhecimento escolar de como as técnicas de IA produzem soluções no campo educacional, acarretando como consequência tanto a hipervalorização de seu “poder” solucionador quanto sua demonização (Kaufman, 2022) como redutora do papel do professor. A entrada das plataformas de apoio ao ensino produzidas pelas *big techs*¹ impacta o equilíbrio precário entre os interesses públicos e privados, especialmente na rede pública. Assim, parece relevante produzir conhecimento acessível e claro para ajudar esse profissional da

¹educação a manter-se atualizado e consciente sobre o risco da evasão de dados e ao mesmo tempo e do potencial das técnicas de aprendizado de máquina, redes neurais de aprendizado profunda, que compõem a IA (Van Dijck, 2017).

2.2. Metodologia de pesquisa:

Quanto à abordagem, utilizou-se, ao longo de toda a dissertação, a pesquisa qualitativa a partir de investigação bibliográfica de autores de referência e de publicações acadêmicas, na busca de explicações dos fenômenos decorrentes do desenvolvimento deste campo de estudo. É na pesquisa qualitativa que se alcança um melhor enfoque na interpretação do objeto pesquisado e permite compreender a totalidade do fenômeno, analisando as informações narradas de uma forma organizada, ainda que intuitiva (Gerhardt, 2009; Gil, 2008). Sob o ponto de vista da natureza da pesquisa, especialmente no capítulo 2, optou-se pela pesquisa descritiva, usando análise documental e estudos de caso (Gerhardt, 2009). Finalmente, sob o ponto de vista dos procedimentos, esta dissertação, em toda a sua extensão, apresenta-se como uma pesquisa documental, utilizando-se de fontes constituídas por material já elaborado em livros, dissertações e principalmente artigos científicos.

Foram consultados cerca de 250 artigos ao longo de toda a pesquisa, extraídos de plataformas como *Google Scholar*, *Arxiv* e *ResearchGate*, observando-se particularmente a possibilidade desses artigos: a. abordarem os aspectos técnicos dos modelos de aprendizado de máquina e da IA de um modo claro para a compreensão dos não especialistas e b. estarem de algum modo conectados às perspectivas educacionais da aplicação desses modelos.

Além dos artigos e algumas dissertações produzidas por pesquisadores brasileiros (buscou-se esta ênfase para contribuir com o trabalho dos colegas, reconhecendo que a produção de conhecimento é um processo coletivo), há quatro obras que merecem ser citados pela sua abrangência e contribuição a este estudo, mencionadas a seguir.

1. *International Handbook of Metacognition and Learning Technologies* de Roger Azevedo e Vincent Alevén, publicado pela Springer em 2013. Este livro reúne diversos ensaios acadêmicos no campo da metacognição e ajudou a dissertação a apontar a metacognição como instrumento de análise de possíveis impactos da IA na aprendizagem.

¹ *Big Techs* é como são conhecidas as grandes empresas dominantes no mercado de tecnologia, tais como a Apple, a Google, a Amazon, a Meta, entre outras.

2. Educação e Tecnologia – abordagens críticas, organizado por Giselle Martins dos Santos Ferreira, Luíz Alexandre da Silva Rosado e Jaciara de Sá Carvalho, publicado pela Universidade Estácio de Sá em 2017. Aqui encontrei reunidos os principais autores da crítica às tecnologias de ensino que ajudaram a consolidar a leitura que a dissertação propõe para o preparo da escola frente ao advento da IA como instrumento pedagógico.
3. Building Intelligent Interactive Tutors, por Beverly Park Woolf, publicado em 2009 pela Elsevier. Os tutores inteligentes são a aproximação mais completa da IA nos processos educacionais, desde 1970. É imperativo que os conheçamos para podermos avaliar o impacto da IA.
4. Artificial Intelligence – a modern approach, por Stuart Russell e Peter Norvig, publicado em 2020 pela Pearson. A referência teórica mais presente em todas as dissertações lidas quando se trata de dissecar tecnicamente a IA.

2.3. Organização da Pesquisa:

O capítulo 1 apresenta inicialmente a trajetória do pesquisador e seu impacto na trajetória da própria pesquisa. Em seguida, as justificativas para entender o peso e as perspectivas da IA na pesquisa em tecnologias da educação.

No segundo capítulo, apresenta-se a estrutura da dissertação, as questões de estudo, o estado da arte no campo de estudo, a organização e a metodologia de trabalho.

O capítulo 3 da dissertação expõe, de um modo abrangente, o campo da IA, sua conceituação, que segue sendo objeto de divergência entre pesquisadores (Kaufman, 2022) e seu desenvolvimento histórico como campo experimental ao longo de 70 anos (o campo da inteligência artificial foi criado em 1956). Em seguida, são apresentados o subcampo da IA, denominado aprendizado de máquina, seus paradigmas de aprendizado e alguns dos modelos algorítmicos, com destaque aos modelos que serão úteis nos estudos de caso que serão citados no capítulo seguinte. O capítulo busca aproximar a conceituação técnica do funcionamento da IA do público educador brasileiro, na direção de uma das hipóteses centrais deste trabalho, em que a emancipação digital depende da fluência digital, e que esta se alcança não somente pela fluidez no uso, mas especialmente pela compreensão clara, pela familiaridade de uso e pela conscientização dos mecanismos de funcionamento, produção e distribuição da tecnologia em questão.

O capítulo 4 analisa estudos de caso, organizados a partir da perspectiva do usuário, aluno ou professor. São aplicações educacionais de IA, classificados por serem

centradas no aluno ou no professor, apresentadas com o apoio de evidências do uso de IA encontradas em diversas fontes. A pesquisa aprofunda a análise do impacto dessas aplicações - sistemas tutores inteligentes, grandes modelos de linguagem e sistemas de correção automática de redações - bem como os algoritmos que as definem, e procura apresentar e discutir modelos de uso possivelmente úteis da IA no ensino em geral. Seja nas aplicações centradas no aluno seja naquelas centradas no professor, o capítulo apresenta, ao final de cada estudo, uma segunda abordagem denominada de IA aprendiz. O estudo discute as oportunidades de se utilizar aprendizado de máquina no desenvolvimento metacognitivo dos estudantes, invertendo-se, de algum modo, os papéis, ou seja, colocando aluno e professor para “treinarem” as aplicações de IA (Kent, 2022).

Finalmente, o capítulo 5 busca ampliar o discernimento do educador e da instituição escolar em relação ao potencial das aplicações descritas anteriormente e as discussões que deveriam ser realizadas na escola visando à sua incorporação. Com base em experiência de quase 40 anos atuando no mercado escolar brasileiro, particularmente na interface da tecnologia com a didática e o currículo, a dissertação apresenta, com o apoio dos estudos da pedagogia crítica da aprendizagem via tecnologia, cenários de incorporação da tecnologia na escola que resultaram em relativo fracasso. O capítulo pretende estimular a reflexão sobre esse processo de incorporação das tecnologias digitais baseadas em IA na escola brasileira, a fim de tornar a escola e seus agentes mais capazes de avaliar criticamente a adoção da inteligência artificial.

3. CONHECENDO UM POUCO MELHOR A IA

3.1. Termos gerais da IA

Inicialmente, apresento um glossário básico para permitir que a terminologia adotada ao longo deste trabalho possa ser compreendida. Este glossário ajuda também a introduzir as temáticas que representam este campo de conhecimento: a inteligência artificial.

Algoritmo – uma fórmula ou uma sequência de regras (ou procedimentos, processos, instruções ou passos) para solucionar um problema ou executar uma tarefa. Em IA, o algoritmo leva a máquina a encontrar padrões nos dados lidos e, a partir deles, reconhecer as respostas a uma questão ou as soluções de um problema; o algoritmo é parte da linguagem matemática que permite a interação entre homem – máquina. Em aprendizado de máquina, os sistemas usam diferentes tipos de algoritmos. Os exemplos mais comuns são árvores de decisão, algoritmos de clustering, algoritmos de classificação e de regressão (Glossary JRC European Commission)

Aprendizado de máquina (AM) – subcampo da IA, criado em 1959, que foca no desenvolvimento de sistemas capazes de “aprender” a partir dos dados a resolver problemas sem ser explicitamente programados, ampliando gradualmente sua precisão, usando algoritmos e modelos estatísticos para analisar e inferir a partir de padrões nos dados (em inglês, *machine learning*).

Sistema Tutor Inteligente (STI)- o termo foi cunhado por Sleeman and Brown, em 1982, e representa o campo de estudo de aplicações digitais que podem proporcionar tutoria efetiva para cada estudante, sob medida para suas necessidades, seu ritmo de estudo, e seu estilo de aprendizagem (Nkambou et al.,2010).

Chatbot – Um programa de computador desenhado para simular uma conversação com um usuário humano, normalmente no ambiente digital; usado especialmente para fornecer informação ou assistência ao usuário como parte de um serviço automatizado.

Mineração de dados – processo computacional que extrai padrões analisando dados por diferentes perspectivas e dimensões, categorizando-os e resumindo relações e impactos potenciais.

Aprendizado profundo (DL) – é uma técnica de aprendizado de máquina baseado em redes neurais artificiais, cuja arquitetura utiliza-se de muitas camadas ocultas

para o treinamento destas redes. Vamos denominar estes métodos de Redes Neurais de Aprendizado Profundo (em inglês, *deep learning*).

Cluster - Coleção de pontos de dados agregados devido a certas semelhanças; os dados parecem ser reunidos em torno de um valor específico. Termo associado à segmentação de usuários nas redes sociais ou em qualquer outro processo de agregar usuários com perfis similares.

Inteligência Artificial Geral (IAG) – também denominada de IA forte, a IAG é a habilidade hipotética de que um sistema inteligente possa, com sucesso, compreender, aprender e performar qualquer tarefa intelectual que um ser humano desempenha. No estágio atual da IA, não existe evidência científica de que esse estágio de desenvolvimento será atingido.

Inteligência artificial estreita – conhecida como IA fraca ou restrita, contempla os sistemas de IA que permeiam a totalidade das implementações atuais em distintas tarefas, em distintos setores de atividade. São conhecidos como estreitos porque sua aplicação é restrita a um campo específico, não servindo para resolver problemas em campos distintos. Ex: uma aplicação de IA para análise de crédito.

Inteligência Artificial de propósito geral – ao contrário das aplicações de IA estreita, trata-se de sistemas de IA que podem ser usados em muitas aplicações, em vários campos, sem que haja necessidade de ajuste substancial. O ChatGPT poderia estar classificado nesta categoria e seu advento abre discussões profundas sobre a acurácia de sistemas que operam em campos tão diversos. Os sistemas de IA de propósito geral atuais são caracterizados pela sua escala (muita memória, muitos dados e um hardware potente) assim como sua confiabilidade no aprendizado por transferência (aplicando conhecimento de uma tarefa em outra).

IA preditiva - sistema baseado em IA que extrai padrões de dados existentes para fazer previsões. Impulsionado pelo desenvolvimento da técnica de redes neurais profundas, tem aplicações nos mais diversos campos do conhecimento. Ex: pré-seleção de currículos em processo de contratação pelo RH de grandes empresas.

IA generativa - sistema baseado em IA que, a partir de dados e modelos estatísticos, gera material artificial. Com os avanços das redes neurais profundas, a IA generativa gera, além de textos, imagens, vídeos, gráficos e áudios. Ex: ChatGPT e MidJourney. A IA preditiva e a generativa diferem-se pela arquitetura distinta.

Arquitetura de sistemas - “A arquitetura de software define o que é o sistema em termos de componentes computacionais e, os relacionamentos entre estes componentes, os

padrões que guiam a sua composição e restrições. Além da escolha dos algoritmos e estruturas de dados, a arquitetura envolve: decisões sobre as estruturas que formarão o sistema, controle, protocolos de comunicação, sincronização e acesso a dados, atribuição de funcionalidade a elementos do sistema, distribuição física dos elementos, escalabilidade, desempenho, e outros atributos de qualidade.”²

Processamento de Linguagem Natural (PLN) – baseia-se na combinação da ciência da computação com a linguística computacional, um campo interdisciplinar da linguagem humana, a fim de criar modelos com base em regras da fala humana ou em texto que podem ser utilizados por computadores. Isso permite que computadores processem e respondam de maneira adequada à linguagem humana. Essa tecnologia impulsiona a tradução por computador de uma língua para outra e a capacidade de resposta a comandos verbais por parte de tecnologias, como navegação por satélite ou assistentes de voz (Currículos de IA para a Educação Básica – Unesco).

Grandes modelos de linguagem – São modelos algorítmicos capazes de processar grande quantidade de textos e gerar respostas em linguagem natural a partir de inputs do usuário. Sistemas como o GPT-3 [1] fizeram avanços significativos no processamento de linguagem natural (PLN) em anos recentes. Esses modelos são treinados em grandes quantidades de dados de texto e são capazes de gerar texto semelhante aos produzidos pelo humano, responder perguntas e concluir outras tarefas relacionadas ao idioma com alta precisão (KASNECI et al., 2023).

A visão computacional (VC) - trata da extração de informações, da identificação e classificação de objetos contidos em imagens. Os sistemas de VC vêm sendo usados em reconhecimento de pessoas, de assinaturas, de objetos; inspeção de peças em linhas de montagem; orientação de robôs em indústrias automatizadas etc. O reconhecimento de imagens é uma área de estudo fundamental para a VC, uma vez que, é por meio dela que as imagens são processadas e transformadas em informações que podem ser mais facilmente interpretadas por um computador. Para tal, várias abordagens são adotadas, como extração dos padrões de cor, extração dos padrões de textura, detecção de formas e bordas, dentre outras.

Realidade aumentada – um sistema que suplementa o mundo real com objetos virtuais (produzidos por computador) que parecem coexistir no espaço do mundo real,

² Disponível em https://www.cin.ufpe.br/~gta/rup-vc/core.base_rup/guidances/concepts/software_architecture_4269A354.html Acesso em 11 dez. 2023

combinados os objetos virtuais com os reais (por exemplo, possibilidade de experimentar roupas virtualmente no corpo real, ou visualizar o interior de um imóvel sem estar nele).

Big data – são grandes volumes de dados que passam a ser armazenados digitalmente à partir da proliferação da computação distribuída e das plataformas sociais. A inteligência analítica permite o uso destes grandes e diversificados conjuntos de dados em análise preditiva para entender padrões, tendências e comportamentos. O *big data* estabelece correlações entre os dados (e não causalidades) (Kaufman, 2022)

Ciência de dados – em inglês, *data science*, campo de conhecimento multidisciplinar sobre processos e sistemas para transformar dados em informações; combina a estatística com aprendizado de máquina e tecnologias de bases de dados para responder ao desafio que o *big data* apresenta (Cavique, 2014 apud Gonsales, 2022)

Learning analytics – coleta, medição e análise apurada de grandes quantidades de dados educacionais, recolhidos das plataformas de apoio ao ensino, no intuito de embasar a tomada de decisões pedagógicas e administrativas. É a ciência de dados aplicada ao campo educacional. (Isotani; Bittencourt, 2019 apud Gonsales, 2022).

3.2. Discutindo inteligência de máquina – podem as máquinas pensar?

As tentativas de definir com clareza o conceito de inteligência e a discussão sobre a possibilidade e os meios de reproduzir habilidades do cérebro biológico em máquinas nos acompanha há décadas e ainda apresenta poucos sinais de consenso e efetivos resultados. Muitos pesquisadores, como Floridi, afirmam que ainda seguimos inspirados pelas premissas iniciais de McCarthy, Marvin Minsky, Nathaniel Rochester e Claude Shannon, que, em 1956, no seminal documento produzido em Dartmouth³, definiram pela primeira vez o campo da IA: “para o presente propósito, o problema da inteligência artificial é considerado o de fazer uma máquina se comportar de maneiras que seriam chamadas de inteligentes se um humano estivesse se comportando assim” (McCarthy et al. 1955). Entretanto, isto é contrafactual, “só porque uma máquina de lavar louça lava a louça tão bem quanto (ou até melhor do que) eu posso fazer não significa que limpe como eu, ou precise de alguma inteligência para realizar sua tarefa” (Floridi, 2020). A mesma

³ Em Dartmouth Colagem nos EUA, aconteceu, em 1956, uma conferência de verão, reunindo vários pesquisadores, convocados por John McCarthy, que cunhou para a conferência o termo Inteligência Artificial (Gonsales, 2022).

compreensão contrafactual da máquina inteligente está por trás do teste de Turing que verifica a capacidade de uma máquina executar uma tarefa de forma que o resultado seja indistinguível do resultado de um agente humano trabalhando para realizar a mesma tarefa (Turing, 1950).

“Se fossemos capazes de ter uma atitude assim, esse comportamento seria considerado inteligente. Isso não significa que a máquina seja inteligente, ou mesmo que pense por si. Uma máquina pensar de modo autônomo é uma falácia. Devemos tratar a IA como um reservatório de agência inteligente disponível, ou seja, um crescente recurso de agenciamento capaz de aprender de modo autônomo e interativo, que pode lidar com tarefas que requereriam intervenção e inteligência humana para serem executadas com sucesso.” (Floridi, 2019, p.2)

Santaella rebate dizendo:

Ora, aquilo que Floridi chama de agência sem inteligência, não passa de ação eficiente despida de ação inteligente. Transposto para o ChatGPT, ele não passaria de um executor despropositado, mais desgovernado do que uma barata sob ação de Rodox. Esse está muitíssimo longe de ser o caso. Um caso que não é outro a não ser reconhecer que operações estatísticas são operações inteligentes de que a IA se alimenta. Tudo isso vem demonstrar que, para compreender a IA e o ChatGPT em suas próprias medidas, sem impor sobre eles parâmetros tipicamente humanos, ambos apresentam agenciamentos que não dispensam a ação propositada que é ação inteligente. (Santaella, 2023)

Turing produz, entre 1940 e 1950, equipamentos e ensaios que impulsionam a computação e estimulam especialmente os matemáticos a reconhecerem o potencial da computação para compreendermos melhor como funciona nosso cérebro - “a nossa maquinaria” (Minsky, 1996, *apud* Cooper, 2013, p.526). Isso abriu um novo campo de pesquisa, aproximando a filosofia, a psicologia, a engenharia e a matemática no desenvolvimento de uma ciência abrangente com grande impacto no avanço tecnológico posterior. (Cooper, 2013). No filme *O jogo da imitação*⁴, Turing afirma que não devemos

⁴ Filme de 2014, disponível na plataforma de streaming NetFlix, baseado na obra *Alain Turing: The Enigma* de Andrew Hodges.

perguntar se uma máquina pode pensar como um ser humano, mas sim questionarmos se, quando algo pensa diferente de nós, isso significa que não está pensando.

Churchland (1990, *apud* Bachinski, 2015, p. 167) insiste que não há por que não imaginar ser possível que a ciência siga buscando construir uma inteligência artificial explorando o que se descobre sobre o sistema nervoso humano. Segundo ele, deve-se reconhecer que certas estratégias computacionais têm vantagens importantes sobre outras tarefas cognitivas típicas e que talvez seja mais adequado assumir que se trata de outra forma de cognição, distinta da cognição do cérebro humano. Pollack adiciona mais um questionamento nesse dilema, afirmando que:

“Devido a esta preocupação em imitar a inteligência de nível humano, como campo científico, ignoramos ou excluímos as contribuições de muitos mecanismos não simbólicos. Tais mecanismos vão desde modelos associativos e matriciais da psicologia matemática, aos modelos Markovianos, às teorias de jogos e de decisão, até o início redes neurais, para simulações de evolução e auto-organização orgânica.... Por que simular a mente humana é mais importante do que simular o metabolismo celular, a inteligência de insetos ou animais, a formação de padrões complexos ou o controle distribuído de ecossistemas complexos?” (Pollack, 2006, p.51).

Há, segundo Kaufman, dois atributos na cognição humana que os cientistas não sabem como incorporar nos sistemas de IA: a causalidade e o raciocínio contrafactual. As técnicas de IA estabelecem correlações entre os parâmetros de grandes bases de dados, mas não conseguem aferir a causa dessas correlações. “Um módulo de raciocínio causal daria às máquinas a capacidade de refletir sobre seus erros, identificar pontos fracos em seu software, funcionar como entidades morais e conversar naturalmente com humanos sobre suas próprias escolhas e intenções” (Pearl, 2018 *apud* Kaufman, 2022).

O debate sobre se a consciência distingue humanos de máquinas prolifera tanto nos meios acadêmicos como entre pensadores e criadores de tecnologia é dominado por duas posições opostas: o naturalismo biológico, que afirma que a capacidade de ser consciente é exclusiva dos organismos biológicos, e o otimismo tecnológico, que reconhece a capacidade dos sistemas computacionais sofisticados de serem conscientes (Searle, 1983)

Searle afirma que mesmo que um computador passasse no teste de Turing, ele ainda assim não pensa, pois lhe falta a capacidade causal do cérebro humano de produzir

intencionalidade, que é um fenômeno biológico. Searle propõe o argumento do *quarto chinês* para questionar a capacidade de que computadores possam produzir estados mentais genuinamente humanos, ou seja, pensar. Essa experiência que Searle propõe visa evidenciar que o computador pode executar precisamente um programa específico sem qualquer evidência cognitiva relevante. Searle imagina-se falante de uma língua qualquer, num quarto fechado, com um programa de computador que lhe permite decifrar ideogramas do chinês (língua que ele não fala nem compreende), recebendo questões em chinês por baixo da porta e usando o algoritmo para devolver respostas adequadas, também em chinês, às perguntas recebidas, sem compreender em absoluto o que significavam as perguntas ou as respostas. (Searle, 1983).

Símbolos formais, por eles somente, não podem nunca ser o bastante para os conteúdos mentais, porque os símbolos, por definição, não têm significado (ou interpretação, ou semântica), exceto na medida em que alguém, fora do sistema, lhes dá. (Searle, 1980 apud Bachinski, 2015, p.160)

A lição geral extraída é que qualquer sistema que meramente manipule símbolos físicos de acordo com regras sensíveis às estruturas será, na melhor das hipóteses, uma imitação vazia da inteligência consciente real, porque é impossível gerar “uma semântica real” apenas operando uma “sintaxe vazia” (Churchland, 1990 apud Bachinski, 2015, p. 160).

O lançamento do *ChatGPT* coincidiu com o início da escrita desta dissertação. O *chatbot*, do grupo dos grandes modelos de linguagem (LLM), usa técnicas de redes neurais profundas para encontrar padrões em grandes conjuntos de textos e relaciona-os com as perguntas e os diálogos interpretados, gerando respostas. Foi desenvolvido pelo laboratório de pesquisa *OpenAI* e disponibilizado à experimentação pública em 30 de novembro de 2022. Passamos, pela primeira vez, a consumir uma IA que não só prediz mas gera conteúdo, sempre a partir da análise de dados. O advento do *ChatGPT* aproxima a IA do grande público ao permitir interação por meio de diálogo, ou seja, inova ao propor uma solução com interface baseada em linguagem natural - elemento chave na comunicação humana, que nos distingue das demais espécies. Imaginemos nossas pesquisas, indagações e produções, que podem agora ser apoiadas pelo ChatGPT. As respostas oferecidas pelo *chatbot* parecem, por vezes, tão razoáveis e humanas que poderiam nos levar a confundí-las com “intervenções conscientes” quando são somente

arranjos probabilísticos de conceitos, palavras ou frases encontradas em sua base de dados. Iremos apresentar com mais profundidade esta aplicação de IA generativa e alguns de seus impactos na educação no capítulo seguinte.

Refletindo, enfim, sobre as dezenas de definições de IA indicadas por pesquisadores, Wang (1995) e Troshani (2020) apontam para o fato de que a escolha da definição, a abordagem para se explicar a IA influencia fortemente os rumos da pesquisa, do desenvolvimento de soluções baseadas nesta tecnologia e do impacto sobre os processos em que for utilizada. A antropomorfização da IA, ou seja, atribuir-se características humanas a sistemas ou máquinas, por exemplo, quando denominamos de inteligentes os sistemas que utilizam aprendizado de máquina, impacta na maneira como consumidores confiam, reagem e consomem, enfim, produtos baseados em IA (Troshani, 2020).

Embora tenha sido aconselhado pela professora Santaella a evitar o risco de discutir algo tão complexo como inteligência:

Nega-se a inteligência às máquinas como se todos soubessem o que é inteligência. Conclusão, as pessoas tomam a si mesmas e outros seres humanos que conhecem como modelos de inteligência, de resto, uma ideia que, na realidade, não se enquadra na noção de modelo, pois não passa de intuição muito vaga do que é inteligência. Acrescenta-se a isso o fato de que muitas vezes podemos estar erroneamente certos de nossas intuições. (Santaella, 2022)

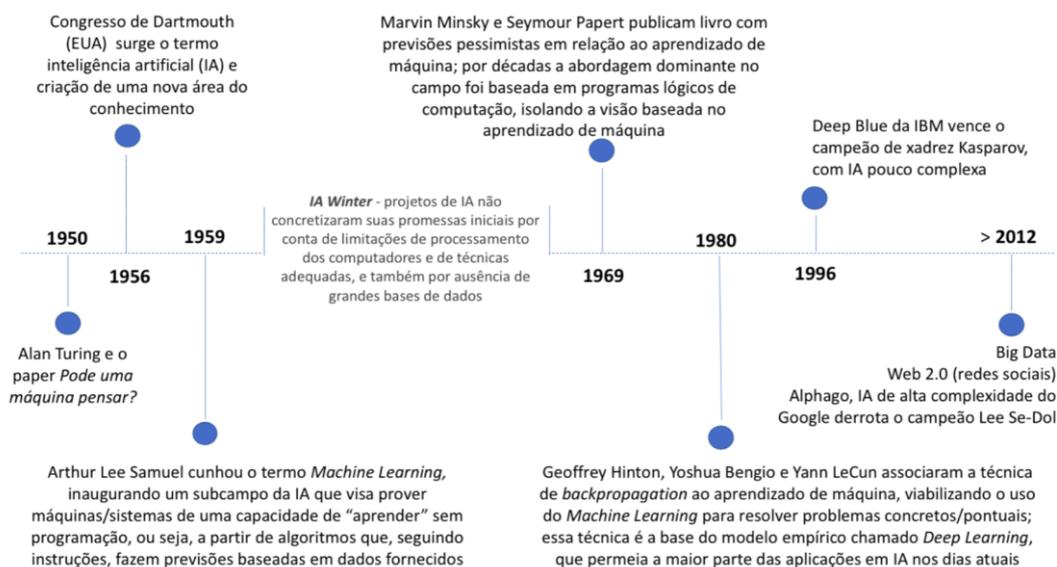
Vamos adotar, nesta dissertação, o conceito de inteligência de máquina estabelecido por Wang (1995): “Inteligência é a capacidade de um sistema de processamento de informações de se adaptar ao seu ambiente enquanto opera com conhecimento e recursos insuficientes” (Wang, 1995). Um sistema pode ou não se modificar (adaptando-se) ao admitir alguma limitação de recursos para responder ao desafio do ambiente. Segundo Wang (1995), é “ao modificar-se que um sistema poderia ser chamado de um sistema inteligente”.

Adiciono mais um elemento a essa conceituação, reiterando a afirmação de Floridi que sugere tratarmos a IA como um reservatório de agência inteligente disponível. Devemos levar em conta, conforme cita Lemos, que toda obra humana passa pelo uso, como parceiro, de algum dispositivo artificial. O humano sem artefatos não existe. É

nessa parceria que acredito que a inteligência artificial, como muitas das tecnologias digitais, potencializa nossa inteligência (Lemos 2023)⁵.

3.3. A história do desenvolvimento da IA:

Figura 1 – Eventos relacionados à evolução do campo de estudo da IA



Fonte: GONSALES, Priscila, *Inteligência Artificial, educação e pensamento complexo*, 2022

Ao longo destes 70 anos, um importante conjunto de conhecimentos científicos acompanhou o desenvolvimento da IA e a viabilizou. Segundo Norvig and Russel (2014), o desenvolvimento da IA recebe a contribuição de diversas áreas, como a filosofia, a matemática, a economia, a biologia, a neurociência, a genética, a psicologia, a engenharia da computação, a linguística e a cibernética. Na figura 1, apresentam-se alguns dos marcos mais importantes nesse desenvolvimento, que obteve pouco êxito inicial, segundo Gonsales e Kaufman, fruto de diversas limitações (conceitual, tecnológica, computacional), gerando ceticismo sobre as possibilidades dessa tecnologia e, consequentemente, redução significativa no volume de financiamento a pesquisas em IA. Foi a partir de 1980, com a técnica das redes neurais de aprendizado profundo (cuja explicação virá mais adiante neste capítulo), que se ampliaram as perspectivas reais de

⁵ <https://andrelemos.substack.com/p/frankenstein> Acesso em 09 dez. 2023

aplicação da IA, embora tendo alcançado reconhecimento da academia e do mercado efetivamente em 2012, como explicam as pesquisadoras:

Sua proeminência atual ocorre em função de dois fatores principais. O primeiro está diretamente ligado aos resultados positivos da técnica de aprendizado de máquina, denominada redes neurais profundas (*deep learning*). O segundo fator envolve duas variáveis: a) a gigantesca disponibilidade de dados digitais, o *Big Data*, termo utilizado para nomear grandes conjuntos de dados não estruturados (imagens, textos, transações, geolocalização, ... dentre outros) que necessitam de sistemas de IA (algoritmos de IA) para encontrar, analisar e aproveitar as informações geradas nas interações com os meios e/ou os dispositivos digitais; e b) a maior capacidade de processamento dos computadores, particularmente com o advento das GPUs (*Graphics Processing units*) (Gonsales; Kaufman, 2022)

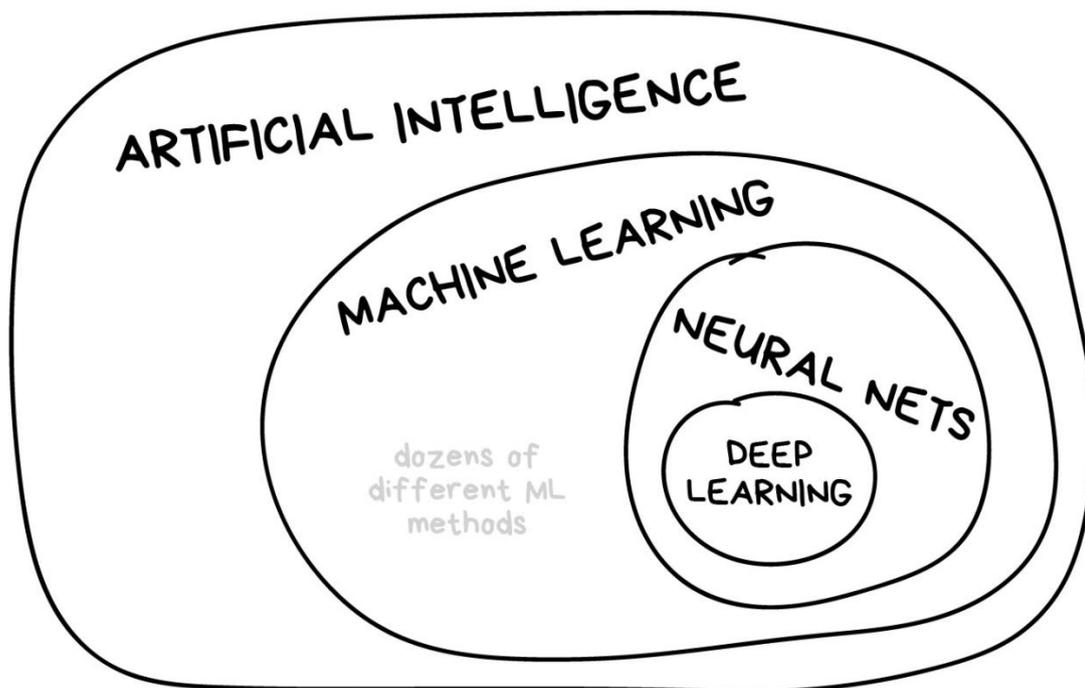
Pedro Domingos (2017) organiza de um modo original o modo como a IA foi se reconfigurando ao longo destes 70 anos: ele nomeia cinco abordagens que foram se aprimorando, predominando e evoluindo: os *conexionistas*, os *evolutivos*, os *analíticos*, os *bayesianos* e os *simbolistas*. Os *simbolistas* acreditam que a inteligência pode ser reduzida à manipulação de símbolos. Eles dominaram as primeiras décadas (1940 – 1970) da psicologia cognitiva. Os *conexionistas*, que assumem protagonismo na década de 1980, simulam o funcionamento do cérebro biológico, que aprende modificando a intensidade das conexões (sinapses), que acontecem entre os neurônios (Pohl, 2019). Os *evolucionistas* simulam a seleção natural usando algoritmos genéticos. A ideia evolucionista é criar várias soluções alternativas e combinar partes das melhores alternativas para otimizar o algoritmo que aprende. Os *analogistas* procuram similaridades entre situações distintas buscando padrões naquilo que precisa ser resolvido rapidamente. Quanto mais os dados apresentam falhas ou há mais incerteza, mais os analogistas podem ajudar. Finalmente os *bayesianos*, que se baseiam na inferência probabilística para superar a incerteza. Os modelos bayesianos estão em evidência pela explicabilidade e pelos modelos que reduzem o “ruído” dos dados, retirando características estatisticamente menos relevantes para a solução do problema.

Domingos (2017) afirma que estamos ainda na infância das capacidades de aprendizado de máquina e salienta que um algoritmo mestre que leve o aprendizado de máquina a um nível de Inteligência Geral Artificial (AGI) exigirá a integração das distintas abordagens seguidas pelos *conexionistas*, *evolucionistas*, *bayesianos*,

analogistas e simbolistas (Pohl, 2019). Veremos, a seguir, como funcionam, de modo geral, as técnicas de aprendizado de máquina, subcampo central da IA, para compreender melhor essa tecnologia.

3.4. Como as máquinas “aprendem” - o aprendizado de máquina (AM)

Figura 2 - Inteligência artificial e subáreas



Fonte: <https://tinyurl.com/2s3cmfj8>

A inteligência artificial é o campo de conhecimento, conforme figura 2, o aprendizado de máquina é um subcampo da IA e entre suas técnicas, estão as redes neurais e o aprendizado profundo. Aprendizado de máquina (AM) é o subcampo de estudo que permite aos computadores a capacidade de aprenderem sem serem explicitamente programados; o algoritmo aprende com os dados e pode tomar decisões e lidar com situações que o programador não previu (Samuel, 1983). Samuel já reconhecia, em 1959, que a ciência da computação deveria buscar resolver o problema de que computadores, então, não aprendiam com a própria experiência.

Essa busca, segundo Samuel, resulta em um desenvolvimento do aprendizado de máquina e das redes neurais, que, 25 anos depois, em 1983, com o avanço das pesquisas, especialmente as produzidas por Yoshua Bengio, Geoffrey Hinton e Yan Lecunn, permitiu que o computador se tornasse um instrumento muito mais útil. “O aprendizado de

máquina é a única abordagem viável para a construção de sistemas de IA que podem operar em ambientes complicados do mundo real (Hinton, 2019). Para Wu (2022), o desenvolvimento das redes neurais de aprendizado profundo, uma das técnicas de aprendizado de máquina, aplicada a tarefas de visão computacional e processamento de linguagem natural, impulsiona o desenvolvimento exponencial do campo da IA (Wu, 2022).

Como explica Kaufman (2019, p. 25), “o atual crescimento exponencial dos dados inviabiliza o uso da tradicional programação computacional”. A figura 3 apresenta a diferença entre a programação convencional e o aprendizado de máquina. Todo algoritmo tem entradas (dados) e saídas (resultados ou respostas). Na programação convencional, segundo Wang, delimita-se o problema a ser processado para que o conhecimento e os recursos disponíveis possam resolver o problema. As regras, o escopo e as variáveis são estabelecidos a priori no algoritmo que precisa ser reprogramado para atuar em situações distintas das pré-estabelecidas. O aprendizado de máquina inverte isso: entram os dados e o resultado desejado e sai o algoritmo que transforma um no outro, criando as regras a partir dos dados. Com o aprendizado de máquina, os computadores escrevem seus próprios programas (Domingos, 2017)

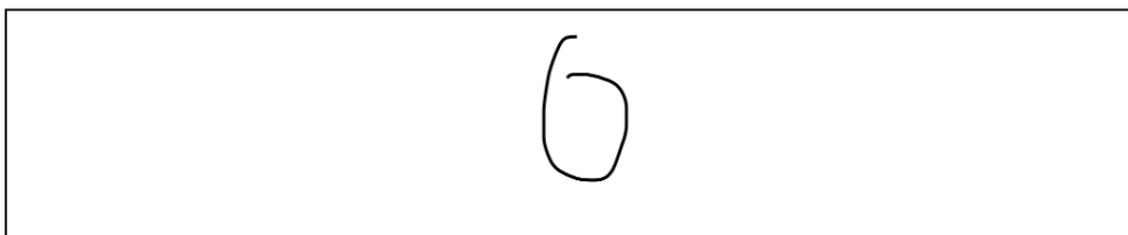
Figura 3 – Programação convencional e aprendizado de máquina



Fonte: <https://tinyurl.com/4y9x9k43>

O reconhecimento de imagens e o processamento de linguagem natural, por exemplo, são complexos demais para serem resolvidos por programação clássica, em que é preciso definir antecipadamente o escopo e as regras que o computador deve utilizar para resolver cada problema. É aqui que o aprendizado de máquina ganha sentido (Pohl, 2019). Um exemplo é a interpretação de texto manuscrito, usando reconhecimento de imagem (figura 4).

Figura 4 – reconhecimento de imagem manuscrita

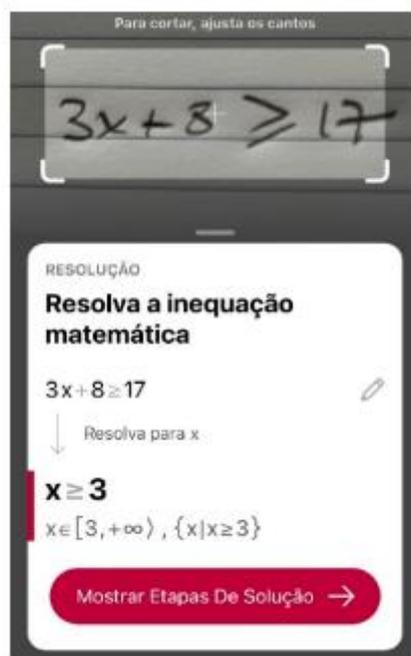


Fonte: <https://tinyurl.com/yc7npr84>

O manuscrito da figura 4 poderia ser lido como o número seis ou como zero. Não sabemos exatamente como nosso cérebro interpreta esses símbolos e distingue-os. Não temos como então produzir um algoritmo que reconheça qualquer traçado humano e permita que o computador resolva essa questão. Na abordagem de aprendizado de máquina, propõe-se que o computador seja submetido a milhares de exemplos e aprenda com eles a reconhecer, por exemplo, símbolos como o zero acima. Estatisticamente, vamos treinando a máquina a reconhecer (quase) todas as possibilidades de humanos manuscureverem zeros. Mas o quase dessa abordagem ainda traz problemas. Mesmo tendo interpretado milhões de símbolos, não podemos afirmar que, ao ler um novo símbolo semelhante, ele o faça corretamente (Pohl, 2019). O desenvolvimento de técnicas como as redes neurais e o aprendizado profundo, associado ao grande poder de processamento disponível, torna os algoritmos capazes de processar milhões de parâmetros simultaneamente e mitigar gradualmente essas incertezas.

Uma aplicação educacional de reconhecimento de imagem, usando aprendizado de máquina, aparece no aplicativo desenvolvido para smartphone chamado Photomath. Quando apresentado à inequação $3x + 8 \geq 17$, manuscrita em um papel, o aplicativo digitaliza a imagem fotografada pela câmera do smartphone, reconhece a inequação manuscrita (reconhecimento de imagem) e apresenta sua resolução passo-a-passo.

Figura 5: Tela do aplicativo Photomath



Fonte: foto do autor

O *Photomath* é um *bot* que utiliza técnicas de visão computacional e realidade aumentada e, segundo o CEO da empresa desenvolvedora, a MicroBlink, apoia-se em uma equipe de revisores que treinam o algoritmo com milhares de problemas e suas soluções iniciais. O aplicativo também reconhece problemas que não têm solução na sua base de dados e direciona-os para que os anotadores os solucionem e ampliem a base de dados (Saundarajan *et al.*, 2020). Dificilmente uma equação ou problema manuscrito devidamente reconhecido terá uma solução equivocada, mas há alguma incerteza se todos os manuscritos serão identificados corretamente.

3.5. Da IA preditiva para a generativa

A IA preditiva, como essa do exemplo acima, treinada para ler zeros manuscritos para prever, com alto grau de precisão, que um novo zero manuscrito nunca lido por ela é efetivamente um zero, tem inúmeras aplicações. Nos sistemas de recomendação das

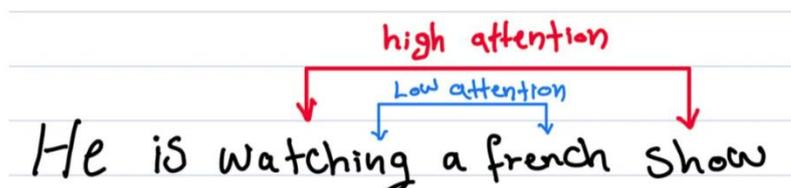
plataformas de streaming, em que o algoritmo, a partir dos padrões de consumo, prediz novos conteúdos, nas redes sociais, onde novamente a partir dos padrões de likes e tempos de consumo de conteúdo, o algoritmo propõe marketing direcionado, na previsão do tempo, quando os padrões do passado aumentam a precisão das previsões futuras, no mercado financeiro, nas operações de crédito, na escolha de peças jurídicas para petições e embargos, na escolha de rotas para economia de combustível etc. As predições são baseadas em padrões obtidos de enormes bases de dados, treinamento do algoritmo e muito processamento.

A nova perspectiva, embora haja evidências de pesquisa e aplicações experimentais desde 1980 (Hinton, 2019), é a IA generativa, cuja manifestação mais impactante vem dos grandes modelos de linguagem (LLM) representados pelo seu produto mais popular, o ChatGPT, lançado em 30 de novembro de 2022 pela OpenAI. Ao contrário da IA preditiva, a generativa pode criar conteúdo original. Baseado na arquitetura Transformer (a sigla GPT significa Generative Pre-trained Transformer), utiliza enormes bases de conteúdo digital disponível, com técnicas de PLN, para processar e produzir textos, a partir de prompts do usuário, por meio da linguagem natural em diversas línguas, criar poemas, gerar código e exibir criatividade em escrever desde um parágrafo até um extenso artigo científico convincente (ou quase) em diversas áreas do conhecimento. Processando até 100 trilhões de parâmetros (cada letra de cada frase de cada texto é um parâmetro processável), ele foi desenhado para gerar textos a partir de propostas ou perguntas (prompts) dadas pelo usuário. Também é capaz de evoluir no diálogo apropriando-se das etapas anteriores da conversa. O GPT4, assim com o BART (do Google), são os mais conhecidos grandes modelos de linguagem (LLM) (Wei, 2022).

A arquitetura do *Transformer*, operacional desde 2017, avança em relação a arquiteturas anteriores, as redes neurais recorrentes (RNN) e as CNNs – redes neurais convolucionais, que são muito usadas ainda para reconhecimento de imagem e voz, mas que, no processamento de texto, operam palavra por palavra, na sequência que ela aparece na sentença. O *Transformer*, cujo nome se deve à transformação, baseada em álgebra linear, de palavras e frases em vetores (matrizes unidimensionais) pode “ler” (processar) até 25.000 palavras de uma só vez. Depois de treinado com um corpus (uma grande base de textos selecionados), consegue capturar o relacionamento entre as palavras da sentença para dar mais “atenção” (o mecanismo, específico da arquitetura *Transformer*, é conhecido por *self-attention*) aos termos centrais, mais importantes para a análise dos

textos. Por relacionamento compreende-se a atribuição matemática de valor mais alto às palavras que frequentemente aparecem associadas (Han, 2021).

Figura 6 – Modelo de interpretação textual - Transformer



Fonte: <https://tinyurl.com/2xtzttw7>

Como vemos na figura 6, o treinamento do algoritmo atribui valores maiores às palavras mais relevantes no contexto - além dos pronomes e dos artigos, pouco relevantes aqui, o relacionamento *watching show* é mais relevante do que o *watching french* e assim se atribui mais valor a essa relação, facilitando sua classificação para a construção de padrões que serão úteis na busca por respostas aos prompts do usuário. O modelo, devidamente treinado, aprende (atribuindo valores as correlações) estruturas de diferentes gêneros, regras gramaticais e sinônimos, entre outras características linguísticas. Esse aprendizado está na base da devolução, ou seja, na geração do texto-resposta ao pedido do usuário. A partir dos padrões aprendidos, usando uma técnica chamada autorregressão, o algoritmo gera cada nova palavra baseada nas palavras que foram geradas anteriormente, buscando similaridade nas ocorrências já processadas (Vaswani, 2017).

Exemplificando o modo como o modelo é treinado para se apropriar dos padrões do gênero, das ocorrências gramaticais e estruturais da escrita e produz textos “originais” temos, nas figuras 7a, 7b, 7c e 7d), a geração de textos baseados na interação do modelo com o livro “Guerra e Paz” de Tolstói⁶.

Depois de 100 iterações (com o algoritmo processando o livro completo), quando pedimos que ele escreva um trecho baseado no que processou de Tolstói, ele devolve isso (Karpathy, 2015):

⁶ No blog <https://karpathy.github.io/2015/05/21/rnn-effectiveness/> encontra-se um resumo técnico acessível ao modo como as redes neurais recorrentes (RNN) atuam e os autores utilizam o treinamento do algoritmo na obra de Tolstói para demonstrar o modo como o algoritmo vai reconhecendo os padrões da escrita do autor.

Figura 7a– Iteração sobre texto Tolstói

```
tyntd-iafhatawiaoihrdemot lytdws e ,tfti, astai f ogoh eoase rrranbyne 'nhthnee e
plia tklrqd t o idoe ns,smtt h ne etie h,hregtrs nigtkie,aoaenns lng
```

Fonte: <https://karpathy.github.io/2015/05/21/rnn-effectiveness/>

Sem pontuação e sem nenhum sentido. Depois de 300 iterações com o livro, o modelo começa a aprender a pontuação e o espaçamento entre as palavras, ...

Figura 7b – Iteração sobre texto Tolstói

```
"Tmont thithey" fomesscerliund
Keushey. Thom here
sheulke, ammerenith ol sivh I lalterthend Bleipile shuwv fil on aseterlome
coaniogennc Phe lism thond hon at. MeiDimorotion in ther thize."
```

Fonte: <https://karpathy.github.io/2015/05/21/rnn-effectiveness/>

Depois 500 iterações, o texto começa a fazer sentido, as palavras mais comuns começam a aparecer.

Figura 7c – Iteração sobre texto Tolstói

```
we counter. He stutn co des. His stanted out one ofler that concossions and was
to gearang reay Jotrets and with fre colt ofp paitt thin wall. Which das stimn
```

Fonte: <https://karpathy.github.io/2015/05/21/rnn-effectiveness/>

E finalmente, após 700 iterações, o texto começa a parecer ser Tolstói.

Figura 7d – Iteração sobre texto Tolstói

```
Aftair fall unsuch that the hall for Prince Velzonski's that me of
her hearly, and behs to so arwage fiving were to it beloge, pavu say falling misfort
how, and Gogition is so overelical and ofter.
```

Fonte: <https://karpathy.github.io/2015/05/21/rnn-effectiveness/>

Os grandes modelos de linguagem apresentam diversos desafios. A maior dificuldade, em função dos diversos métodos e da simultaneidade e do tamanho do corpus do modelo, é a de identificar os caminhos das decisões tomadas pelo algoritmo. Isso redundará em dúvidas na acurácia nos dados de controle, na veracidade das fontes usadas

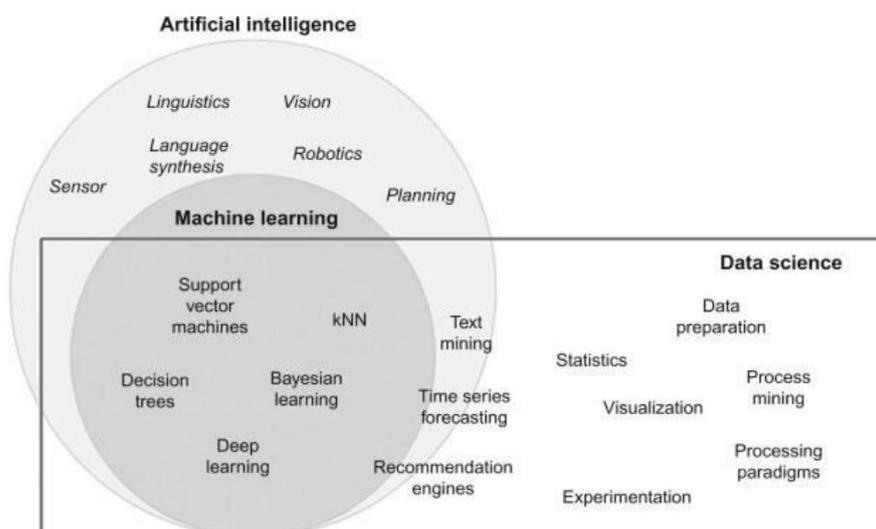
na comparação de dados, na dificuldade do modelo em compreender as idiossincrasias semânticas presente nos prompts de cada usuário, entre outras fragilidades do modelo. Professores devem manter-se atentos ao uso desses modelos pelos alunos, pois, embora cada vez mais produzindo informação precisa e relevante, ainda tem muito para evoluir (Kasneci, 2023).

3.6. Ciência de dados – evolução e impacto.

Veremos a importância dos dados, na sua qualidade e no tratamento, para o resultado das análises preditivas ou generativas da IA. Jim Gray, vencedor do *Turing Award*⁷ preconizou, em 2007, a separação da ciência de dados da ciência da computação, indicando que os métodos e os processos de pesquisa deveriam ser revistos diante do fenômeno do *big data*. O avanço na digitalização dos processos, da coleta massiva de dados, do armazenamento e da computação em nuvem catalisou essa nova ciência, um campo de estudo sistemático sobre a organização, as propriedades e a análise dos dados e seu papel na inferência de resultados, incluindo nossa confiança nessa inferência (Elshawi, 2017; Dhar, 2013). A mineração de dados, ou seja, a extração de informação útil e relevante de grandes bancos de dados, é resultado das técnicas da computação, da estatística, do aprendizado de máquina e da IA, das teorias de banco de dados e do reconhecimento de padrões (Kotu, 2018), conforme a figura 8.

⁷ Prêmio conhecido como o Nobel da ciência da computação

Figura 8 – intersecção entre os campos da ciência de dados, inteligência artificial e aprendizado de máquina



Fonte: <https://www.sciencedirect.com/topics/mathematics/sub-field>

O processo de extração de informação a partir dos dados é iterativo. Trata-se de procedimento não linear, com muitos *loops*⁸, com avanços e recuos entre cada etapa. No quadro 1, as etapas críticas para o processo de mineração de dados (Kotu, 2018).

Conhecimento prévio	Se refere a informação que já se tem sobre o tema. O problema, em ciência de dados, não acontece de forma isolada. Qual o contexto em que os dados são gerados e precisam ser analisados?
Preparação de dados	É a parte que mais consome tempo no processo. Raramente os dados estão no formato requerido para serem analisados pelos algoritmos. Organizá-los em tabelas, dar-lhes os atributos necessários, retirar redundâncias e convertê-los ao mesmo padrão são partes desta etapa;
Modelagem dos dados	O modelo é uma representação abstrata dos dados. Nesta etapa planeja-se toda a ação, desde o preparo até a validação.
Aplicação	É quando se coloca em produção o modelo desenhado na etapa anterior, e se avalia o resultado, apurando o modelo e integrando a análise no processo de trabalho com aqueles dados.

⁸ repetições

Conhecimento	O processo de ciência de dados parte do conhecimento prévio e finaliza com o conhecimento posterior, trazendo algum insight incremental sobre o contexto em relação ao que se conhecia antes do tratamento.
---------------------	---

Quadro 1 – Etapas do processo de mineração de dados (*data mining*), elaboração do autor.

No campo da educação, a ciência de dados se denomina de *Learning Analytics* e aparece nos painéis e relatórios de trabalho nas diferentes plataformas utilizadas em escolas e universidades.

3.7. Paradigmas de aprendizado de máquina:

Os avanços da ciência de dados permitiram mais conquistas na predição e geração de resultados na IA. Ela transforma dados em estudo bruto em compreensão, insight e conhecimento (Wickham et al., 2023). Os dados, sejam eles estruturados (aqueles que já estão organizados em tabelas, listas ou planilhas eletrônicas) ou não (textos ou imagens da internet e da web, por exemplo), precisam ser preparados, selecionados, reduzidos, organizados para serem processados pelos algoritmos.

Há vários tipos de aprendizagem dos algoritmos em sistemas de IA. É preciso olhar para os dados e para o feedback que o algoritmo terá. Essa combinação entre o tipo de dado e o feedback disponível produzirá alguns tipos distintos de aprendizado de máquina (Russel; Norvig, 2014).

Figura 9 – Tipos de aprendizado de máquina



Fonte: <https://tinyurl.com/3yh2385h>

São três os principais tipos de aprendizado de máquina: o supervisionado, o não supervisionado e o aprendizado por reforço. Na figura 9, temos exemplos de aplicações que se utilizam de cada um deles (Russel; Norvig, 2014).

3.7.1 O aprendizado supervisionado

O *aprendizado supervisionado* é aquele que produz previsões baseadas na rotulagem humana dos dados, viável quando há recursos financeiros e boa quantidade de dados com resultados concretos para serem rotulados ou quando as saídas do sistema (os outputs) são conhecidas. Esses outputs então alimentam o algoritmo e permitem-no fazer previsões mais precisas quanto maior for a quantidade de dados e mais bem rotulados eles forem. Esse aprendizado é conhecido também como aprendizado indutivo, em que o algoritmo vai produzindo (e apurando) a regra geral, a partir dos dados treinados, para conduzir novas observações. Esse processo de associar entradas e saídas denomina-se comumente de rotulagem de dados. “A presença dos rótulos possibilita que os algoritmos ajustem seus parâmetros para reproduzirem as mesmas saídas caso sejam apresentadas entradas semelhantes” (Bochie, 2020).

O exemplo clássico é o treinamento algorítmico para reconhecimento de imagens. Para treinar um algoritmo em reconhecer gatos e cachorros, faz-se o algoritmo processar

milhares de fotos de cachorros distintos, já rotuladas (com um rótulo “cachorro” associada a cada imagem de cachorro) e se faz o mesmo com as imagens de gatos. A partir dessa base treinada, é testado o algoritmo com dados novos (imagens de gatos ou cachorros não pertencentes à base treinada). Há vários modelos matemáticos (veremos adiante), típicos do aprendizado supervisionado, para a classificação dos dados novos a partir dos dados treinados. Normalmente, para o treinamento dos algoritmos no aprendizado supervisionado, são separados 80% dos dados que se têm rotulados, o conjunto de treinamento para ajustar seus parâmetros e 20% são utilizados para o teste do algoritmo, o conjunto de teste, que é usado para certificar o efetivo aprendizado algorítmico (Bochie, 2020).

3.7.2. O aprendizado não supervisionado

O aprendizado *não supervisionado* funciona quando não há feedback prévio nem dados classificados, não possuímos os outputs corretos a priori e, portanto, não precisamos de intervenção humana para a rotulagem dos dados. Seu uso mais frequente é para classificação, por exemplo, para agrupar em *clusters* assinantes do Netflix ou usuários do Facebook. Os algoritmos do sistema de IA identificam as características ou os perfis comuns e classificam, agrupando os dados por essas características. O modelo aprende, de modo autônomo, reconhecendo os padrões nos dados e aprimorando-se com a quantidade de dados novos a serem classificados (Bochie, 2020). Uma aplicação de monitoramento de tráfego, por exemplo, como o *Waze* utiliza esse aprendizado para reconhecer bons e maus trajetos, baseando-se nos registros da movimentação de milhares de usuários.

3.7.3. O aprendizado por reforço

Por fim, vamos falar do aprendizado *por reforço*. Ele acontece quando o algoritmo não depende de dados treinados, nem consegue encontrar os padrões de modo autônomo, mas aprende na interação com o ambiente e no resultado da ação que deve tomar naquela situação. Um exemplo seria treinar um carro autônomo em uma cidade real ou treinar um algoritmo para jogar xadrez. (Woolf, 2009). O objetivo deste tipo de aprendizado é permitir que o sistema extrapole ou generalize suas respostas de modo a agir corretamente

em situações futuras e não presentes no conjunto de testes. Num território desconhecido, espera-se que o agente aprenda com sua própria experiência (Sutton; Barto, 2010)

Apesar da tentação de pensar no *aprendizado por reforço* como um tipo de *aprendizado não supervisionado* porque ele não se baseia em comportamentos previamente rotulados como corretos, o aprendizado por reforço busca maximizar a recompensa em vez de buscar a estrutura escondida (Sutton; Barto, 2018). De todas as formas de aprendizado de máquina, é a que mais se aproxima do modo como humanos e outros animais aprendem e muitos dos algoritmos que funcionam nesse paradigma se inspiram em sistemas biológicos de aprendizado. Um exemplo prático de aplicação do aprendizado por reforço é o caso dos aspiradores domésticos robóticos. Imagine um deles tomando a decisão de entrar em um novo cômodo da casa para retirar a sujeira do piso ou retornar a base para recarregar suas baterias. Ele toma a decisão baseada no nível atual de sua bateria e em quanto tempo ele retornaria à base, daquele ponto em que está, conforme os registros de suas movimentações anteriores pela casa (e dos erros cometidos nessas movimentações).

Aplicado ao ensino, este tipo de organização dos dados para o aprendizado de máquina aparece nos tutores inteligentes que “aprendem” a melhor combinação de questões a serem ofertadas ao aluno para a obtenção de uma boa nota em uma prova objetiva. Cada vez que um aluno performa bem em uma avaliação, o algoritmo registra as questões que ele trabalhou e ajusta seus parâmetros para levá-las em consideração para futuros alunos.

3.7.4. Outros tipos de aprendizado

Essas representações, os três tipos de aprendizado, são, segundo Bochie, uma aproximação conceitual e ajudam a descrever melhor o campo do aprendizado de máquina, mas há outros paradigmas de aprendizado possíveis. Temos o aprendizado semissupervisionado, que é útil, por exemplo, quando parte importante dos dados não está rotulada - o aprendizado não supervisionado entra em ação e rotula por padrão esses dados não rotulados para que o supervisionado faça então a classificação de todos os dados. Um exemplo seria quando em um hospital existem muitas radiografias que já produziram diagnósticos enquanto outras ainda não estão associados a nenhum diagnóstico. Na classificação desta base não rotulada, o algoritmo usa seu treinamento anterior para rotular a base adicional, economizando trabalho humano.

Há ainda um outro paradigma, que deve se tornar uma tendência (Kojima, 2022) baseado nas técnicas *Zero-Shot* ou *Few-Shot* que se apresentam cada vez mais para a classificação de objetos que ainda não foram usados no conjunto de treinamento. São construções estatísticas para extrair padrões de poucos dados com sucesso na aplicação ao conjunto de dados reais. Tais técnicas que visam ao treinamento dos modelos algorítmicos com menor esforço e menor custo. Outra técnica, chamada *transfer learning*, permite a transferência do aprendizado do modelo treinado em uma tarefa para outra tarefa distinta, sempre que os objetos analisados sejam semelhantes. Um modelo pré-treinado para reconhecimento de riscos de crédito poderia ser adaptado para um sistema de análise de inadimplência para planos de saúde, por exemplo, sem que todo o processo de treinamento, normalmente custoso e lento, precise ser repetido (Torrey; Shavlik, 2010).

Dados rotulados por humanos (aprendizado supervisionado) constituem desafio de tempo e investimento de capital. Os sistemas usam cada vez mais dados, conseqüentemente usam sistemas de processamento robustos, intensivos em energia, e custa muito caro treinar as novas soluções de IA, o que favorece a concentração de mercado.

Na aplicação educacional, a técnica de rubricas *zero-shot* aplicada em uma plataforma de ensino de programação (Code.org), produziu *feedbacks* suficientes para que o aprendizado dos alunos alcançasse níveis surpreendentes. (Wu, 2019). Wu relata que não era possível o trabalho de validar as diferentes respostas que cada aluno dava à programação específica, que produzia os desafios propostos de modo a personalizar o caminho do aluno. Por mais que se buscassem os principais padrões, havia muita aleatoriedade e isso impossibilitava *feedbacks* precisos para cada construção (lembrando que o Code.org é usado por 600 milhões de alunos em todo o mundo). Contratar um grupo de especialistas e conduzir um estudo estatístico que gerou uma coleção de rubricas de autorregulação foi a saída criada. Essa rubrica, uma redução da multiplicidade das questões e das interações feitas pelos estudantes, definida por especialistas, passou a ser usada pelo algoritmo para classificar as interações dos estudantes na plataforma. Mais adiante voltaremos a falar deste tipo de treinamento de dados e seu impacto nas aplicações educacionais.

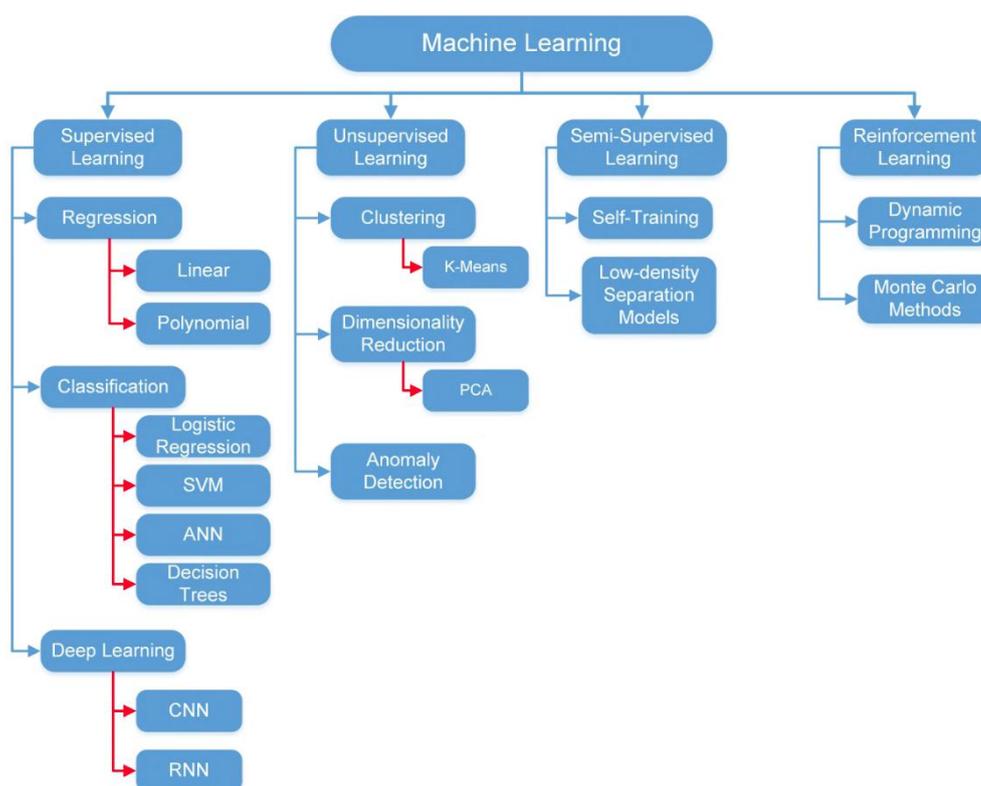
Essa “redução” da complexidade da aprendizagem humana, desejável para a viabilidade econômica no desenvolvimento dos sistemas, é fator crítico na análise da efetividade dos sistemas de automação, via IA, na escola.

3.8. Modelos algorítmicos

Os estudos de caso, que serão apresentados no capítulo 4, fazem uso dos modelos de aprendizado de máquina. No estudo de caso que veremos sobre os sistemas tutores inteligentes (STI), o aprendizado por reforço vai ajudar, entre outros aspectos, a reconhecer estilos pessoais de aprendizagem, para melhor prever as mídias mais eficazes para o estudo de cada aluno, em um processo de aprendizagem personalizada, bem como na avaliação mais precisa da performance do estudante comparando-a com a de um especialista no assunto, indicando quando há ou não efetivo domínio de tópicos de conhecimento. O aprendizado por reforço vai ajudar também a otimizar a oferta de dicas e sugestões de estudo baseadas nas condições daquele aluno e nos dados de performance (tempo para obter a resposta, dicas e sugestões que funcionaram com outros alunos para terem sucesso na atividade) dos demais alunos que já trabalharam na plataforma. No estudo de caso da correção automática de redações, que será apresentado igualmente no capítulo 4, o modelo de aprendizado de máquina que prevalece é o aprendizado supervisionado, quando é preciso classificar previamente (o que na ciência de dados denomina-se de rotular dados) muitas redações em relação aos critérios utilizados pelos corretores do ENEM, para que o modelo possa então atuar sobre novas redações. Será também preciso reconhecer características do texto e compará-las a grades quantidades de textos avaliados por professores humanos, treinando o algoritmo por meio de rubricas que funcionam para reconhecer erros ortográficos, de pontuação, de coerência, entre outros.

A representação a seguir (figura 10) descreve os principais algoritmos, associados ao aprendizado de máquina em que normalmente estão associados. São muitas opções que um cientista de dados tem para treinar os modelos de aprendizado de máquina. Conforme a característica dos dados disponíveis e dos objetivos da análise pretendida, um dos algoritmos pode funcionar melhor que outro. Para que possamos reconhecer sua utilização nas aplicações do capítulo seguinte e compreender como efetivamente funcionam nessas aplicações, será importante conhecermos um pouco melhor alguns destes algoritmos. De acordo com a premissa estabelecida neste estudo, a possibilidade de se entender o funcionamento, ainda que esquematicamente, o funcionamento dos modelos e algoritmos de aprendizado de máquina, vai permitir maior capacidade de atuação profissional nas diversas áreas em que a IA vem avançando.

Figura 10 – Modelos algorítmicos do aprendizado de máquina



Fonte: <https://tinyurl.com/5y8jc5ph>

Como proposto, veremos, de modo esquemático, o funcionamento lógico-matemático dos principais algoritmos que aparecem nos estudos de caso do capítulo 4. Serão abordados os seguintes modelos:

- Regressão linear
- K-Means
- Árvore de Decisão
- Redes Neurais de Aprendizado Profundo

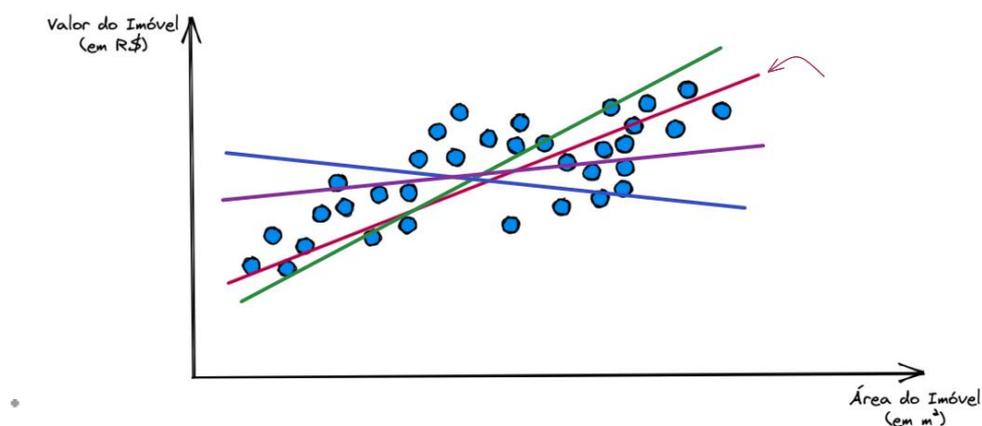
A escolha desses quatro modelos segue o desafio de ampliar a explicabilidade nos sistemas de IA, o que pressupõe "garantir que previsões algorítmicas e qualquer dado de entrada que produza estas previsões possa ser explicável para não-especialistas" (Yalcinet al., 2021). Os três primeiros são construções estatísticas bastante conhecidas e estão entre os modelos de maior explicabilidade, entretanto não performam tão bem em tarefas mais complexas. As redes neurais revolucionaram o campo da IA pela sua grande capacidade

de processamento, útil nessas tarefas mais complexas, mas apresentam, em contraponto, mais opacidade para as análises.

3.8.1. Regressão Linear

É, entre os algoritmos de aprendizado de máquina, um dos mais simples e comuns. É uma abordagem estatística usada para análise preditiva. A abordagem relaciona uma variável dependente e uma ou mais independentes, por meio de uma função linear, e ignora dados que escapem dessa relação geral, simplificando a correlação, daí a denominação regressão linear. As independentes predizem as dependentes (Maulud, 2020). Na figura 9, de modo bastante intuitivo, percebe-se que o valor de um imóvel é variável dependente da sua área. Com muitos dados à disposição, o algoritmo encontra então a função linear que melhor relaciona área e valor - a reta vermelha na figura, a que tem mais pontos próximos de sua função - e consegue prever o possível valor de um novo imóvel a ser avaliado em função de sua área, com razoável precisão. Há também várias técnicas para reduzir o ruído ou o custo⁹, que são estes pontos mais afastados da reta da figura 11. Normalmente, as funções usadas são muito complexas do que esta do exemplo. Há diversas outras variáveis em jogo na avaliação do preço de um imóvel, tais como localização, tempo de uso, condições de conservação, entre outras. As previsões que envolvem mais de uma variável independente tomam a forma de regressões polinomiais ou exponenciais (Maulud, 2020).

Figura 11 – Exemplo de função estatística usando Regressão Linear



Fonte: <https://brains.dev/2022/modelos-de-regressao-regressao-linear/>

⁹ denominações da ciência de dados para os dados que produzem desvios na função,

No estudo de caso do capítulo seguinte, veremos que a partir do treinamento algorítmico em correção de redações por critérios concretos (no caso estudado, os critérios do ENEM), o algoritmo usa regressão linear para encontrar a função que correlaciona número de ocorrências de eventos ligados a cada critério com notas oficiais dadas, estabelecendo, assim uma predição bastante razoável das notas para novas redações.

3.8.2. *K-means*

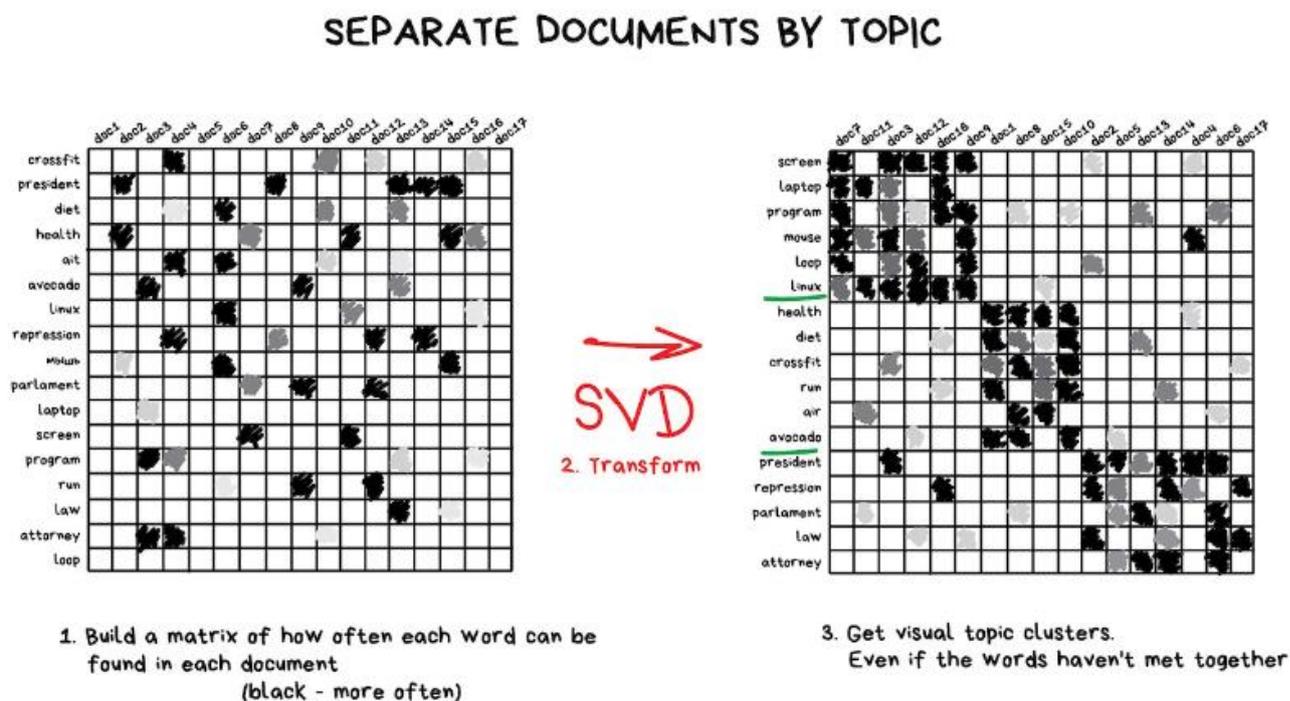
Este método é muito usado na clusterização, que é a busca de padrões em *dados não supervisionados*. O ponto de partida do trabalho nesta abordagem é buscar o que há em comum entre os conjuntos de dados e separá-los pelas suas características comuns, definindo então as regras para classificação de novos objetos. Esta metodologia é bastante útil na classificação de textos por temática, reconhecimento de imagens ou na segmentação de clientes para campanhas de marketing.

Na figura 12, uma imagem esquemática de como funciona um algoritmo que agrupa documentos pela frequência da ocorrência de palavras. O algoritmo é previamente treinado com palavras ligadas às temáticas que tentará detectar nos textos que vai processar. No exemplo da figura 10, ele inicialmente detecta as palavras mais frequentes que aparecem nos documentos processados (como fazem os algoritmos das nuvens de palavras) e, reconhecendo, pelo treinamento anterior, palavras relacionadas a três temas (política – derivadas das palavras *president*, *repression*, *law*, *parlament*, tecnologia – derivadas das palavras *screen*, *laptop*, *mouse*,... ou saúde – *air*, *crossfit*, *diet*,...), agrupa matricialmente os documentos que contêm várias delas, classificando-os por tema. A partir daí, o algoritmo assim treinado poderá reconhecer com facilidade a temática principal de novos documentos. No estudo de caso do capítulo seguinte, o algoritmo é usado para definir a correlação entre a redação do aluno e o tema proposto, ajudando professores a terem uma visão geral de grandes conjuntos de redações em relação à compreensão da proposta e à aplicação de conceitos coerentes à proposta, um dos critérios de avaliação no ENEM (o critério específico que pode ser analisado por esse tipo de algoritmo é a compreensão do tema e aplicação das áreas de conhecimento).

O processo de aprendizado de máquina geralmente mistura mais de um modelo algorítmico. Depois de estabelecidos os padrões, usando a técnica de K-means, para que um texto possa ser reconhecido, no caso, como tratando (ou não) do tema da redação, usa-

se *regressão linear* (apresentada anteriormente), para se obterem previsões nas novas redações a serem classificadas.

Figura 12 – Classificação de documentos por tópico



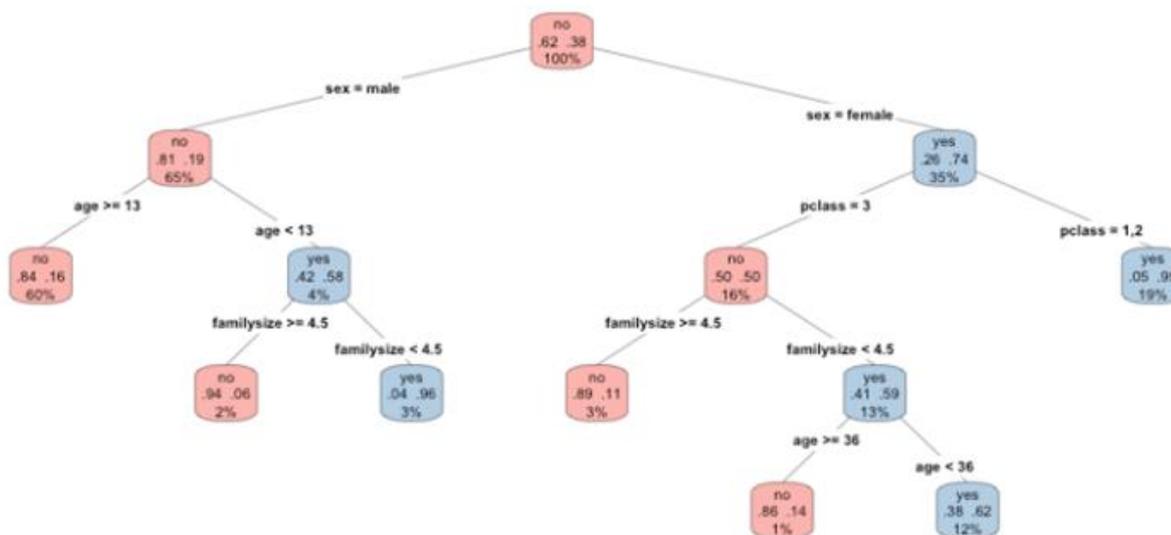
Fonte: <https://tinyurl.com/2s3cmfj8>

3.8.3. Árvore de decisão

A *árvore de decisão* é um método binário, usado no aprendizado supervisionado, com uma estrutura de fluxograma, que aparece bastante no treinamento de modelos algorítmicos devido à sua explicabilidade, baixo custo computacional e pelo fato de que se assemelha muitas vezes ao modo como funciona o raciocínio humano (Barros et al., 2012). Na figura 13, como exemplo, temos uma simulação para avaliar a chance de sobrevivência de um passageiro no Titanic, baseada em gênero, idade e nível socioeconômico, a partir do banco de dados¹⁰ contendo 1309 passageiros, dos quais em 1068 casos se sabia o paradeiro (se sobreviveu ou não) e 239 casos de paradeiro desconhecido. Como saber, com boa precisão, o que teria acontecido com esses 239 a partir dos casos de destino conhecido?

¹⁰ *Kaggle* – uma comunidade online de cientistas de dados

Figura 13 – árvore de decisão – sobrevivência no Titanic



Fonte: [Titanic survival prediction - datawerk \(buhrmann.github.io\)](https://github.com/buhrmann/titanic-survival-prediction-datawerk)

O sucesso da árvore depende da boa escolha das variáveis (denominadas de nós). Nesse recorte da imagem, iniciamos a árvore com 100% dos passageiros, dos quais se sabe que somente 38% sobreviveram. Em seguida, usa-se gênero como novo nó da árvore. Entre os homens somente 19% sobreviveram, entre as mulheres, 74%. Entre os homens as chances de sobrevivência eram maiores para os menores de 13 anos (58%) com famílias de menor tamanho (< 4,5 pessoas). Entre as mulheres, as chances de sobrevivência daquelas que estavam na terceira classe do navio foram bem menores (50%) do que as das mulheres da primeira classe (95%). Treinando o algoritmo a ajustar seus parâmetros de modo a realizar sempre o percurso da árvore torna possível, com razoável acerto, prever o que teria acontecido com uma garota de 18 anos, da 3ª classe, acompanhada de uma família grande - teria somente 10% de chance de ter sobrevivido. O algoritmo por meio da técnica da árvore acima, poderá então prever o resultado de qualquer caso novo. (Farg; Hassan, 2018).

Veremos, nos estudos de caso do próximo capítulo, o uso de árvore de decisão como método para treinamento de dados em grandes bases textuais, uma vez definidas regras gerais, envolvendo gramática, semântica, contexto e outros aspectos importantes para a interpretação da linguagem. Veremos também árvores de decisão ajudando, no caso de sistemas tutores inteligentes, na tomada de decisão, pelo algoritmo, sobre a dica

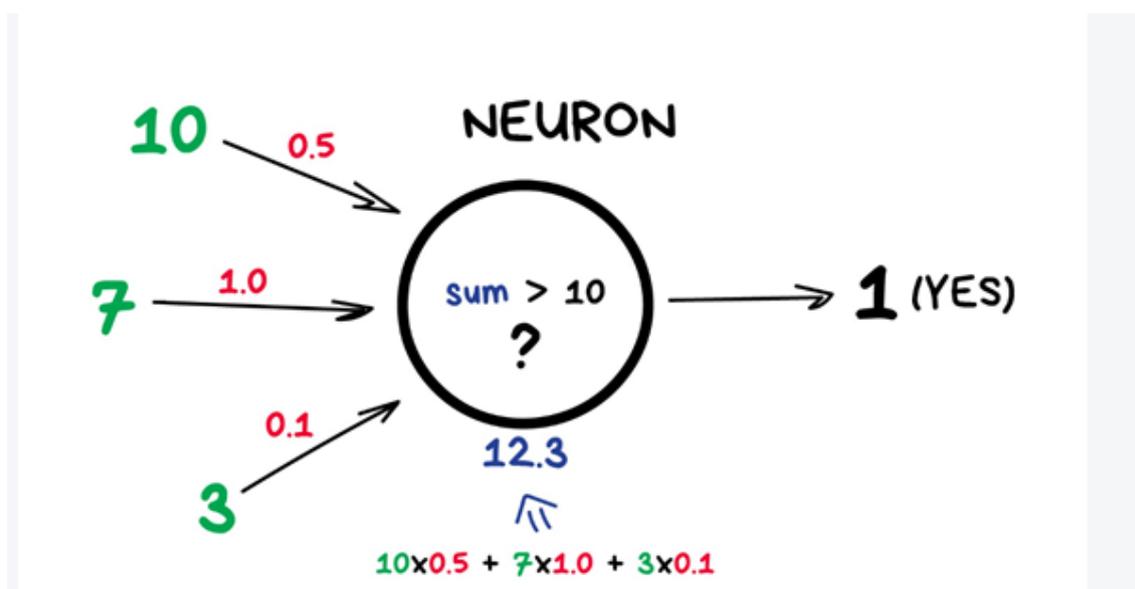
ou a recomendação de leitura ou de exercício mais indicado para o aluno diante de sua dificuldade instantânea.

E, finalmente, veremos, no próximo item, o algoritmo que impulsiona o desenvolvimento do aprendizado de máquina e da IA:

3.8.4. Redes Neurais

Rosenblatt, engenheiro da Cornell University, apresenta, em 1957, um modelo matemático, chamado *Perceptron*. Um neurônio artificial (o *perceptron*) poderia, a partir de entradas (inputs - x) balanceadas por parâmetros ou pesos (w), produzir uma saída (output - y) e ser treinado para que recalcular seus parâmetros a fim de obter a saída desejada (figura 11). Em 1960, tínhamos pouco poder de computação disponível e o modelo de processamento em camada única parecia pouco escalável para análises complexas (Pohl, 2019). Esse estudo, que se revelou promissor 20 anos depois e acabou redundando no sucesso das redes neurais atuais, foi criticado e abandonado (em um dos chamados invernos da IA - em que, por vezes, estudos eram abandonados por impossibilidades técnicas, ou pelo aparecimento de outras linhas teóricas).

Figura 14 – o modelo do Perceptron

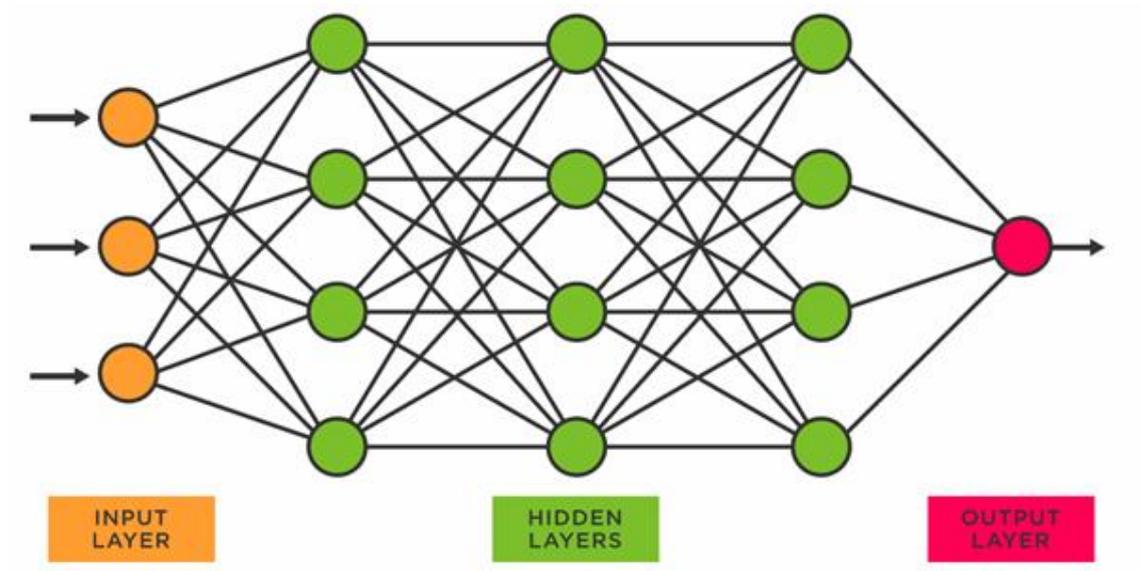


Fonte: <https://tinyurl.com/2s3cmfj8>

Na figura 14, temos uma simplificação esquemática do *Perceptron* para sua representação: um neurônio digital – um modelo matemático inicialmente - recebe três inputs (10, 7 e 3) e, se a soma deles multiplicados por seus parâmetros (0.5, 1.0 e 0.1) - nesse caso, funcionando como uma média ponderada - totalizar mais de dez, a saída (output) deste neurônio será um e ele conseqüentemente se conectará eletricamente ao próximo neurônio da camada neuronal digital. Caso a soma seja menor que 10, a saída será zero e esse neurônio não ativará mais nenhum outro naquela camada (Wang; Benning, 2020). Esse seria o princípio teórico, para Rosenblatt, de uma computação neural.

Ao longo da década de 1980, a pesquisa em IA e na ciência da computação apresenta vários avanços, a partir da possibilidade de serem processados múltiplos *perceptrons* (neurônios digitais) em muitas camadas, em uma rede de *perceptrons*, que passa a ser chamada de rede neural pela similaridade com o modo como nossos neurônios são ativados em rede, como esquematizado na figura 15. Nosso sistema neuronal, baseado em neurônios e suas terminações nervosas, ativa-se eletricamente, com um neurônio “excitado” ativando eletricamente os seus milhares de vizinhos, conforme o caminho neural “aprendido” para a solução da tarefa em questão, compondo nosso funcionamento cerebral. O aumento de camadas neurais artificiais, (em um GPT essas camadas podem chegar aos bilhões), com cada uma delas se especializando em identificar um conjunto de características em particular, chega-se a um processamento com enorme alcance e simultaneidade. (Bochie, 2020).

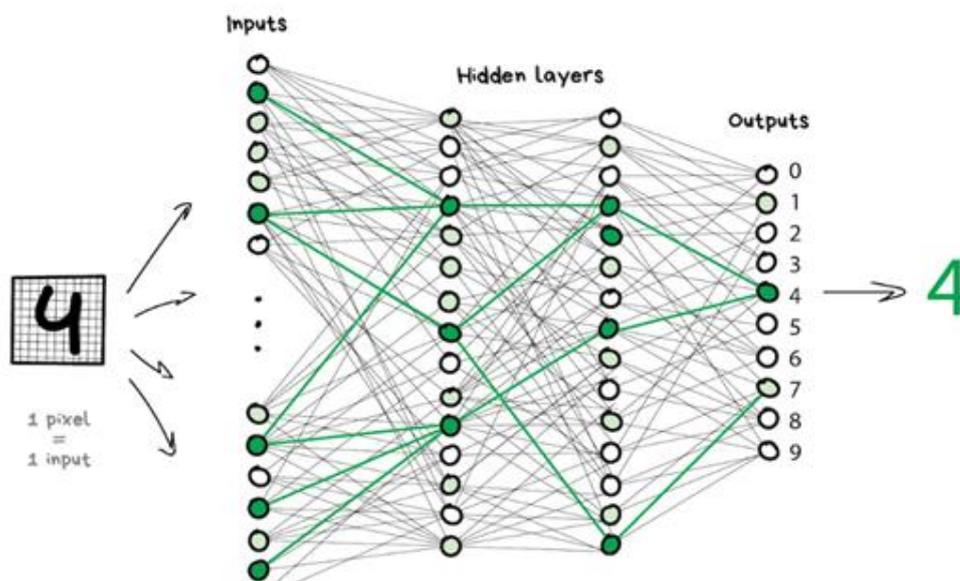
Figura 15– esquema da rede neural composta de várias camadas de neurônios digitais



Fonte: <https://tinyurl.com/2s3cmfj8>

Geoffrey Hinton, professor da Universidade de Toronto e até o início de 2023 coordenador da área de IA do Google, e outros pesquisadores, em mais um importante avanço, ajudam a demonstrar as possibilidades do processo chamado *backpropagation*, ou retropropagação, em que a rede neural consegue, quando depara com um resultado não esperado, voltar o processo do fim para o começo, modificando progressivamente os parâmetros (o 0,5 ou o 1.0 ou 0.1 no caso da figura 11) e processando continuamente até alcançar o resultado esperado. Vejamos um exemplo na figura 16.

Figura 16– Rede neural processando o reconhecimento progressivo de caracteres manuscritos



Fonte: <https://tinyurl.com/2s3cmfj8>

Está sendo treinado um algoritmo para identificar algarismos manuscritos, como o quatro, neste exemplo. O algoritmo decupa a imagem do número quatro em pixels¹¹ e cada *pixel* do 4 é um *input* da imagem, um neurônio digital de entrada da rede neural que pode estar ativo ou inativo – verde ou branco. O treinamento da rede neural, em uma explicação simplificada, ativa, no início do treinamento, a partir da camada de input, diferentes neurônios ao longo das camadas e obtém um output que não representa o 4 (os neurônios da última camada combinados representariam pixels compondo todos os caracteres). O resultado errado faz com que o processamento retorne pela rede neural modificando sucessivamente os parâmetros em cada neurônio de cada camada e volta novamente ao final, até que a saída, o *output* seja um 4. Se repetirmos o processo com milhares de 4 manuscritos, chegaremos a uma parametrização quase precisa para garantir que todos os novos 4 de input sejam processados pela parametrização já alcançada resultando sempre no output 4, que vai então ser usado pelo algoritmo para o fim destinado (poderia ser um sistema de digitalização de textos manuscritos, por exemplo,

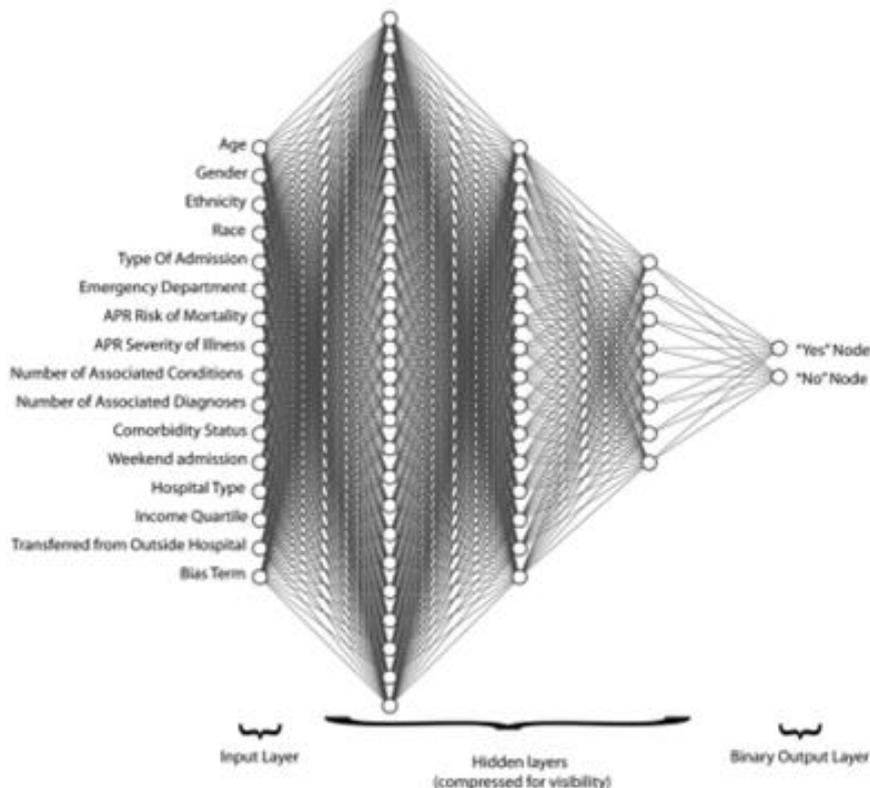
¹¹ uma imagem, dependendo de sua qualidade, é composta por milhares ou até milhões de pixels – a menor unidade de uma imagem digital

previsões ou que o ChatGPT possa percorrer vastas bases textuais para compor respostas imediatas a seus prompts.

Na figura 18, como exemplo prático das possibilidades de processamento advindo do aprendizado profundo, aparece o esquema de estudo para análise de viabilidade financeira e técnica na recomendação clínica de cirurgia plástica de quadril ou joelho (para colocação de prótese) para uma operadora de plano de saúde. No campo à direita, os dados de entrada referem-se a vários componentes da análise de viabilidade (idade, sexo, raça, comorbidades, tipo de hospital, renda do paciente etc.). Do lado direito, dois dados de saída: o sim (aprovação para a cirurgia) e o não (reprovação). O algoritmo de rede neural profunda foi treinado com milhares de casos de diagnósticos semelhantes, com dezenas de características pessoais e as respostas dadas pelo sistema de saúde. Assim, como no exemplo do reconhecimento da imagem do quatro, usa-se o aprendizado supervisionado para treinar o algoritmo a reconhecer como positivos (pelo ponto de vista da seguradora) determinados arranjos de entrada e aplica-se essa regra aos novos casos. Destaca-se aqui o aspecto ético - questões sobre viés nos dados de treinamento dos modelos dominam as discussões sobre a ética da IA (Gonsales, 2022) do processo de aprendizado de máquina para previsões. Como garantir que a seguradora leve em conta as efetivas necessidades do paciente em detrimento das suas condições financeiras, do plano, do equipamento hospitalar necessário ou da lucratividade da seguradora (Haeberle et al., 2019)?

Figura 18 – Rede neural de aprendizado profundo processando análise de viabilidade de seguro médico

Fig. 1 Example of input, hidden, and output layers used to predict value-based metrics prior to elective primary total hip or knee arthroplasty from Ramkumar et al. [6**]. Dr. Ramkumar retains the rights to this figure



Fonte: <https://www.sciencedirect.com/science/article/abs/pii/S0883540319305406>

Em um dos estudos de caso do capítulo 4, o algoritmo, no aprendizado por reforço baseado em redes neurais de aprendizado profundo, vasculha a *Wikipedia* em busca de dicas úteis para as dúvidas do aluno na sua interação com o conteúdo e processa também os dados dos estudantes que já passaram pelo curso, relacionando as dicas mais bem-sucedidas com os demais alunos com as dúvidas daquele aluno instantaneamente. São muitas operações simultâneas, que permitem ao algoritmo comparar longos trechos textuais, extraindo padrões, com neurônios digitais em múltiplas camadas processando e reparametrizando todas essas variáveis simultaneamente para a interpretação do texto digitado pelo aluno, analisando de grandes blocos de texto da *Wikipedia* e das correlações entre tipos de questões, dicas úteis e dúvidas anteriores daquele aluno e de outros milhares que já estudaram pelo tutorial (Kochmar, 2020).

Embora essa arquitetura do aprendizado profundo tenha alavancado o desenvolvimento de aplicações de IA em diversos campos, é importante compreender que além das questões de viés, chama a atenção o *trade-off* entre os ganhos que essas redes estão trazendo, como no caso dos grandes modelos de linguagem e inúmeras aplicações importantes e o impacto no consumo de energia e para o conseqüente do arrefecimento térmico necessário, o volume de recursos financeiros para o funcionamento dos parques

computacionais e a concentração desses parques e processamentos nas mãos de poucos players de mercado. Esses modelos de processamento de grandes bases textuais exigem muito processamento e enorme capacidade computacional instalada (Kaufman, 2019). Outro *trade-off* levantado pela pesquisadora está na dificuldade de encontrar explicações precisas sobre como o modelo chegou a tal predição ou gerou tal conclusão, devido à complexidade e opacidade do modelo algorítmico. Esse *trade-off* tem alavancado esforços internacionais na direção de uma regulação que garanta transparência, responsabilidades juridicamente bem definidas e sustentabilidade dos modelos utilizados.

3.9. Incidência dos modelos algorítmicos em aplicações educacionais

O advento da pandemia de covid-19 acelerou a digitalização dos sistemas tradicionais de ensino, da educação básica ao ensino superior. As plataformas de apoio¹³ ajudaram nas tarefas de ensino e de aprendizagem no confinamento de estudantes e professores e depois tornaram-se mais presentes no trabalho híbrido (que conjuga práticas presenciais e online). “A produção de dados por alunos e professores subiu exponencialmente, gerando momentum para o desenvolvimento das métricas de análise da aprendizagem (learning analytics) e da própria ciência da aprendizagem (Learning Sciences)” de acordo com Munir, (2022). Dados brutos precisam ser tratados - reorganizados e limpos (retirando de sua composição variáveis irrelevantes). Da ciência de dados, derivam, no campo educacional, em duas linhas de pesquisa: a mineração de dados educacionais e a análise da aprendizagem (learning analytics - o termo em inglês tem sido bastante utilizado na discussão da educação brasileira). Enquanto a mineração de dados desenvolve metodologias para explorar os diferentes tipos de dados que são coletados nos diferentes ambientes educacionais, o LA refere-se diretamente à medição, à coleta, à análise e à produção de relatórios sobre estudantes e seus contextos, permitindo que possamos compreender e otimizar os ambientes de ensino e aprendizagem. (Romero, 2020).

Entre as aplicações mais frequentes, a partir de pesquisa sobre publicações indicando a presença de IA na educação (Munir, 2022), temos:

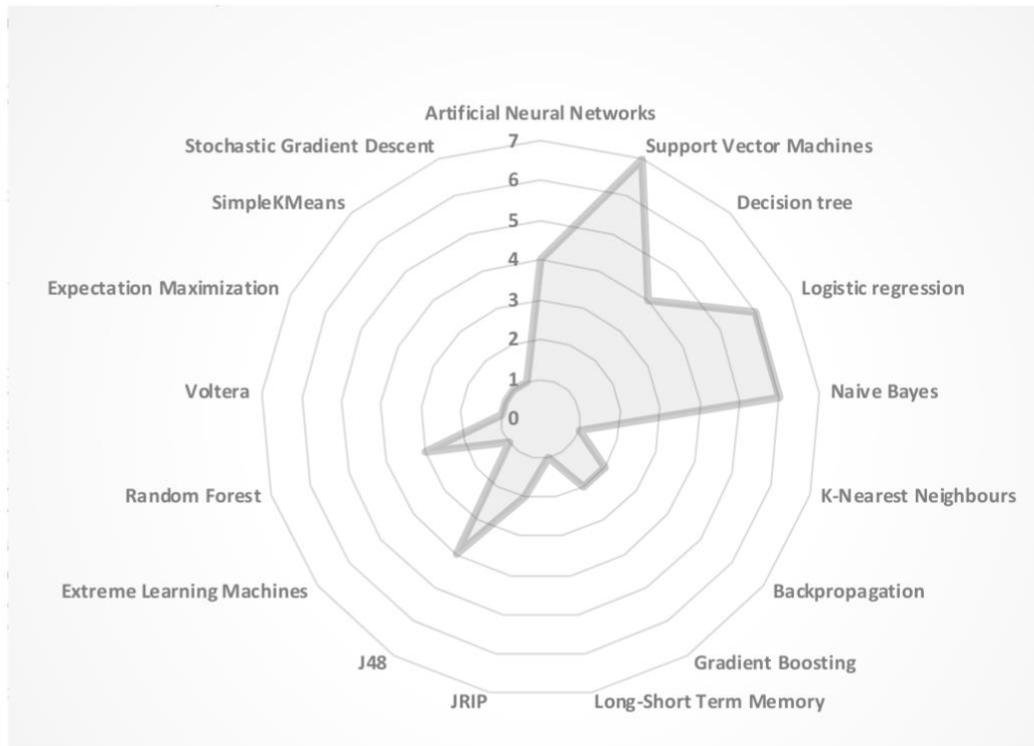
- Tutores Inteligentes

¹³ os Ambientes Virtuais de Aprendizagem – Moodle, Google Sala de Aula, entre outros

- Predição de Performance Acadêmica
- Ensino Preditivo e Adaptativo
- Predição de abandono (ensino superior)
- Automação
- Avaliação, análise e estudo em grupo

Este estudo listou as abordagens de aprendizado de máquina que mais tem sido utilizadas na educação digital (figura 19). A variação na frequência dos modelos algorítmicos indica que a qualidade e as características dos dados coletados para treinamento do modelo ou mesmo no caso do aprendizado não supervisionado podem fazer prevalecer um ou outro algoritmo (neste estudo, prevalece o SVM, que é um modelo não abordado nesta dissertação, bastante sólido sob o ponto de vista estatístico, mas que não funciona tão bem com grandes conjuntos de dados pelo tempo dispendido no treinamento do modelo). Outra conclusão possível aqui seria que, pela pouca incidência de redes neurais no processo, ainda temos baixo investimento na produção destas soluções educacionais. (Munir,2022)

Figura 19 – incidência de modelos algorítmicos em aplicação educacional de IA



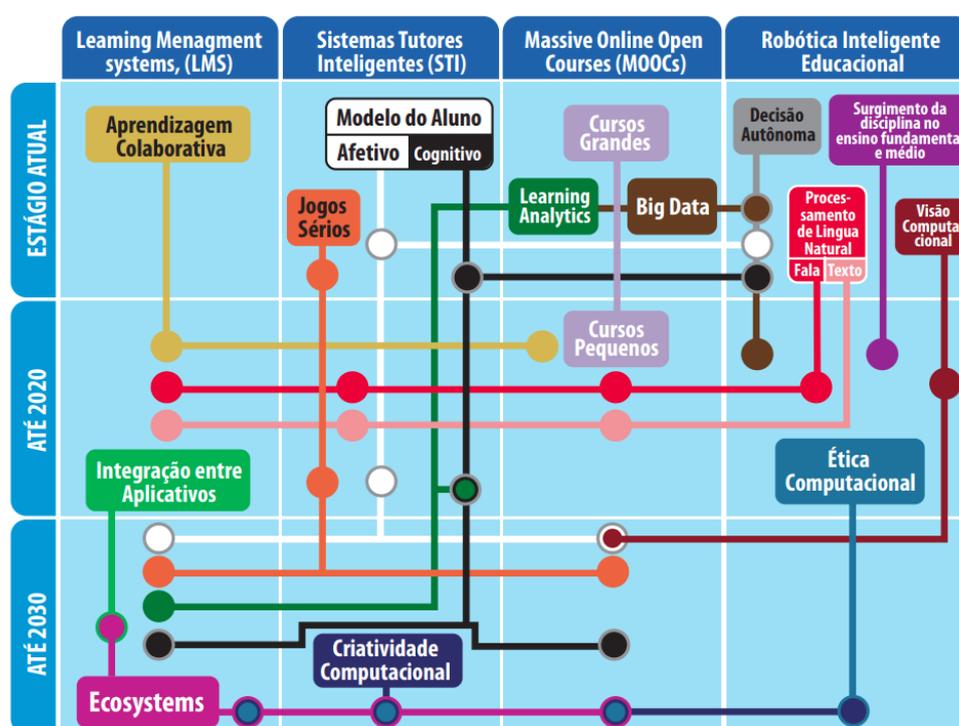
Fonte: <https://tinyurl.com/yxua54e3>

4. ESTUDOS DE CASO - APLICAÇÕES DE IA NA EDUCAÇÃO:

4.1. Tendências:

Vicari elaborou, em 2018, um mapa indicativo das tendências no desenvolvimento de aplicações educacionais baseadas em IA e aprendizado de máquina para o período 2017-2030.

Figura 20 – tendências nas aplicações de IA em educação



Fonte: https://acervodigital.sistemaindustria.org.br/bitstream/uniepro/259/1/Sumario_tendencias_web.pdf

Construindo para o CNI¹⁴, em 2018, o estudo denominado Tendências em Inteligência Artificial na Educação no Período 2017-2030, Rosa Vicari, pesquisadora das tecnologias na educação e pioneira na área da IA aplicada, vasculhou artigos, teses e patentes para prospectar os avanços na área. O trabalho apresenta uma metodologia chamada *Roadmap Tecnológico*. Ele representa uma técnica utilizada para o gerenciamento e o planejamento tecnológico, especialmente para explorar e comunicar

¹⁴ Confederação Nacional da Indústria, organismo que administra o sistemas SESI e SENAI.

interações dinâmicas entre recursos, objetivos organizacionais e mudanças no ambiente (Vicari, 2018). Na figura 20, cada retângulo representa tecnologias em uso ou que estão surgindo como tendência para o período até 2030, vinculadas sempre ao período de prospecção e à área em que a tecnologia surgiu. As grandes áreas de trabalho com tecnologia educacional e possíveis interfaces com a IA, são os *MOOCs*¹, os AVAs, os STIs e a Robótica Educacional. Os círculos representam períodos de produtividade (inovação) de uma tecnologia. Por exemplo, o PLN foi incorporado primeiramente na Robótica e gradativamente foi fazendo parte da realidade dos AVAs, dos STIs e dos *MOOCs*. (Vicari, 2018)

O advento da IA generativa pode acelerar as tendências apontadas por Vicari. Os chatbots associados aos tutores inteligentes, aos AVAs e aos *MOOCs* provavelmente vão impactar todo o sistema educacional formal e informal, tornando as aplicações mais engajantes e dialógicas. Nesta dissertação, entretanto, optamos por apresentar algumas aplicações que estão no campo da IA preditiva, anteriores ao advento do ChatGPT, como explicaremos a seguir.

4.2. Critérios para os estudos de caso apresentados:

Segundo Luckin, a “ IA veio para ficar e terá um impacto cada vez maior no *design* de tecnologia para uso em educação e treinamento” (Luckin, 2019, p.2). Segundo Maud Chassignol (2018), a inteligência artificial tem o potencial de influenciar o processo de ensino-aprendizagem em quatro áreas, mencionadas a seguir.

1. Conteúdo educacional personalizado: apoio à construção de base conceitual para o trabalho na docência de qualquer área, e possibilidade de organização diferenciada do conhecimento conforme as características do aluno.
2. Métodos de ensino inovadores: perspectiva de ampliação das estratégias utilizadas pelos docentes para atingir cognitivamente seus alunos e das estratégias de estudo e aprendizagem dos alunos.
3. Avaliação aprimorada por tecnologia: perspectivas de mais elementos nos diagnósticos de aprendizagem e nas correções de rota decorrentes desses diagnósticos.
4. Comunicação entre aluno e professor: mais possibilidades de interação aluno-professor- conhecimento, mediadas pelos recursos digitais.

Seguem os grandes conjuntos de aplicações de IA no ensino e na aprendizagem mais apontadas neste relatório (Munir, 2022) e nos demais pesquisados nesta dissertação (Gonsales (2022), Sayad (2022); Vicari, 2018; Luckin et al., 2016) .

<p>Tutores Inteligentes Adaptativos:</p>	<p>Trata-se de ambientes de conteúdo curricular estruturado que, dependendo do conhecimento, das habilidades e das características pessoais, entregam conteúdo diferenciado conforme as possibilidades e as necessidades de cada aluno. Podem igualmente estar equipados de <i>chatbots</i>, derivados ou não dos grandes modelos linguísticos, para apoiar pessoalmente o aluno em sua trajetória de estudo.</p>
<p>Predição de evasão escolar:</p>	<p>Trata-se de ambientes de análise de dados que, baseados nos números de clique, no tempo dispensado a cada elemento do AVA, nas características do curso e no perfil do aluno (idade, gênero, ocupação profissional) conseguem determinar com bastante antecipação e precisão as chances de cada aluno novo no sistema desistir do curso.</p>
<p>Predição de Resultados Acadêmicos:</p>	<p>Similarmente aos algoritmos para predição de evasão, comuns no ensino superior via EAD, a partir de avaliações intermediárias e dos demais dados obtidos nas plataformas de estudo (AVAs), com correção automatizada e treinamento dos dados resultantes, determinam também com bastante precisão, as performances previstas do aluno no curso, permitindo correção do planejamento escolar, investimentos balanceados etc.</p>
<p>Automação na gestão de conteúdo:</p>	<p>Diversas técnicas de aprendizado de máquina são utilizadas para classificação das questões múltipla escolha, disponíveis em grandes bancos de questões, que melhor se adaptam a cada tipo de avaliação, catalogação automática e predição do melhor sequenciamento didático, a partir do material didático catalogado, que corresponderia melhor a determinados objetivos em um curso específico.</p>

Análise, avaliação e estudo em grupo:	Trata-se de técnicas diferentes de aprendizado de máquina são utilizadas para aprimorar a interação entre pares (alunos) em grupos de trabalho ou grupos de estudo. Coletam-se informações sobre o engajamento e a contribuição para o grupo por meio de publicações ou intervenções didáticas e são oferecidos ao professor indícios de interações que poderiam aperfeiçoar o trabalho do grupo.
Auxílio a pessoas com deficiência –	Há inúmeras iniciativas usando aprendizado de máquina para produzir ambientes pessoais interativos, que dialoguem com o aluno usando PLN, traduzam conteúdo escrito para conteúdo oral e vice-versa, bem como para reconhecer as combinações de material didático catalogado para oferecer a cada tipo de estudante.
Avaliação da intervenção didática do professor:	Há várias aplicações de reconhecimento de imagem que, baseadas nas gravações de aulas do professor e no treinamento de dados recolhidos de muitos outros professores dando aula, indicam aprimoramentos possíveis, seja no apoio à alunos específicos na sala, seja na correção de determinados hábitos didáticos, verbais e gestuais do professor, com supervisão automatizada.
Apoio na produção de material didático:	A IA generativa, os grandes modelos de linguagem e o aprendizado profundo aportam aplicações que catalisam e apoiam o professor na produção didática de videoaulas, apresentações nas mais diversas mídias, material interativo, ideias para intervenções, avaliações e questões, nos mais variados contextos didáticos.
Correção automática de avaliação:	Modelos de aprendizado de máquina apoiam o professor na correção automatizada de avaliações objetivas e dissertativas, classificando os diferentes grupos de alunos, mediante rubricas pré-estabelecidas para o treinamento do algoritmo.
Treinamento docente:	a partir das técnicas de IA generativa, base dos grandes modelos linguísticos, é possível treinar professores simulando estudantes virtuais, que são representados pelo chatbot mediante prompts bem

	<p>detalhados sobre seu perfil, recebendo orientação didática, permitindo que o professor possa reconhecer possibilidades de recomendar distintos materiais didáticos conforme estilo de aprendizagem e conhecimento específico do aluno (MARKEL, 2023).</p>
--	--

Quadro 2 – Aplicações de IA na educação – elaboração do autor

Para encontrar aplicações educacionais que atuem em uma dessas áreas e escolher algumas para apresentar em detalhe, mapeamos, em dissertações e teses sobre IA aplicada à educação, as indicações que obedecessem a dois critérios:

- a. apresentar evidências efetivas do uso da IA e
- b. permitir, metacognitivamente, que, ao estudá-las e explorá-las, o leitor pudesse aprender mais sobre aprendizado de máquina e IA.

Para apresentar as aplicações de IA na educação, vamos utilizar uma classificação sugerida por Luckin (2022), agrupando-as em três categorias, conforme o usuário principal da aplicação (neste estudo, embora relevantes para a apropriação, pela escola da IA, que gestores sejam impactados e envolvidos, optamos por estudar com mais profundidade as duas primeiras):

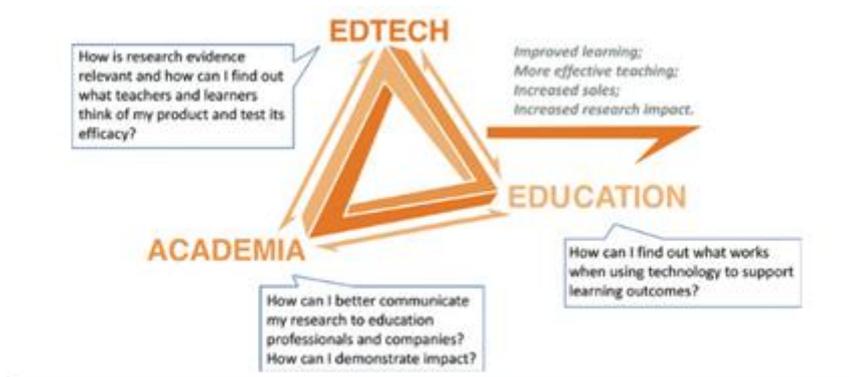
1. Aplicações de IA centradas no aluno;
2. Aplicações de IA centradas no professor; e
3. Aplicações de IA centradas na gestão escolar

Luckin dirige o departamento de Learning Science da University College of London (UCL) e produz reflexão e pesquisa sistemática sobre IA desde 1990. O Reino Unido tem sido pioneiro na incorporação de disciplinas obrigatórias de letramento midiático e digital no currículo nacional, impulsionando pesquisas vigorosas no campo das *Learning Sciences*, cujos expoentes são David Buckingham, Sonia Livingstone e a própria Luckin (Polizzi, 2020). No âmbito desse departamento, foi criada em 2016 a EDUCATE¹⁵, visando mentorar startups inglesas no aprimoramento de sua capacidade de compreender os fenômenos da educação, aproximando, em um "triângulo dourado" (Figura 21), escolas, pesquisa (universidade) e mercado.

¹⁵ *Educational Technology Exchange Program*, programa de integração empresa, escola e universidade da University College of London.

O problema reside no fato de que quem desenvolve Ed-Tech (empresas Ed-Tech), quem pesquisa Ed-Tech (academia) e quem usa Ed-Tech (usuários – professores/alunos/pais) operam em silos, e as informações sobre como demonstrar o impacto, sobre o que demonstrar o impacto e para quem não são acessíveis o suficiente para criar tecnologias educacionais verdadeiramente impactantes. Para agravar a questão, não existem teorias para informar como aproximar essas três comunidades específicas. Uma construção, o triângulo dourado da Ed-Tech informada por evidências, foi apresentada pela primeira vez por Rose Luckin, professora de design centrado no aluno da UCL, para preencher essa lacuna (Luckin; Cukurova, 2020, p.4)

Figura 21 – O triângulo dourado



Fonte: <https://www.educateventures.com/research>

Os trabalhos do grupo de Luckin, retratando os esforços de aproximação da indústria, academia e escola e especialmente no preparo da cultura escolar para a apropriação das aplicações de IA, serão explorados com mais profundidade ao longo do capítulo 5, constituindo-se em parte fundamental do desenvolvimento desta dissertação.

A escolha desta classificação - centrada no aluno, professor e gestor escolar -, amplia o campo de reflexão sobre o impacto possível dessas tecnologias no âmbito escolar. As aplicações descritas no quadro 3 foram geradas em buscas por aplicações educacionais baseadas em IA a partir de vários artigos e, em seguida, submetidas ao Google Scholar. As aplicações selecionadas têm pelo menos dois artigos científicos analisando seu impacto e atestando o uso de alguma das técnicas de aprendizagem de máquina. O quadro 3 contém links no nome da aplicação que remetem ao site do desenvolvedor e links na descrição de sua funcionalidade básica que remetem ao artigo escolhido como referência.

Quadro 3 – Aplicações educacionais com evidências do uso de técnicas de IA

<i>Centrada no Aluno</i>		<i>Centrada no Professor</i>		<i>Centrada na Gestão Escolar</i>	
Korbit	Sistema Tutor Inteligente para ensino de ciência de dados, machine learning e inteligência artificial	LightSide	Plataforma de apoio à classificação e à pesquisa sobre mineração de dados textuais desenvolvida pela Carnegie Mellon. O professor treina o modelo.	IBM Watson Assistant	Gerador de chatbots para atendimento interno e externo
Squirrel	Tutor inteligente chinês para o ensino de matemática	Grade Scope	Plataforma para correção em larga escala baseada em rubricas e reconhecimento de escrita	BrightBytes	Plataforma de análise de dados e Learning Analytics para instituições educacionais
MetaTutor	MetaTutor, um ITS baseado em hipermídia projetado para estruturar aprendizagem autorregulada de estudantes universitários enquanto eles aprendem sobre o sistema circulatório humano	Adobe Sensei	Aplicação interna à suíte Adobe que reconhece padrões de trabalho mecânico na produção gráfica e executa-os automaticamente	Learnosity	Plataforma múltipla de apoio à edição de conteúdo e gestão de dados
Aleks	Assessment and Learning in Knowledge Spaces (ALEKS) -tutor inteligente usado para ensino de matemático, adotado no Projeto Ceibal (Uruguai)	Cerebron	Plataforma baseada em técnicas de PLN para correção automatizada de redações	Panorama Education	Plataforma de apoio a gestão socioemocional de alunos
RoboTutor	Um tutor inteligente, desenvolvido na Carnegie Mellon, que ajuda na interpretação de textos por meio de técnicas de	Cerego	Plataforma para produção de conteúdo e gamificação digital	YellowDig	Plataforma de estímulo interacional que opera integrada nos AVAs

	Naive Bayes e Regressão linear				
Assistments	Tutor inteligente para ensino individualizado de matemática, produzido na Worcester University e oferecido gratuitamente	EdThena	Plataforma para treinamento de professores e autossupervisão de aulas expositivas	Knime	Plataforma aberta para mineração e visualização de dados
Brainly	Tutor de consulta geral baseado em perguntas	PAM	Sistema tutor adaptativo de matemática usado no projeto Ceibal Uruguai	Orange	Plataforma aberta de mineração e visualização de dados
ChatGPT	Chatbot baseado em IA generativa que dialoga com aluno e professor atendendo a demandas gerais (dúvidas, pesquisa, produção de texto, código)	ChatGPT	Chatbot baseado em IA generativa que dialoga com aluno e professor atendendo a demandas gerais (dúvidas, pesquisa, produção de texto, produção de código,...)	PowerBI	Plataforma da Microsoft voltada à gestão de dados e à geração de painéis de análise de dados.
Photomath (APP)	App para ensino de álgebra - usa reconhecimento de imagem	Synthesia	Gerador de vídeo artificial		
SimStudent	Plataforma de apoio ao ensino de matemática, produzida pela Carnegie Mellon, em que o aluno treina o agente virtual				
Betty's Brain	Plataforma de apoio ao ensino de temas da biologia desenvolvido pela Vanderbilt onde o aluno ensina o tutor com mapas conceituais				
MATHia	Tutor cognitivo para ensino de matemática - Carnegie Mellon				

Fonte: elaboração do autor.

Do quadro 3, foram selecionadas três aplicações de aprendizado de máquina para análise. O critério usado na escolha, além da garantia de que seja utilizada na aplicação alguma das técnicas de IA, foi a perspectiva metacognitiva da aplicação, ou seja, que o leitor desta dissertação pudesse, ao conhecer e explorar a aplicação, aprender mais sobre aprendizado de máquina e IA.

4.3. Metacognição e autorregulação:

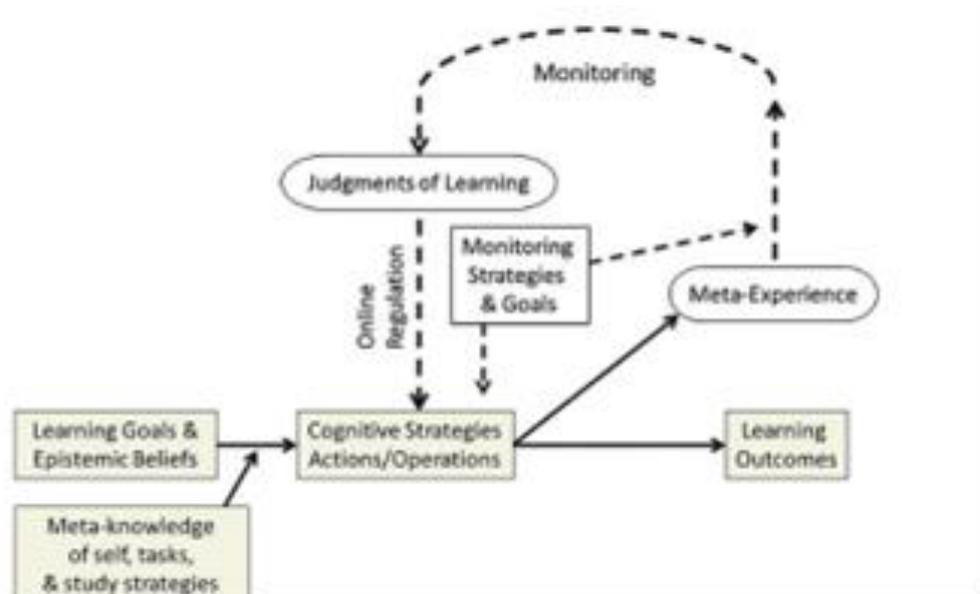
Pesquisas revelam que estudar por meio de ferramentas tecnológicas exige do aluno a análise da situação de estudo, estabelecer objetivos razoáveis e determinar as estratégias que devem ser usadas. Ao longo do estudo em plataformas digitais ele é levado a avaliar qual estratégia que lhe possibilitou alcançar o objetivo que estabeleceu. E tem a chance de ir modificando seus planos, seja usando seus próprios conhecimentos, seja usando o apoio externo (de um tutor ou professor), conforme a tecnologia que utiliza. Esse processo é também conhecido como autorregulação da aprendizagem.

Autorregulação envolve autodirecionamento e automotivação. Permite que o estudante se envolva estrategicamente em diferentes processos que ampliam suas possibilidades de alcançar um objetivo. Não é uma habilidade inerente aos estudantes, mas é aprendida e desenvolvida por processos de ensino. (Zimmerman; Moylan, 2009).

Habilidades metacognitivas se referem a conhecimento procedimental que é necessário para a regulação e o controle sobre o comportamento de aprendizagem de alguém. Orientação, definição de objetivos, planejamento, monitoramento, checagem, avaliação e recapitulação são manifestações dessas habilidades. Há evidências de que habilidades metacognitivas produzem até 40% de variância nos resultados de aprendizagem em um largo espectro de tarefas cognitivas.

Scaffolding (ou andaimes) é também um termo bastante utilizado na literatura sobre metacognição e autorregulação. Representa todo o suporte intermediário oferecido pelo docente ou pelo ambiente de estudo (digital ou não - o conjunto livro didático, anotações de classe e consultas gerais também compõem esse suporte) para reforçar ou ajustar o progresso de estudo do aluno diante das dificuldades que ele passa na solução de alguma tarefa. E no ambiente digital, em particular, é possível avaliar, de modo mais preciso a qualidade destes “andaimes” pelo rastreamento do percurso de estudo do aluno e por seu impacto no seu resultado cognitivo, além de ser possível detectar outras fontes consultadas fora da plataforma, ampliando o conhecimento sobre estratégias de estudo.

Figura 22 – O processo da Metacognição



Fonte: International Handbook of Metacognition and Learning Technologies

No *loop* da Figura 22, estão as experiências metacognitivas internas associadas às tentativas de aprender, monitoradas pelos alunos para julgar seu progresso real de aprendizagem e fazer revisões on-line de suas ações cognitivas; caso contrário, os alunos serão guiados apenas por um conhecimento prévio incompleto e muitas vezes errôneo. O caminho inferior da esquerda para a direita representa a influência direta que o conhecimento metacognitivo pode ter nos resultados da aprendizagem ao impactar a seleção inicial da estratégia durante o planejamento (Aleven; Azevedo, 2013).

A aprendizagem por meio de tecnologias parece efetivamente estimular a autorregulação. E cada vez mais as plataformas digitais de apoio a aprendizagem podem ser projetadas para estimular o aluno no desenvolvimento de sua autorregulação e de habilidades metacognitivas. O processo de *scaffolding* também é crítico no desenvolvimento dos sistemas tutores inteligentes, para permitir a granularidade necessária para atuar com a maior diversidade possível de dificuldades na aprendizagem (Ge, 2000). E o estudo em plataformas digitais também permite que se examinem os processos de autorregulação por parte dos estudantes, oferecendo a docentes, pesquisadores e instituições de ensino, insights significativos sobre os processos cognitivos de estudo. (Aleven; Azevedo, 2013). Portanto, acreditamos ser importante que os sistemas de apoio ao ensino e à aprendizagem baseados nas técnicas de IA sejam

prescrutados sob esta ótica, tão relevante para os processos de autonomia na aprendizagem.

4.4. Estudos de caso - aplicações

Nos três estudos de aplicações, visando estimular a reflexão sobre a IA moldável ao usuário, apoiando uma aprendizagem autorregulada, apresentaremos uma aplicação de mercado e uma segunda aplicação baseada no conceito de IA como aprendiz. Carmel Kent (2022) chama a atenção para um tipo de aplicação de IA que ela denomina “*AI as a learner*”, em que professores e alunos aprimoram e modelam o modelo probabilístico. Ensinar exige externalizar a compreensão por meio da fala, da escrita ou da ilustração. Ao ensinar, percebemos o modo como aprendemos. Nesse caso o aluno, seja ele estudante, professor ou gestor, pode instruir a IA aprendiz e testar como ela performa uma habilidade ou demonstra sua compreensão. É possível também, na relação com uma IA aprendiz, compararmos nossas respostas às dela, apurando a nossa e ajudando-a a corrigir as suas.

4.4.1. Aplicações centradas no aluno

Esta dissertação selecionou, entre as aplicações centradas no aluno, aquelas que em que os estudantes possam aprender tópicos específicos ou melhorar habilidades específicas, os denominados “Sistemas Tutores Inteligentes” (STIs), que têm sido também chamados de Sistemas Adaptativos. Escolhemos este tipo de aplicação para representar as aplicações centradas no aluno porque elas aparecem notadamente nas pesquisas como promissoras e já vêm sendo exploradas, aplicadas e desenvolvidas há pelo menos 20 anos (Brusilovsky, 1998).

Esses sistemas respondem às necessidades individuais e em evolução dos alunos (Baker; Smith; 2019), por exemplo, adaptando o conteúdo de aprendizagem com base na interação de cada um, no seu modo particular de aprender e no conhecimento e habilidades anteriores (Luckin, 2019). Segundo Brusilovsky (1999), a adaptabilidade dos tutores inteligentes faz parte de um desenvolvimento posterior dos STIs. Vamos denominar estes sistemas, daqui em diante, de STIAs (Sistemas Tutores Inteligentes Adaptativos), compreendendo nessa categoria a adaptabilidade como característica intrínseca.

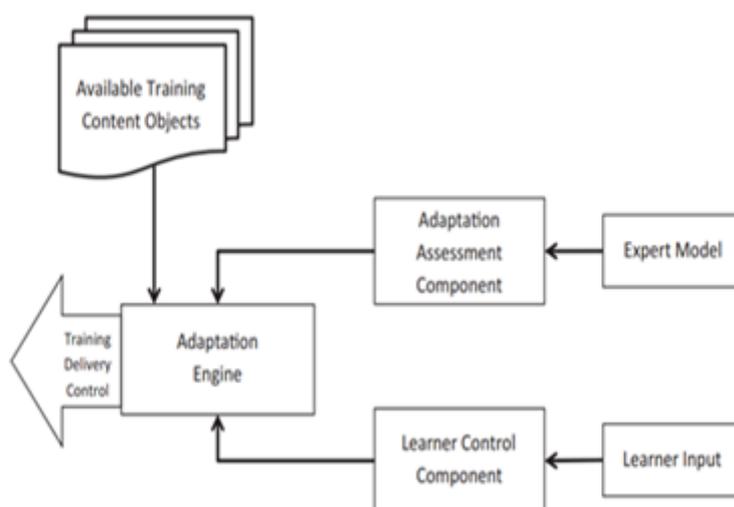
Segundo Hou e Fidopiastis (2018), um STIA deve ser capaz de adaptar dinamicamente o conteúdo de aprendizagem para atender às necessidades individuais de aprendizado em tempo real para que os estados ideais do aluno (por exemplo, engajamento, desempenho, carga de trabalho, entre outros) sejam alcançados e mantidos, e que a experiência de aprendizado seja otimizada. Para isso, conforme Figura 23, são necessários três componentes básicos, citados a seguir (Woolf; 2010).

a) O componente de adaptação da avaliação do aluno, que compara as iniciativas do indivíduo no sistema com o modelo de aprendizagem do especialista e o aprendido pelo algoritmo com muitos outros alunos;

b) O componente de controle do aluno acompanha a ação do indivíduo no sistema solicitando (e aprendendo de modo autônomo) que ele valide e oriente o sistema nas suas sugestões, volume de trabalho proposto, mais facilidade de estudar usando vídeo, fazendo exercícios, lendo, ouvindo áudio (o que corresponde ao que os especialistas denominam de estilo de aprendizagem); e

c) o componente de adaptação é o responsável por balancear a informação produzida pelos outros dois componentes e apresentar material didático relevante e coerente ao aluno.

Figura 23 – Modelo de STIA



Fonte: B. P. Woolf in Building Intelligent Interactive Tutors.

Outro objetivo dos STIAs é proporcionar aos professores melhores condições para personalizar a aprendizagem e produzir recomendações além de apoiar o aluno em suas potencialidades e dificuldades. STIAs atuam em duas frentes centrais da ciência da cognição: o rastreamento do conhecimento e a adaptação da instrução (Luckin, 2020).

A arquitetura básica de um STIA, segundo Woolf (2010), deve abarcar quatro componentes, expostos a seguir.

1. Modelo do aluno: representa a compreensão (domínio) do aluno sobre o campo do conhecimento em estudo, como funciona o processo de aprendizagem e compreensão, suas etapas, incluindo os erros de concepção, o tempo gasto na busca da compreensão, as ajudas necessárias, as respostas adequadas e o estilo de aprender.
2. Modelo do tutor: representa o conhecimento sobre as estratégias didáticas para selecioná-las em função das características do aluno.
3. Modelo do Domínio: representa o conhecimento do especialista no campo específico e como esse especialista atua nesse campo do conhecimento; e
4. Modelo da Comunicação: representa o conhecimento sobre os métodos de comunicação entre o aluno e os dispositivos digitais.

Na década de 1990, a tecnologia dos chatbots passa a ser incorporada no desenvolvimento dos STIAs e os aprimora (Chassignol, 2018). São utilizadas técnicas de PLN e computação afetiva¹⁶ para se comunicar por texto ou voz com humanos ou outros chatbots (Kochmar, 2020). Os chatbots atuam acompanhando as interações de texto do usuário em um sistema, e reagem buscando respostas ou recomendações específicas a cada interação.

Entre as plataformas centradas no aluno, escolhemos a plataforma Korbit, desenvolvida pela startup Korbit.ai, fundada por pesquisadores do Quebec AI Institute (MILA) e da Cambridge University tendo entre seus cofundadores Yoshua Bengio - um dos pesquisadores mais importantes da técnica de redes neurais de aprendizado profundo, tratada no Capítulo 3 – e reconhecida como umas Top 100 AI Startups pela CB Insights¹⁷.

¹⁶ Espera-se que em alguns anos os computadores se tornem muito bons em detectar, reconhecer e simular emoções, habilidades estudadas em uma área interdisciplinar denominada computação afetiva (CORTIZ, 2022)

¹⁷ A CB Insights é uma empresa privada com plataforma de análise de negócios e banco de dados global que fornece inteligência de mercado sobre empresas privadas e atividades de investidores. Wikipedia. Acesso em 9 dez. 2023

A Korbit dá acesso à razoável documentação sobre sua concepção e funcionamento, facilitando a tarefa de explicarmos os mecanismos pelo qual a IA opera nos STIAs. E por se tratar de um STIA que ensina ciência de dados, aprendizado de máquina e IA, apresenta-se como um interessante instrumento metacognitivo para o leitor deste trabalho (permite aprender IA pela IA).

A Korbit oferece um tutor interativo e personalizado em tempo real que se adapta às necessidades do aluno e fornece suporte pedagógico em forma de diálogo. Apesar de se apresentar como um modelo aberto, em que podem se incorporar novos campos de conhecimento, atualmente oferece somente cursos de IA, ciência de dados e técnicas de aprendizado de máquina.

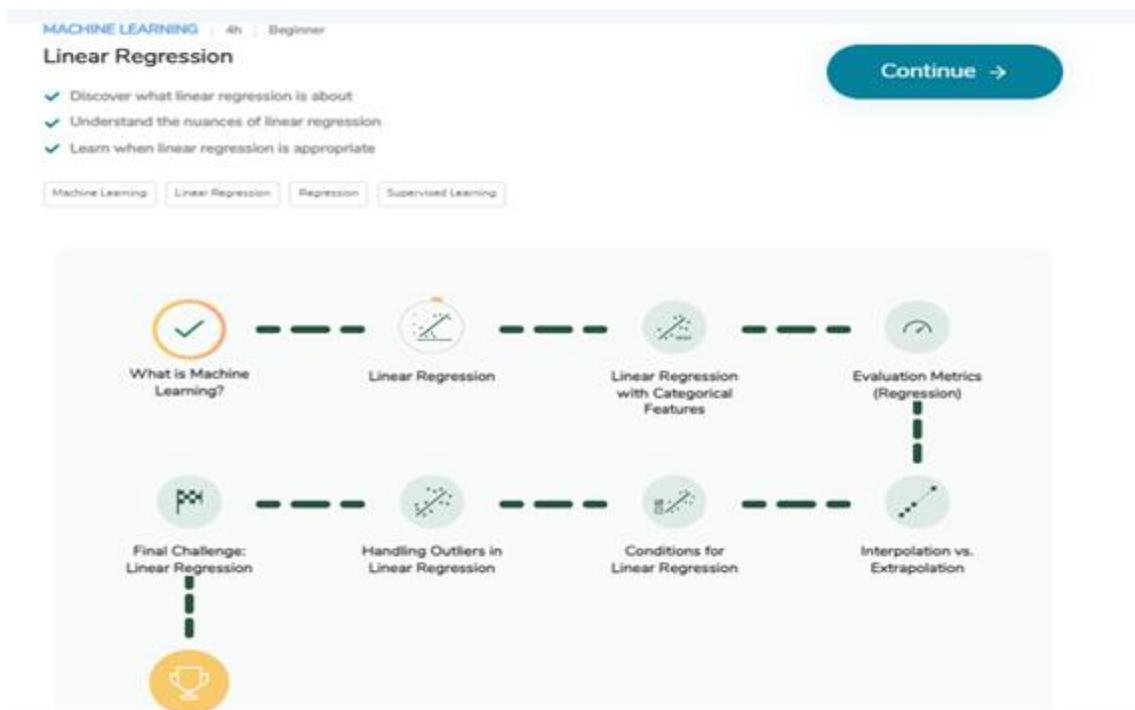
A plataforma do Korbit mistura vídeos e exercícios com diálogos interativos por meio de um chatbot, questões de múltipla escolha, diagramas conceituais, exercícios de matemática e programação e elementos de gamificação. Seu modelo probabilístico utiliza PLN e aprendizagem por reforço. Conforme explicamos no capítulo 3, aprendizagem por reforço é uma técnica de aprendizado de máquina em que o modelo aprende a partir da interação com o ambiente. O modelo segue “aprendendo” a partir da interação com os estudantes que o utilizam (mais de 20.000 estudantes já utilizaram a plataforma).

Segundo Iulian Serban (2020), há evidências de sucesso na aplicação do Korbit em grupos de estudantes de ciência de dados, na comparação com cursos de mesmo conteúdo baseados nos MOOCs (*Massive Open Online Courses*). MOOCs são uma tendência na educação superior desde 2013 quando universidades de todo o mundo passaram a oferecer gratuitamente cursos variados em suas plataformas de ensino a distância para grandes públicos.

Ao se cadastrar na plataforma, o usuário submete-se a um diagnóstico com um questionário de múltipla escolha sobre os diversos tópicos do currículo oferecido pelo sistema; comentários simples, como certo ou errado, são oferecidos logo após cada resposta. A partir de agosto de 2023, a Korbit pede que o interessado em usar a plataforma manifeste seu interesse para que eles permitam o acesso.

Ao final do diagnóstico, o sistema identifica as habilidades do aluno nos conteúdos a serem tratados no tema escolhido por ele e recomenda uma sequência de estudo na plataforma (uma trilha) como mostra a Figura 24.

Figura 24 – Sequência didática recomendada, a partir do diagnóstico



Fonte: Korbit.ai (<https://app.korbit.ai/my-curriculum>).

Em cada etapa estudada, o primeiro elemento cognitivo é geralmente uma vídeoaula que apresenta o conteúdo específico; segundo Kochmar (2022), o uso de vídeo na apresentação do conteúdo explora as vantagens da informação não textual. Em seguida, o chatbot passa a dialogar com o aluno sempre propondo questões sequenciadas, uma vez que, pela pesquisa dos autores, ao ter de resolver as questões sobre o material visto no vídeo, o aluno vai se apropriando do conteúdo o que gera resultados positivos no aprendizado. Os criadores do sistema referem-se a essa “conversação” com o bot como “tutoria socrática” pela similaridade com os diálogos socráticos¹⁸. No estudo citado, há evidências que este ambiente, mobilizado pelo diálogo original com o chatbot, agrada e mantém os estudantes engajados por mais tempo

¹⁸ A perspectiva aberta pelo diálogo que refuta respostas inconsistentes exigindo do interlocutor mais esforço para encontrar a verdade (Costa, 2019)

Figura 25 – Diálogo socrático no Korbit

The screenshot shows the Korbit AI interface. On the left is a sidebar with navigation options like 'Linear Regression 1', 'Solve and Advertising Costs', 'True or False?', 'Linear Regression Not Available', 'Question for Starting Sets and with', 'Linear Regression 2', and 'Calculating the Residual'. The main area displays a question: 'True or False? The ordinary least squares (OLS) method calculates the line for the observed data that will perfectly predict Y (dependent variable). True or false? Explain why.' Below the question is a 'I don't know' button. A 'CONCEPT TREE' diagram shows a hierarchy: 'Least Squares' at the top, followed by 'Linear Least Squares', and 'Ordinary Least Squares' at the bottom. Below the diagram is a 'I don't know' button. At the bottom of the interface is a text input field with a 'Send' button.

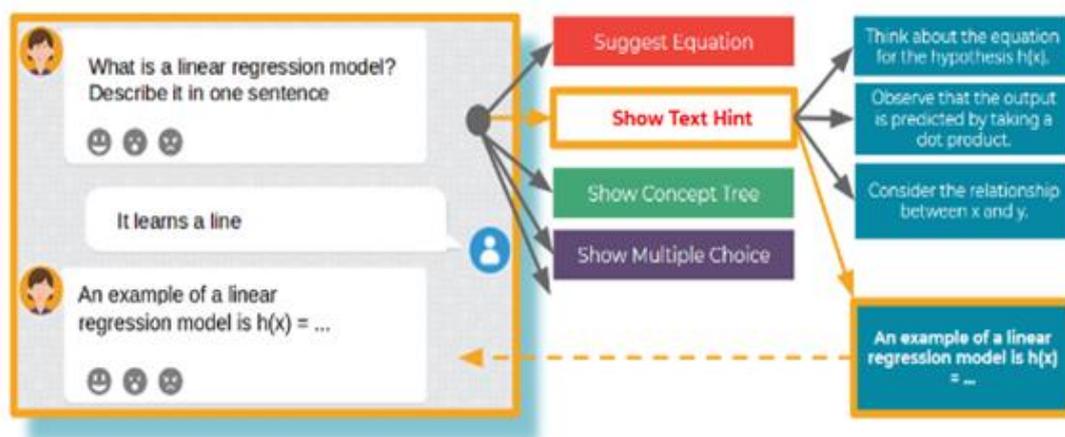
Fonte: Korbit.ai (<https://app.korbit.ai/my-curriculum>).

Sempre que o aluno tenta resolver uma questão, sua tentativa de solução é comparada com a expectativa (ou seja, solução de referência disponível no banco de dados, validada por professores a partir de um treinamento inicial do modelo com 450 alunos), usando um modelo de PLN. Há uma base de dados, nos temas de aprendizado de máquina, IA e ciência de dados, extraída da Wikipedia, por meio de palavras-chave devidamente selecionadas, que atua com as soluções de referência do banco de dados do aplicativo que está por detrás desses feedbacks variados (Kochmar, 2020). Esse conjunto de soluções preparadas e soluções da Wikipedia é o corpus linguístico do STIA para personalizar e adaptar o sistema de feedbacks a cada aluno.

Se a solução dada pelo aluno for classificada como incorreta, o sistema ativa e responde com uma de várias intervenções diferentes, que incluem dicas textuais, equações matemáticas, explicações, diagramas de árvore conceitual (mapa conceitual), como mostra a Figura 25, e novas questões de múltipla escolha. A intervenção pedagógica é escolhida por meio da aprendizagem por reforço com base no perfil de conhecimento do aluno e suas quatro últimas tentativas de solução. O sistema reconhece quando o aluno se adapta melhor a feedbacks em mapas conceituais, questões de múltipla escolha ou dicas textuais, entre outros. Quando a resposta do aluno é parcial e incompleta, ilustra a Figura 25, o sistema reconhece como parcialmente correta, oferece uma dica e pede novamente alguma resposta. A Figura 26 ilustra como o sistema de loop interno seleciona a intervenção pedagógica. O aluno dá uma resposta incorreta, o algoritmo reconhece,

pelas interações anteriores dele, que ele reage melhor às dicas textuais e oferece uma das várias opções de dica de texto.

Figura 26 – Um diálogo ilustrativo



Fonte: Korbit.ai (<https://app.korbit.ai/my-curriculum>).

Na Figura 26 o algoritmo de inteligência artificial executa, em três etapas, a escolha da dica mais apropriada, em função da resposta esperada, entre as soluções de referência do banco de dados. Na figura 27, as etapas da escolha feita pelo processador de linguagem:

- a) palavras-chave, incluindo substantivos e frases nominais, são identificadas na pergunta (por exemplo, *overfitting* e *underfitting*);
- b) período de sentença apropriado que não inclui palavras-chave é identificado em uma solução de referência (validada por um especialista no treinamento do modelo) usando um filtro, que considera a dica *when it has a high bias* como possibilidade; e
- c) uma gramática correta da dica é gerada usando modificações baseadas em discurso (por exemplo, *Think about the case*) e a dica parcial da etapa (2) (por exemplo, *when it has a high bias*).

Figura 27 – PLN na formação de uma dica

Question	Expectation	Generated hint
What is the difference between overfitting and underfitting ?	A model is underfitting when it has a high bias.	Think about the case when it has a high bias.

Fonte: <https://arxiv.org/abs/2203.03724>

A geração automática de dicas personalizadas é objeto central de estudo dos desenvolvedores da Korbit (Kochmar, 2021). As dicas são classificadas de acordo com sua qualidade linguística, bem como as interações anteriores entre o aluno e o aplicativo. Utiliza-se classificação da *árvore de decisão*, com dois conjuntos amplos de recursos, citados a seguir.

- 1) Os recursos de qualidade linguística avaliam a qualidade da dica apenas da perspectiva linguística (por exemplo, considerando o comprimento da dica/explicação, palavras-chave e sobreposição de tópico entre a dica/explicação e a pergunta);
- 2) Os recursos baseados em desempenho também consideram a interação anterior do aluno com o sistema, levando em conta o número de tentativas de questões, a proporção de acertos e erros em até 4 ciclos anteriores de interação daquele aluno com o aplicativo.

Os modelos de feedback são treinados e avaliados em uma coleção de 450 interações de diferentes alunos gravadas anteriormente. A base de respostas extraídas da Wikipedia (uma base fixa, de cerca de 2GB) proporciona alternativas de ajuda ao aluno. Usando *árvore de decisão*, o algoritmo da Korbit compara as palavras-chave da pergunta com o título do artigo da Wikipedia e com o corpo do artigo e a partir dos acertos e erros dos alunos ao receberem as dicas da Wikipedia, o algoritmo seleciona as melhores para serem utilizadas com outros alunos diante das mesmas questões. Há ainda a seleção das dicas matemáticas que, para serem indicadas, exigem que o algoritmo:

- a. decomponha a expressão digitada pelo aluno, usando o Latex¹⁹,
- b. extraia a melhor possibilidade entre elas (por exemplo quando o aluno digita $y(x+5)$ ele pode indicar y como uma função ou como um multiplicador de $(x+5)$) e
- c. compare a mais provável (de acordo com a pergunta a que o aluno responde) com várias opções de solução-referência.

¹⁹ um editor matemático, auxiliar para edição de caracteres específicos da notação matemática

No quadro 4, temos estudo comparativo que evidencia o resultado do aluno com o sistema de dicas automáticas padrão (sem personalização, usando programação convencional), com baixa personalização e com a personalização completa do sistema. No caso da personalização plena, os alunos testados conseguiram sucesso em mais de 60% na média antes da segunda tentativa de resolver as perguntas propostas.

Quadro 4 – Sucesso a partir da dica personalizada

Model	All attempts		Before second attempt	
	Mean	95% C.I.	Mean	95% C.I.
BASELINE (No Personalization)	39.47%	[24.04%, 56.61%]	37.93%	[20.69%, 57.74%]
SHALLOW PERSONALIZATION	46.51%	[31.18%, 62.34%]	51.43%	[33.99%, 68.62%]
DISCOURSE PERSONALIZATION	48.53%	[36.22%, 60.97%]	60.47%*	[44.41%, 75.02%]

Fonte: <https://arxiv.org/abs/2203.03724>

Assim, apresentamos a primeira aplicação de IA na educação centrada no aluno. Ainda que não esteja sendo utilizada em escolas, visto tratar-se de conteúdo de formação técnica, a aplicação nos permite compreender alguns dos mecanismos de funcionamento da IA nos sistemas tutores inteligentes adaptativos, e conseqüente reflexão sobre seu papel e impacto no aprimoramento das estratégias de ensino-aprendizagem.

[] Em público, os sistemas de aprendizado de máquina são frequentemente percebidos erroneamente como caixas pretas cujas decisões não são compreensíveis. Embora os modelos de Deep Learning sejam certamente complexos, eles não são caixas pretas. Na verdade, seria mais correto referir-se a eles como caixas de vidro, porque podemos literalmente olhar para dentro e ver o que cada componente está fazendo (GONSALES, 2022, p.35).

Nesse modelo de STIA, encontramos estudos bastante consistentes explicando as técnicas e os métodos usados no treinamento de dados e na construção do algoritmo. Além da *transparência*, ressaltada no parágrafo anterior, esses tutores estarão cada vez mais presentes nas escolas e poderão apoiar estudantes em inúmeras situações, contudo, será sempre importante avaliar se essas técnicas e modelos têm a *abrangência* necessária ao abarcar, no treinamento de suas bases de dados, grupos heterogêneos de estudantes, abrangendo a proporcionalidade representada no universo em que essas plataformas podem ser úteis, para evitar problemas de viés, tão comuns nas aplicações de IA. Mesmo que sejam levados em conta vários grupos heterogêneos de alunos para compor o sistema de tutoria, será sempre insuficiente para abarcar a singularidade humana. Será também

preciso que estes tutores garantam aos usuários o controle sobre o uso dos dados produzidos por eles, contemplando as leis de proteção de dados, no caso brasileiro, da LGPD. Transparência, abrangência e privacidade no uso dos dados devem ser requisitos básicos e implícitos no desenvolvimento desses sistemas. O conceito de “ética *by design*” , ou seja, levar em conta as implicações éticas do uso de dados pessoais e os impactos sociais em áreas sensíveis à sociedade, como trabalho, saúde e educação, e contemplar desde o início do desenvolvimento do sistema de IA as questões éticas, para tal pressupõe a formação de equipes de desenvolvedores multidisciplinares, diversificadas cognitivamente. (Kaufman, 2022).

Outra questão seria avaliar se essas aplicações têm a usabilidade para sua adoção sem necessidade de um usuário altamente especializado e sem demandar formação exaustiva dele. ²⁰A usabilidade de software pela ISO 9126 pode ser definida como a capacidade de o software ser compreendido, aprendido, usado e apreciado pelo usuário, quando usado nas condições especificadas. (Piton Gonçalves, 2012). Segundo os desenvolvedores da plataforma Korbit, está em desenvolvimento uma versão editável da plataforma visando atender outros conteúdos, baseados na evolução técnica do seu modelo de IA. A perspectiva de uma plataforma editável, com uma metodologia acessível para a inclusão de conteúdos diversos, seria altamente desejável na perspectiva de uma IA mais transparente e modelável. Um modelo treinado para resolver problemas de ciência de dados poderá ser usado para apoiar o estudo de química, por exemplo?

Ainda que tenhamos visto brevemente o modelo de aprendizado de máquina por transferência, será preciso que as bases utilizadas na nova área de conhecimento tenham similaridade com a anterior.

Finalmente, importante ressaltar o que Benedict du Boulay (2020) chama “*Escape from the Skinner Box*”²¹, ou seja, que nos preocupemos com escolas centradas no humano, focadas em desenvolver o “aprender a aprender” pelos seus educadores e alunos, capacitando-os a aprimorar ou adquirir soluções baseadas em IA com certo grau de facilidade e explicabilidade, sem a preocupação de estar se submeter cegamente às regras estabelecidas pelo desenvolvedor das soluções adotadas; uma IA flexível que permita ao

²⁰ norma ISO para qualidade de produto de software

²¹ Obra de Du Boulay alertando para as possibilidades de Sistemas Tutores Inteligentes trabalhando para o professor superarem as críticas de estarmos voltando aos princípios das máquinas de ensinar preconizadas por Skinner

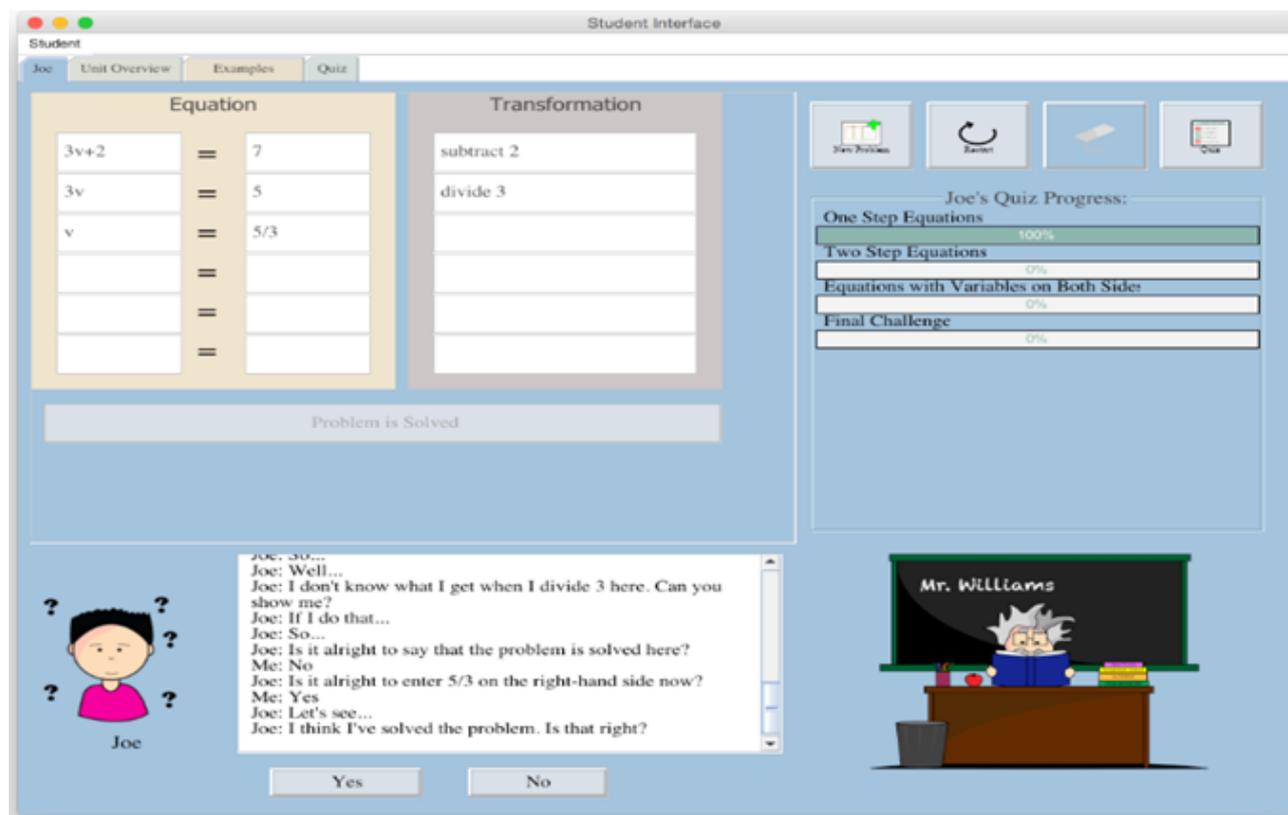
usuário, seja ele aluno ou professor, compreender seu funcionamento, e aprimorá-la com de suas interações.

4.4.1.1 – Aplicações centradas no aluno – IA Aprendiz

Apresentamos, em seguida, a perspectiva de uma IA aprendiz, centrada no aluno, o SimStudent (Figura 28), aplicação desenvolvida em 2005 no projeto Cognitive Tutor Authoring Tool da Carnegie Mellon University.

O aluno seleciona um problema algébrico de uma base já disponível no software. Então o tutor-aprendiz (Joe) tenta resolver e pede feedback ao aluno. Quando ele não encontra solução, o aluno sugere as etapas da solução, em um processo denominado de “Autoria pela Tutoria” (Matsuda et al.,2015). Um tutor especialista (Mr. Williams) acompanha os passos citados pelo aluno e intervém quando necessário, validando o processo. Há uma base de conhecimento que permite o aluno estudar todo o conteúdo. Embora rudimentar na sua interface, a considerar o estado da arte dos STIAs atuais, essa aplicação estimula-nos a pensar em novas formas de produzir tutoria digital baseada em IA. Tutores inteligentes que não apresentem logo de início suas predições, mas que possam aprender com o aluno, parece ser uma área bem interessante para pesquisa. A Carnegie Mellon University é referência na pesquisa sobre STIAs (Weitekamp, 2020).

Figura 28 – SimStudent – modelo de IA como aprendiz

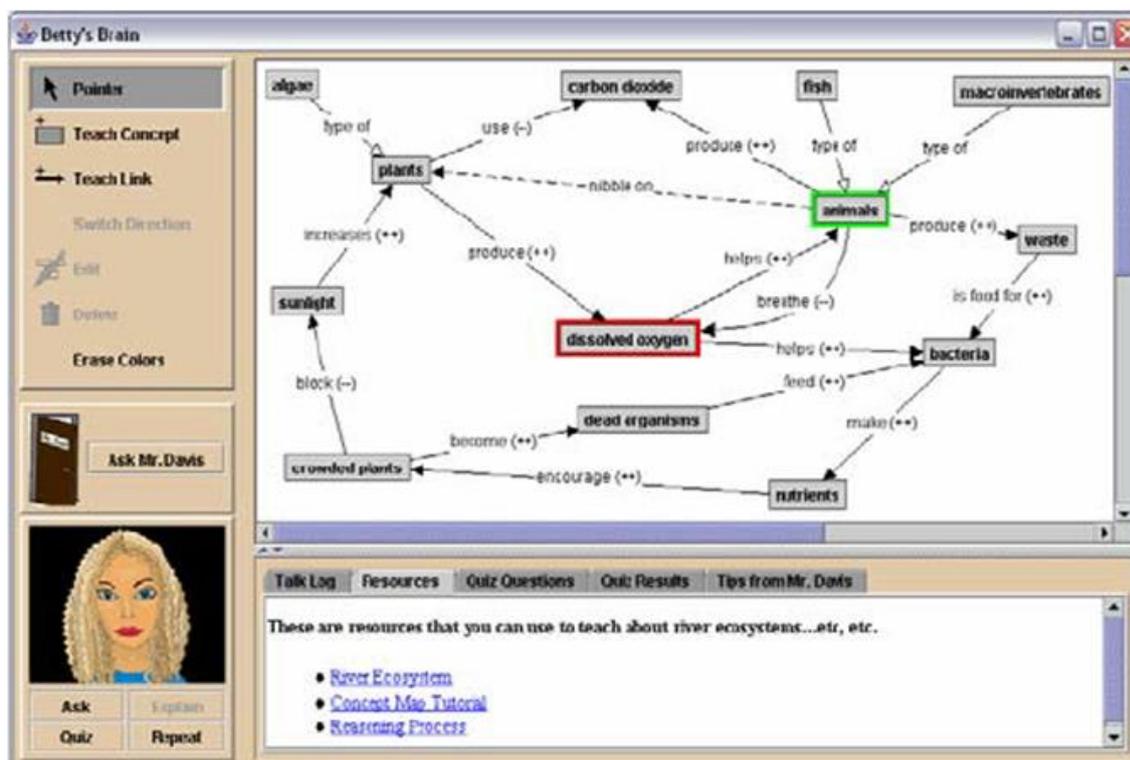


Fonte: <https://www.simstudent.org/home>

Outro exemplo interessante de uma IA aprendiz é o Betty's Brain, plataforma destinada ao ensino de temas básicos de ciências, tais como ecossistemas fluviais e mudanças climáticas, de acordo com o currículo norte-americano, desenvolvida pela Vanderbilt University (esta universidade no Tennessee tem longa tradição em pesquisa na ciência da computação e seu centro de Data Science é reconhecido mundialmente) a partir de 1998 e testada em centenas de alunos de 5º ano em escolas nos EUA. Baseada em extensiva pesquisa que envolve as teorias do sócioconstrutivismo, avaliação por pares e autorregulação da aprendizagem (Biswas et al., 2007) integradas às possibilidades que os tutores inteligentes proporcionam, a plataforma foi construída para alunos “novatos” no assunto e pouco experientes no ato de ensinar os outros. No seu *design* técnico, foram levados em conta os seguintes itens: *ensinar* por meio de representações visuais que organizam a estrutura racional do conteúdo, *usar* interações didáticas reconhecidas para organizar a atividade do aluno, *garantir* que o tutor exerça uma performance independente para dar feedback de quanto aprendeu, usando técnicas de *raciocínio*

qualitativo²² e algoritmos genéticos e manter baixos os custos de desenvolvimento de ensinar os tutores, comparado com programação convencional, implementando um modelo único de raciocínio.

Figura 29 – Betty's Brain



Fonte: <https://wp0.vanderbilt.edu/oele/bettys-brain/>

²² área da Inteligência Artificial que utiliza o raciocínio simbólico para representar funções matemáticas sem o uso de números e com relações de causalidade explicitamente modeladas.

Figura 30 – A tutoria no Betty's Brain

Fonte: <https://wp0.vanderbilt.edu/oele/bettys-brain/>

O aluno lê material especialmente preparado sobre um tema e constrói, na própria plataforma, um mapa conceitual do que compreendeu; ele propõe então questões a Betty, em forma de quizzes. Toda vez que Betty se confunde, dando uma resposta errada, ou fica em dúvida, o aluno é levado a corrigir seu mapa conceitual. O agente virtual (Betty's Brain) só atua (respondendo e confirmando ao aluno) com os elementos ensinados pelo aluno no mapa conceitual. Um professor virtual (Mr. Davis) fica disponível para ajudar tanto na construção do mapa quanto das questões a serem formuladas para Betty. O aluno aciona-o e ele entra com sugestões, a partir da base de conteúdo da plataforma. Pesquisas mostram que tanto a motivação para a aprendizagem quanto a reflexão sobre a construção do conhecimento pelo aluno é bastante ampliada na utilização desse tutor (Aleven; Azevedo, 2013).

O desenvolvimento mais recente do Betty's Brain aplica aprendizado de máquina, por meio do agrupamento (*clustering*) de alunos com comportamento semelhante em grupos distintos, para melhorar a capacidade do algoritmo em compreender a natureza diferente das dificuldades que cada aluno enfrenta. (Al Braiki, 2020). O *modelo estatístico de Markov* (um dos modelos de aprendizado de máquina citados – embora não detalhados - no capítulo anterior) é usado na decomposição do mapa conceitual em material processável pelo algoritmo do Betty's Brain.

Ambas as aplicações citadas (SimStudent e Betty's Brain) são resultado de pesquisas acadêmicas, desenvolvidas antes da viabilidade trazida pelas técnicas de redes neurais de aprendizado profundo. Não conseguimos evidências significativas sobre a evolução destes tutores no uso das técnicas de aprendizagem profunda.

Concluindo, as aplicações centradas no aluno evidenciam as possibilidades que tutores inteligentes e adaptativos oferecem, e o potencial desse modelo para avançar além da oferta direta de questões programadas ou ajustes personalizados nos passos da aprendizagem contida nas plataformas atualmente disponíveis. Os STIAs, segundo Alevén (2013), permitem reconstruir a trajetória de estudo do aluno e a ajuda sob demanda focada na resolução de problemas pode levar os alunos a adquirir conhecimento mais robusto (ou seja, conhecimento que se transfere para novas situações, dura ao longo do tempo e pode facilitar o aprendizado futuro). Quanto mais *human-in-the-loop* as aplicações se tornam, transparentes e abrangentes, flexíveis e ajustáveis por alunos e professores, mais interessantes e potentes elas ficam. Integradas com os chatbots, derivados da IA generativa, que ampliam o diálogo com o conhecimento do aluno e toda a área de conhecimento específica, podem potencializar o estudo de todos. Há um grande campo de desenvolvimento das técnicas de IA aplicadas à educação pela frente e os tutores inteligentes devem evoluir muito (Alevén, 2010).

4.4.2. Aplicações centradas no professor

Os modelos de IA baseados em PLN (processamento de linguagem natural) são centrais nas aplicações centradas no aluno bem como nas centradas no professor. Segundo Cristobal Cobo (2022), as tecnologias de PLN, que atuam criando pontes entre o texto digitado, oralizado ou manuscrito e muitas mídias, e estão no centro do desenvolvimento atual da IA, impactam a aprendizagem escolar e podem apoiar o professor e o aluno em muitas de suas práticas.

Entre as aplicações centradas no professor, elegemos os sistemas de correção automática de texto. Esses sistemas têm sido detectados como as soluções de IA que mais se aproximam da escola brasileira. Destacamos uma plataforma brasileira de correção automatizada de redações, denominada eNeuron. O eNeuron, desenvolvido em 2019 por uma startup alagoana, produz interpretações de redações e recomendações pedagógicas com destaque para redação do ENEM. O eNeuron foi adotado pela Secretaria de Educação do Estado de São Paulo, em 2020²³. Esta solução foi escolhida aqui por representar uma iniciativa nacional, proveniente do corpo docente de uma universidade pública (a UFAL), com características de adaptabilidade a diferentes contextos de avaliação de produção textual, e representa bem todo o conjunto de bots baseados nas técnicas de PLN para correção automática de textos que estão chegando ao mercado educacional.

Cada redação do ENEM deve ser oficialmente avaliada por, pelo menos, dois corretores de forma independente⁹. Tal avaliação é feita de acordo com cinco critérios, chamados de competências, que podem ser avaliados com as notas 0, 40, 80, 120, 160 e 200 pontos. A soma das notas desses critérios forma a nota de cada avaliador, que pode chegar a 1000 pontos, sendo a nota final do aluno a média aritmética da nota de dois avaliadores. Os dois professores realizam a avaliação do desempenho dos candidatos de acordo com os critérios abaixo:

- a) Domínio da norma padrão da língua escrita;
- b) Compreensão da proposta de redação e aplicação de conceitos das várias áreas do conhecimento para o desenvolvimento do tema nos limites estruturais do texto dissertativo-argumentativo;
- c) Capacidade de selecionar, relacionar, organizar e interpretar informações, fatos, opiniões e argumentos em defesa de um ponto de vista;
- d) Conhecimento dos mecanismos linguísticos necessários à construção da argumentação; e
- e) Elaboração de proposta de intervenção para o problema abordado, respeitados os direitos humanos.

²³ A solução, desenvolvida por pesquisadores da Universidade Federal da Alagoas, foi adotada em projeto-piloto pela Secretaria Estadual de Educação de São Paulo a partir de 2020

Uma vez que as notas de uma redação para o ENEM variam de 0 a 1000 pontos, em intervalos discretos de 40 em 40 pontos, o problema da correção automática de redações é tratado estatisticamente como uma *regressão linear*, como vimos no capítulo 3, e utiliza para treinamento da rede neural o erro quadrático médio (MSE), função amplamente utilizada para ampliar a precisão obtida com a técnica estatística de regressão.

Para cada tema, no eNeuron, 60% dos dados são usados como conjunto de treinamento, 20% como conjunto de validação e 20% como conjunto de testes. Há algoritmos em que os avaliadores podem realizar apenas comentários padronizados em relação a trechos específicos da redação; esses comentários são pré-definidos e estruturados com base nos problemas mais frequentes que ocorrem nas redações dos estudantes. Nesses algoritmos, os corretores podem selecionar os comentários apenas de uma lista pré-definida de comentários possíveis. Há aqueles, como é o caso do eNeuron, em que o avaliador pode realizar marcações na redação do aluno e tecer comentários em texto livre em relação aos trechos selecionados da redação. Além disto, o corretor deve realizar um comentário geral sobre a redação do aluno por áudio ou textualmente. Pesquisas atestam que o segundo método produz mais impacto de aprendizagem na produção textual. O *human-in-the-loop*, segundo Kent, aproveita-se da praticidade de uma avaliação provisória feita automaticamente pela IA para garantir um segundo olhar, que leva em conta outras características do aluno e da tarefa.

Aprofundando um pouco mais sobre no processamento de linguagem natural (PLN), as aplicações de correção automática de textos utilizam-se da técnica de *essay-grading* que, segundo Vicari (2019), é considerada um subproduto do PLN, voltada à compreensão da língua escrita e que utiliza algoritmos de análise sintática, semântica e pragmática, além de algoritmos estatísticos de PLN baseados em um robusto conjunto estruturado de textos. O PLN pode ser decomposto em cinco componentes principais: análise morfológica, análise sintática, análise semântica, análise do discurso e análise pragmática. Os cinco componentes incluem algumas subtarefas, como: decomposição de texto, análise gramática e derivação. O processo resulta em uma árvore de análise cuja raiz é a sentença; as frases nominais, verbais etc. são os nós intermediários, e as palavras são as folhas. A semântica no PLN é um processo de dedução do significado do texto. Ele executa o processo como análise semântica (determinando o sentido correto da

palavra, em caso de ambiguidade em significado) e semântica lexical (verificando sinônimos, antônimos, homônimos etc.). Por fim, a pragmática lida com a extração de informações de um pedaço de texto e divide-se em três subcampos: resolução de referência (detecção de referência), análise do discurso (determinando a estrutura do texto), interpretação dialógica (interpretando as informações do texto) (Johri et al., 2021).

A maioria das aplicações deste tipo (revisão automatizada de texto) encontradas no mercado vale-se do chamado “*Feature Engineering*”, técnica de aprendizado de máquina que utiliza intensamente os revisores humanos para garantir a acurácia na predição da correção automática. Há questionamentos se essas técnicas podem ser consideradas técnicas de IA. Já os modelos de aprendizado de máquina baseados em Redes Neurais de Aprendizado Profundo, têm a vantagem de não depender dessa mão de obra intensiva, entretanto dependem de massivos bancos de dados para serem efetivamente treinados. No contexto da língua portuguesa brasileira, tratando-se de problemas dependentes de grandes quantidades de dados relacionados ao PLN, há enorme descompasso em face da qualidade e da quantidade de ferramentas. Dessa perspectiva, as línguas mais faladas no mundo, como o inglês e o chinês, são predominantes, indicando ainda um componente de regionalização (Silva; Finger, 2021).

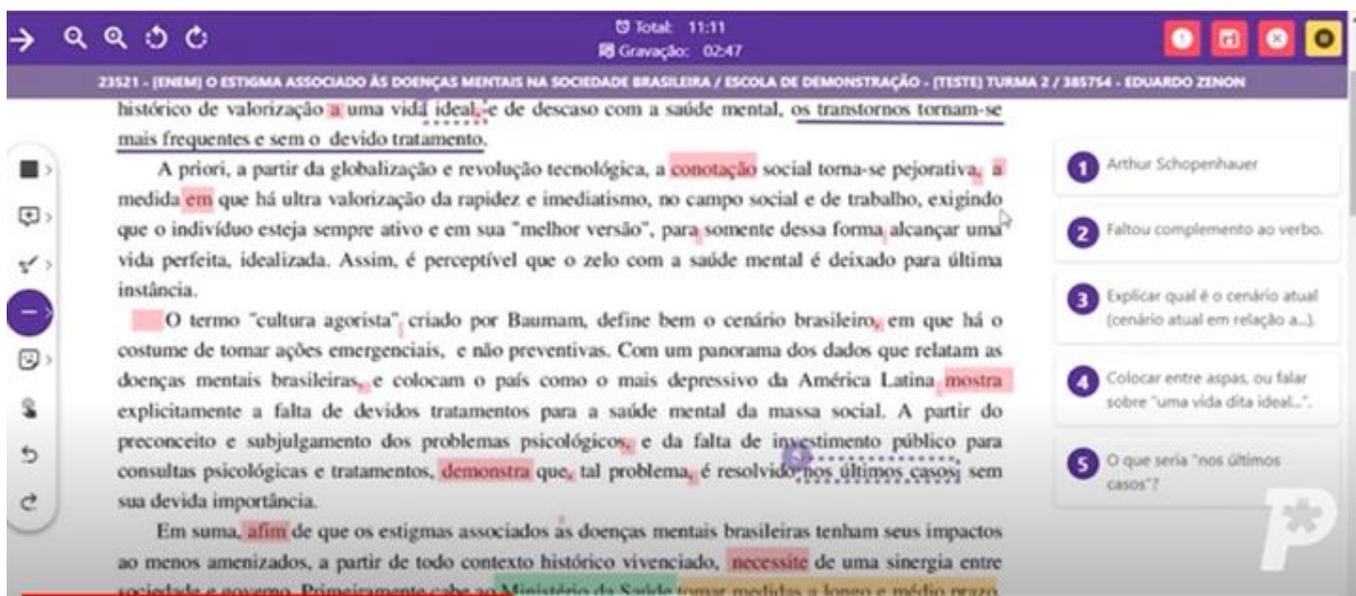
Assim, na busca que realizamos correntemente nos buscadores, e agora nos modelos de IA generativa, utilizam-se mecanismos de similaridade semântica, permitindo, por exemplo, que, quando se digita: “*transfer* para o aeroporto” o buscador procura por táxis, ônibus, locação de carros e trens, mesmo sem que se tenha mencionado qualquer dessas palavras. O sistema aprende a força da conexão entre tokens (tokens são as divisões do texto em partes, que se tornam vetores matemáticos, para serem processados), por exemplo, se pedimos algo relacionado à Igreja, o sistema (ChatGPT) “aprendeu” que padre está fortemente relacionado à Igreja, ou seja, a palavra padre aparece mais frequentemente nos textos que tratam de Igreja. O aprendizado é estabelecer uma hierarquia entre a força/peso (chamado de parâmetros) entre os tokens.

Clusterizar e classificar são duas outras operações fundamentais para os modelos de PLN, aplicados à correção automática de redações. *Clusterizar* é a operação de agrupar estatisticamente sentenças e palavras por critérios (semânticos no caso de interpretação de redações, o que vai permitir avaliar automaticamente se o texto segue o segundo critério, por exemplo, do ENEM, que exige a compreensão da proposta da redação). Vimos o *K-Means* no capítulo 3, como modelo para essa *clusterização*. Classificar é o ato de treinar amostras significativas de texto para que o algoritmo possa comparar os dados

novos aos dados classificados e devolver as análises esperadas. Aqui entra o trabalho dos corretores de redação. Eles classificam os textos pelos critérios estabelecidos, indicando notas em cada redação para cada critério. Assim, com mais redações rotuladas, o algoritmo consegue encontrar o padrão para avaliar novas redações.

No eNeuron, o professor planeja e atribui a seus alunos propostas de redações baseadas ou não nas redações anteriores no ENEM. O aluno então produz sua redação, digitalmente na plataforma e envia ao professor. Imediatamente, o sistema, usando as técnicas de PLN, faz uma primeira revisão no texto e devolve feedbacks ao aluno, seguindo os critérios definidos, no ENEM, como indica a Figura 13.

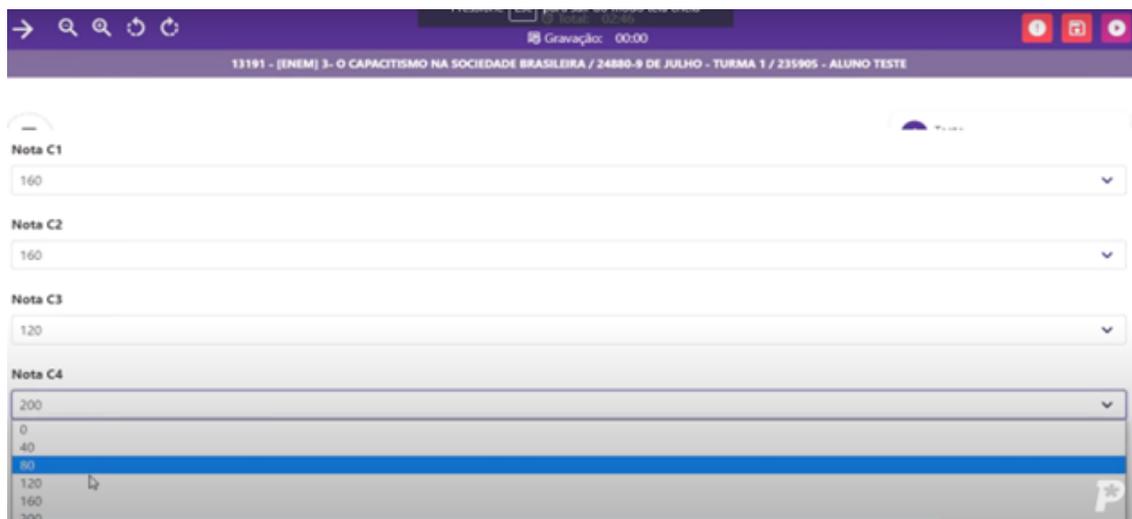
Figura 31 – Tela eNeuron – aplicação baseada em IA para revisão de textos



Fonte: <https://www.youtube.com/watch?v=CVIZwNy57PY>

Nos números destacados em azul, na Figura 31, aparecem, para o aluno, pouco depois de entregue a redação, as recomendações e os ajustes automáticos indicados pelo algoritmo do eNeuron. Na barra à esquerda, há uma palheta de ferramentas para o professor poder adicionar suas próprias recomendações e considerações (em vermelho). Na Figura 32, notas de 0 a 200 para cada um dos 5 critérios de avaliação do ENEM, citados acima, que aparecem para o professor já calculadas pelo algoritmo, e existe a possibilidade de edição do professor sobre eles.

Figura 32 – Tela eNeuron – revisão conceito ENEM



Fonte: <https://www.youtube.com/watch?v=CVIZwNy57PY>

O professor pode modificar as revisões ou optar por aceitar, na íntegra, a revisão e as recomendações oferecidas pelo sistema e devolvê-las ao aluno. Há ganhos interessantes nesse processo na formação dos jovens para a prova específica. Os desenvolvedores apontam, entre os ganhos: a. o tempo de correção cai de uma média de 10 minutos (tempo do corretor experimentado) para cerca de 10 segundos com o algoritmo. b. nível de concordância entre corretores (normalmente uma redação do ENEM passa por pelo menos dois avaliadores distintos, segundo os desenvolvedores do eNeuron). Há razoável discordância na avaliação, e esse percentual cai para significativamente, na comparação professor x sistema. Isso faz com que 30% das redações que teriam de ser enviadas a um terceiro corretor já não sejam mais enviadas (não conseguimos informação sobre a adoção, pelo INEP, de sistema análogo, na correção das milhões de redações feitas simultaneamente pelos alunos brasileiros).

Seria possível imaginarmos um sistema de IA responsivo a cultura de avaliação de produção textual de uma determinada escola ou rede de escolas? O mesmo sistema, além de corrigir segundo critérios do ENEM, poderia ser configurado para utilizar os critérios de correção de outros vestibulares, provas públicas do país e até sistemas mais privados de avaliação de produção textual, desde que devidamente treinados para tal (isso requer acesso a um bom volume de dados, embora tenhamos cada vez mais sendo usadas as técnicas de *few ou zero-shot*, aquelas que permitem treinar o modelo com poucos dados

- vistas no capítulo anterior) e que os critérios em questão sejam claros e bem definidos para permitir sua parametrização. Os desenvolvedores do e-Neuron e da Letrus, aplicação similar consultada, ainda não apresentam planos para a adaptação do algoritmo para uma personalização nos critérios de avaliação.

Algumas questões que poderiam ainda ser feitas a esses modelos? Qual seria o número mínimo de produções treinadas pelos professores no algoritmo para que as correções automáticas alcancem um padrão compatível com as revisões humanas? Há cálculos estatísticos que definem esse volume inicial para treinamento e o método estatístico mais adequado. Será que essa base de redações usadas para treinar o sistema frente ao ENEM é representativa do conjunto de produções textuais de alunos em qualquer lugar do Brasil? Segundo os desenvolvedores, o ENEM utiliza-se de um barema²⁴ de correção e da TRI²⁵ nas questões gerais, que garantem uma distribuição estatisticamente equilibrada para as nuances brasileiras.

4.4.2.1. Aplicações centradas no professor – A IA aprendiz

Vamos avançar demonstrando o potencial dos *bots* baseados em PLNs no apoio ao trabalho docente focado no processo de autorregulação e estudo autônomo do aluno. Esta perspectiva de customização dos algoritmos de IA para que cada professor / escola / rede possa adaptá-los à sua metodologia de avaliação é parte central nas premissas desta pesquisa. É neste encontro da técnica com a inteligência humana e na IA como aprendiz que reside, na opinião de vários pesquisadores (Kent, 2022), sua real efetividade, a possibilidade de que a escola incorpore a IA como estratégia didática. E para que os algoritmos de PLN possam funcionar como aprendizes, retoma-se o conceito de que a quantidade e, especialmente, a qualidade dos dados são o ativo fundamental para o pleno desenvolvimento da IA.

O uso de técnicas de IA nas aplicações de avaliação formativa baseada em rubricas em muitos contextos de avaliação de questões abertas (dissertativas), construídas por professores sem especialização em IA, pode constituir-se em oportunidade para o desenvolvimento de aplicações e para a formação de usuários de IA nas escolas. Kaldaras

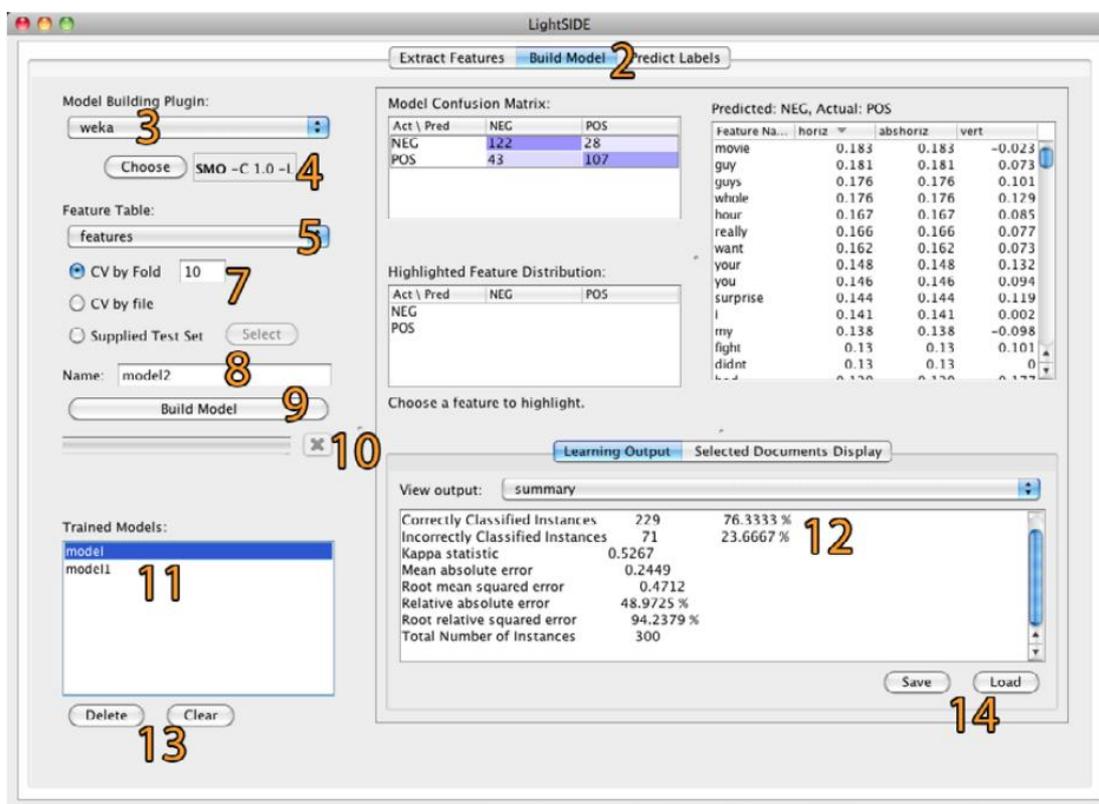
²⁴ Consiste na elaboração de uma prova em que cada uma das questões é formulada por índice de dificuldade (fácil, média, difícil, muito difícil, por exemplo), portanto, bem montada, criteriosamente formulada e submetida pelo elaborador.

²⁵ Teoria de Resposta ao Item

(2022), em um estudo da Colorado University em parceria com a Stanford University, avança na construção de um modelo de aprendizagem de máquina que permita usar IA para aplicação de rubricas construídas pelo professor, classificando e gerando feedback automático para os alunos diante de suas respostas a questões dissertativas sobre conceitos científicos, no projeto nacional de iniciação científica norte-americano denominado NGSS. Testado em grandes grupos de estudantes, o modelo aproximou-se bastante dos resultados atribuídos pelos professores, demonstrando que os modelos de processamento de linguagem natural poderão auxiliar professores e alunos na produção e na automação de análises baseadas em rubricas. Todas as rubricas construídas na pesquisa (Kaldaras, 2022) referem-se a conceitos e habilidades relativas ao conhecimento específico das ciências, não envolvendo habilidades socioemocionais, mais complexas de serem avaliadas por modelos de aprendizagem de máquina.

Selecionamos uma outra aplicação dessa IA moldável à autoria do professor, resultado de pesquisa e trabalho acadêmico: o LightSIDE, desenvolvido a partir de 2012 na Carnegie Mellon. Trata-se de uma plataforma em que o professor e o pesquisador podem comparar, conforme Figura 30, os algoritmos de aprendizado de máquina que podem ser executados na interpretação de questões descritivas e podem comparar a performance dos diferentes e possíveis modelos estatísticos nessa interpretação, apropriando-se do processo de construção da lógica de interpretação algorítmica de textos. O professor e o pesquisador também podem parametrizar e classificar palavras, fazendo a mineração dos dados textuais, além de indicar o modelo estatístico a minerar os dados textuais, indicando que pontuação e palavras de ligação devem ser eliminadas na análise como material semanticamente menos relevante, entre outras preparações para o sistema operar (Kumar; Rama, 2014). Novamente temos aqui uma área de pesquisa muito interessante que envolve a construção de algoritmos de análise de texto modeláveis pelo avaliador.

Figura 33 – Tela do LightSide da Carnegie Mellon



Fonte: <https://www.cs.cmu.edu/~cprose/LightSIDE.html>

4.4.3. A IA aprendiz e os grandes modelos de linguagem

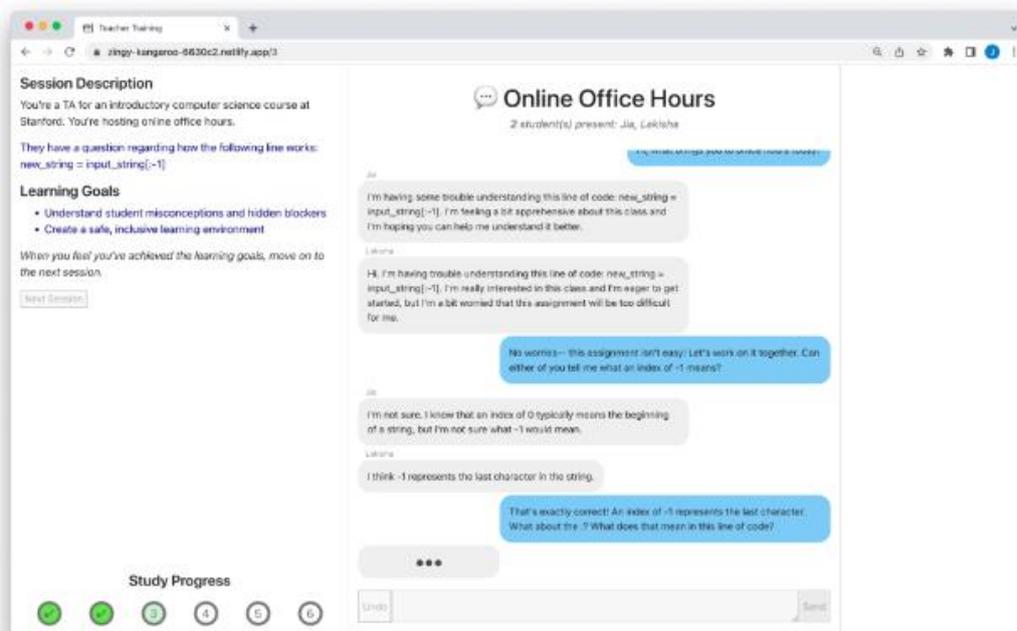
4.4.3.1 O ChatGPT como aprendiz.

A metacognição, conforme Azevedo, tem um papel crucial na educação, permitindo que os alunos se tornem autoconscientes, reflexivos e ativos. Desenvolvendo habilidades metacognitivas, torna os estudantes mais bem preparados para identificar suas forças e fragilidades, selecionar estratégias de aprendizagem efetivas, propor-se objetivos, e ajustar sua abordagem quando necessário para otimizar os resultados de seus estudos (Aleven; Azevedo, 2013). Escolhemos um último estudo, na mesma direção do que já foi feito acima neste capítulo, trazendo uma aplicação em que a IA atua como um bom aprendiz, nesse caso, aprendiz de professor.

A aplicação chama-se *GPTeach*, uma aplicação experimental construída por 4 pesquisadores da Stanford University para testar o ChatGPT na formação de novos professores, que podem praticar sua docência com alunos simulados pelo GPT. A

aplicação foi projetada para simular uma variedade de personas de estudantes, gerando sessões de treinamento docente em ciência da computação. Inicialmente se fornece ao *chatbot* o contexto da aula, o conteúdo que está sendo trabalhado com os estudantes. Em seguida, por meio de prompts, são criadas as personas dos alunos. O aluno de nome X é um estudante do Y ano do curso de Z na universidade W. Ele está fazendo a disciplina de programação, pela primeira ou segunda vez. Alimenta-se o chatbot com características do aluno em relação a seu comportamento geral (se ele é tímido, nervoso, ansioso, agitado, curioso, competitivo....) e seu estilo de estudar (se é independente, motivado, inseguro, apreensivo). Em seguida, pede-se ao GPT, ainda em preparação, para que apresente uma recapitulação do tema, permitindo que sejam dadas dicas específicas de como um professor experiente organizaria aquele conteúdo, enfatizando certos detalhes. Finalmente, o *GPTeach* gera, para o professor em formação, em nome das personas criadas dos alunos (no artigo, aparecem sempre dois alunos sendo atendidos por vez na formação *GPTeach*), questões sobre o conteúdo para o professor em formação refletir e intervir. (Markel , 2023)

Figura 34 – o TeachGPT em ação



Fonte: <https://edarxiv.org/r23bu>

O estudo, realizado em Stanford, produziu vários cenários de atuação para o professor em formação. Na figura 34, temos um dos casos em que se comparou o

engajamento do professor em formação em situações livres, em que ele intervém na dúvida do aluno com liberdade. Os professores reportam as possibilidades que esse ambiente simulado traz em termos de: ter tempo e liberdade para testar intervenções didáticas, compreender melhor a concepção do aluno ao problema, experimentar sua prática ao ter de explicar o conceito aos alunos simulados, entre outros benefícios. Já estamos vivendo, desde o advento do ChatGPT, situações em que professores alimentam conceitualmente o chatbot para então testar hipóteses de intervenção didática. Aqui há novamente um bom campo para pesquisa.

Seguindo na reflexão sobre a construção da cultura de gestão cooperada entre o professor e as agências digitais “inteligentes” (Lemos, 2020), ampliando as perspectivas de formação desses professores na gestão, apoiada por esses agentes, da aprendizagem de seus alunos, vale observar as características da cultura escolar e da cultura docente, que, embora submetidas a validações nacionais unificadas, sempre evoluem de modo distinto. Será que o professor estará capacitado e interessando para, por meio desses sistemas baseados em modelos de aprendizado de máquina, utilizar e aprimorar soluções que aliviem sua carga de trabalho avaliativo, testando as correlações que acredita necessárias? Poderá o professor avaliar e validar as correlações estabelecidas pelo sistema entre atividades avaliativas, rubricas, sequências didáticas, questões, habilidades e evidências, aprimorá-las e editá-las? Será que o sistema apresenta de modo transparente ao professor as evidências de aprendizagem que estão pressupostas para validação das avaliações, da personalização e do avanço do aluno conforme suas interações no sistema?

Veremos, no capítulo seguinte, indicações e reflexões para que escolas e educadores possam preparar-se adequadamente para os desafios que se impõem na chegada da IA.

5. MUITO SKINNER E POUCO PAPERT... UM INÍCIO PROMISSOR, UM CAMINHO NEM TANTO:

[...] como os computadores podem ser veículos de ideias poderosas e sementes de mudanças culturais, como podem ajudar as pessoas a formarem novas relações com o conhecimento que atravessam as linhas tradicionais de separação entre as humanidades das ciências... Trata-se de usar computadores para desafiar crenças atuais sobre quem pode entender o que e com que idade. Trata-se de usar computadores para questionar as suposições padrão na psicologia do desenvolvimento e na psicologia de aptidões e atitudes. Trata-se de saber se os computadores pessoais e as culturas em que são usados continuarão a ser criaturas de “engenheiros” apenas, ou se podemos construir ambientes intelectuais nos quais pessoas que hoje se consideram “humanistas” se sentirão parte, não alienados, do processo de construção de culturas computacionais. (Papert, 1980)

5.1 Premissas

Inicialmente, é importante reiterar as premissas que esta dissertação usa como base para as análises de aplicações de IA na educação, começando com a preocupação com *sistemas preditivos rígidos e pouco aderentes* à dinâmica da cultura escolar e da aprendizagem humana. A cultura escolar precisa abarcar, como propõe Michel Serres (1991), uma travessia sempre incerta.

[...] Explodir em pedaços para lançar-se a um caminho de destino incerto exige tal heroísmo que sobretudo a infância é capaz dele e é preciso, ainda, seduzi-la para que se comprometa nele. Seduzir: conduzir a outra parte. Bifurcar da condição dita natural. (...) Obrigatoriamente, bifurcar quer dizer se comprometer num caminho de travessia que conduz a um lugar ignorado. Sobretudo: jamais tomar a rota cómoda, melhor, atravessar o rio nadando. (Serres, 1991, p. 28)

A escola é o lugar privilegiado onde retiramos crianças e jovens do convívio familiar e do trabalho para se debruçarem livremente sobre o mundo. Ela deve abrir novas possibilidades para cada um destes jovens, incluindo a perspectiva constante de transformarem o mundo (Masschelein; Simons, 2020). Devemos, portanto, nos perguntar constantemente sobre o porquê e como produzir avanços no processo de ensino-aprendizagem apoiados nas tecnologias em geral, e, em particular, na inteligência artificial, e não nos deixar acomodar na lógica reducionista das predições sobre a aprendizagem futura baseada nos dados do passado tampouco automatizar processos em

que educadores humanos conduzem competentemente suas atribuições (Perrota; Selwin, 2019).

Noam Chomsky, um dos mais reconhecidos estudiosos da linguística, afirma que mesmo se pudéssemos processar todos os dados educacionais produzidos por alunos e professores, não conseguiríamos reproduzir a aprendizagem humana: “Segundo Chomsky, as crianças adquirem a linguagem muito rápido e a partir de dados muito esparsos para que possam ser explicados pelo aprendizado por reforço (Chomsky et al., 2023).

O desafio da cultura escolar e da aprendizagem humana exige manter uma leitura crítica sobre as possibilidades das técnicas de IA, experimentando-as, absorvendo-as, analisando-as e evoluindo como usuários ativos e conscientes. Uma das hipóteses desta dissertação é que consigamos, nós educadores, cada vez melhor, compreender os mecanismos pelos quais a aprendizagem é diagnosticada e prescrita pelos algoritmos de inteligência artificial, submetendo-os à análise permanente, evitando a perda da autonomia pedagógica. Segundo pesquisadores da Universidade de Edinburgh:

[...] argumenta-se que a educação futura pode tender para formas muito específicas de governança comportamental – um 'comportamento de máquina' – envolvendo combinações de teorias comportamentais radicais e sistemas de aprendizado de máquina, que parecem funcionar contra as noções de autonomia e participação do aluno, procurando intervir na conduta educacional e moldar o comportamento do aluno em direção a objetivos pré-definidos. (Knox et al., 2020, p.3).

A pesquisa sobre aplicações validadas em escolas ainda é rara e assistemática. Embora a IA esteja na base de aplicações em que alunos e professores buscam informação (nas grandes plataformas de mídia, nos sistemas de tradução, nos buscadores e agora no *ChatGPT*), há pouco consumo de aplicações efetivas de IA nos processos escolares, o que ainda inibe e limita a produção de pesquisa.

A possibilidade de maior autonomia do educador na operação dos sistemas é outro aspecto relevante. Ao longo do capítulo anterior, foram apresentadas discussões do conceito de “*human-in-the-loop*”, um termo cunhado no campo da engenharia e que hoje representa uma extensa área de pesquisa que abrange a interseção da ciência da computação, engenharia, ciência cognitiva e psicologia (Wu, 2022). Nas simulações de aviação, direção autônoma e robótica, humanos têm um papel fundamental porque influenciam os ambientes de simulação com suas ações. No aprendizado de máquina,

humanos podem treinar algoritmos e acompanhar os resultados destes, melhorando: a. a performance do modelo a partir da análise da qualidade dos dados b. a performance do modelo através de intervenções no treinamento e c. o design do sistema.

[...] Garantir que a tecnologia efetivamente responda às necessidades de alunos, professores e sistemas de ensino, sem penalizar nosso senso de ser capazes, nossa autoconfiança, e nosso direito fundamental de desenvolver nossas próprias qualidades humanas e exceder naquilo que somos aptos. Como fazer com que essa parceria homem-máquina possa funcionar do melhor modo possível? (KENT, 2022, p.5).

Kent (2022) adiciona mais um elemento nessa reflexão que ajuda a apurar nossa ótica de análise sobre a parceria homem-máquina através do seguinte questionamento:

1. O que cada parte (homem ou máquina) faz bem? O que cada parte tem mais dificuldade em fazer? Como produzir uma parceria que alavanque o processo a partir dessa simbiose?
2. Que paradigma de divisão de trabalho (entre homem e máquina) deverá se aplicado na busca de resultados específicos no processo de ensino-aprendizagem?
3. Que ganhos e que restrições existem para os diferentes usuários nos vários contextos do uso de IA na escola (o impacto do uso de tecnologias certamente não acontece de modo similar para todos)?

Lucia Santaella (2021) corrobora esse debate com a visão de que devemos reconhecer, compreender e cooperar com as diversas agências, humanas e algorítmicas, que se interconectam.

A mente moderna se tornou uma estrutura híbrida, construída de vestígios de estágios biológicos anteriores junto com recursos simbólicos de uma memória externa, hoje constituída de uma pluralidade de sistemas sígnicos produzidos graças à tecnologias cada vez mais sofisticadas e inteligentes (Santaella, 2021, p.90)

Esta conceituação implica, portanto, o olhar reflexivo sobre as aplicações de IA na educação, apoiado na visão da educação centrada no ser humano, com educadores pesquisando sobre aprendizagem e conduzindo coletiva, crítica e dinamicamente o

processo de aprendizado, visando preparar seus alunos para “aprender a aprender”; pode-se então transferir parte do trabalho escolar para plataformas digitais que operem como assistentes e seguir fazendo uso de pedagogias variadas (du Boulay, 2019).

Finalmente, cabe sempre refletir sobre o papel social da escola. A escola cumpre papel fundamental na preparação humana, longe do mundo do trabalho e da vida familiar.

Momento único de exploração do mundo, da produção cultural humana, de afirmação do sujeito e de sua autonomia intelectual (Masschelein; Simons, 2013). Nem sempre este tempo do ócio - o termo “escola” vêm do grego *skholé*, que significa tempo para o ócio (Masschelein; Simons, 2013) - é respeitado na relação da sociedade com a escola, e as tecnologias digitais acabam trazendo para dentro do ambiente escolar a busca pelo resultado e pela eficiência que descaracteriza seu papel.

Pesquisas recentes descrevem os riscos da apropriação acrítica de soluções de IA no campo da educação escolar:

Em educação, a IA tem sido frequentemente apontada como fonte para melhoria do ensino a partir de uma visão meramente utilitarista e ferramental, ou seja, unicamente para a personalização da transmissão de conteúdos e acompanhamento/avaliação da apreensão de tais conteúdos. No entanto, a IA traz em si um caráter multidimensional, permeado por benefícios e riscos, além de impactos sociais, econômicos, jurídicos e ambientais que são praticamente desconhecidos por educadores e gestores. (Gonsales, 2022, p.7).

O futuro é algo que intriga a escola mais que o presente, mas quando tratamos do pensamento crítico e da inteligência artificial, essa é uma questão preocupante. Se a chamada singularidade, definida por Ray Kurzweill (quando os avanços da tecnologia serão tão rápidos quanto irreversíveis), causa temores, temos que ter ciência que são os impactos causados pela IA no presente que devem ser endereçados com urgência; sobretudo no que tange o pensamento crítico. No decorrer dessa pesquisa, quando apresentada internamente em eventos, o tema pareceu prosaico para alguns acadêmicos; mas, garanto, ele ainda passa longe do debate no chão da escola brasileira, ou entre educadores e formuladores de políticas públicas quando configuram currículos para o desenvolvimento da criticidade dos alunos. A IA ainda é um tema da ficção científica, para a maioria deles. (Sayad, 2022, p.90).

Necessitamos de um processo reflexivo contínuo e da procura pela compreensão dos mecanismos e dos sistemas, permitindo manter instituições e educadores conscientes das possibilidades que a interação homem-máquina pode proporcionar para o avanço da educação escolar.

5.1. Cinquenta anos de tecnologias na escola

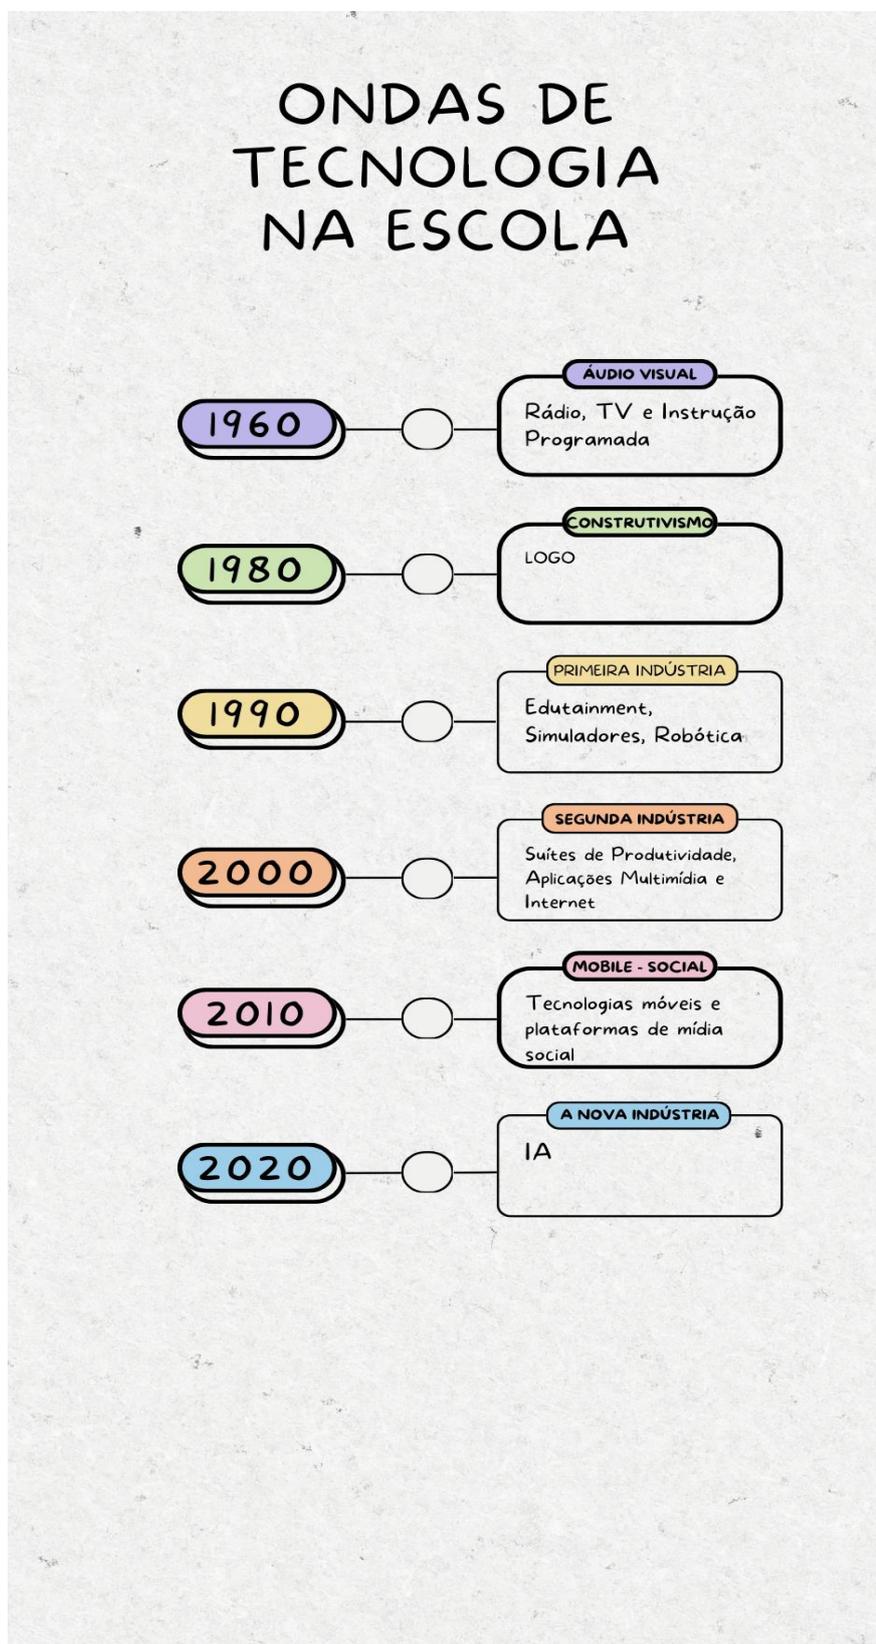
Skinner acreditava que uma sala de aula poderia ser tão automatizada quanto uma cozinha. (Watters, 2015). Seu princípio do condicionamento operante pressupõe que o reforço positivo imediato molda comportamentos e produz aprendizagem efetiva. Papert, por sua vez, propõe que, ao modelar o funcionamento da máquina, a criança, além de desmistificá-la e desvendá-la, expõe seu modo de pensar e depura-o constantemente, em um processo de autoaprendizagem.

“Pode-se dizer que o computador está sendo usado para programar a criança. Na minha visão, a criança programa o computador e, ao fazê-lo, adquire um senso de domínio sobre uma parte da tecnologia mais moderna e poderosa e estabelece um contato intenso com algumas das ideias mais profundas da ciência, da matemática e da arte da construção de modelos intelectuais”. (Papert, 1980)

Pretendemos, neste capítulo final, analisar, a partir das teorias críticas da aprendizagem e das tecnologias na aprendizagem, os caminhos percorridos pela pedagogia e pela escola brasileira na consolidação de sua cultura digital. Aparentemente o aspecto instrucional e tecnicista das tecnologias prepondera nessa trajetória. A chegada da IA traz novos desafios. Será importante que a escola e os agentes educacionais reconheçam suas relações com a tecnologia e se preparem para lidar com mais essa “inovação”, buscando aproveitar suas virtudes e evitar suas mazelas.

Ao longo dos últimos 40 anos de tecnologias e educação, onde este pesquisador atuou, seja no curso de pedagogia, seja no mercado de tecnologia educacional, seja na escola, várias ondas de inovação foram acontecendo e produzindo efeitos nem sempre desejados. A dissertação vai percorrer algumas dessas ondas, para contribuir com a análise crítica necessária à boa incorporação da IA na escola. Entre as principais ondas (e seu aparecimento como tendência na escola), temos as expostas a seguir.

Figura 35 – Ondas tecnológicas na escola brasileira



Fonte: elaboração do autor

As teorias críticas sobre educação e tecnologias em educação assumem um papel central na

“revelação das contradições e dos discursos que pretendem que a infusão das tecnologias na educação seja vista como um "progresso" inelutável, social e culturalmente asséptico, essencialmente guiada por uma concepção reificada de "inovação", onde o que vale é sobretudo a última moda, a última novidade, o último gadget, a última ferramenta, enfim, o inovar por inovar, numa pulsão tecnofílica há muito denunciada por Neil Postman” (Selwin, 2016)

Nos anos 1970, o rádio, a mídia impressa (jornais e revistas), os primeiros sistemas de instrução programada (que deram origem a várias experiências de ensino apostilado) e especialmente a televisão ocupavam a reflexão dos teóricos de educação como mídias possíveis para propor e acelerar a aprendizagem

Evidentemente que a escola não poderá temer a (oni)presença dos meios de comunicação, muito menos repetir a década de 1970, quando ficou encantada com a tecnologia educacional. Foram inúmeras e velozes as mudanças introduzidas nas escolas com base nas novas teorias educacionais em moda à época. As máquinas de ensinar, instruções programadas, projetos de ensino proliferaram em todas as áreas e em todo o país, sem uma transformação fundamental do processo educativo. (PRETTO, 2013, p. 127).

Na década de 1980, as faculdades de educação em diversos estados brasileiros se debruçaram sobre as relações entre o construtivismo inspirado em Piaget e o construcionismo de Papert (Papert estudou com Piaget em Genebra e dedicou parte de sua obra ao biólogo suíço). Segundo Valente,

Na noção de construcionismo de Papert existem duas ideias que contribuem para que esse tipo de construção do conhecimento seja diferente do construtivismo de Piaget. Primeiro, o aprendiz constrói alguma coisa, ou seja, é o aprendiz por meio do fazer, do "colocar a mão na massa". Segundo, o fato de o aprendiz estar construindo algo do seu interesse e para o qual ele está bastante motivado. O envolvimento afetivo torna a aprendizagem mais significativa. (Valente, 2008)

As escolas, públicas e privadas e os órgãos de educação pública entraram na década de 1990 experimentando projetos de ensino de Logo como importantes experiências de informática educativa. Chegavam os computadores pessoais (PCs) ao mercado. O que impediu a escola brasileira em seguir apostando no uso do computador como uma máquina a ser ensinada e usada de modo autoral? Segundo Valente, a principal razão é que “a abordagem que usa o computador como meio para transmitir a informação ao aluno prevaleceu porque mantém a prática pedagógica vigente”.

A concepção de currículo vigente formata uma visão pedagógica que pode tanto limitar o papel das tecnologias como ferramenta, como libertá-las como instrumento de emancipação (Valente; Almeida, 2013).

Assim, tais concepções de currículo implicam superação da abordagem pedagógica, alicerçada na transmissão de informações, e orientam para a prevalência de um currículo construído na prática social, que engloba conteúdos, métodos, procedimentos, instrumentos culturais, experiências prévias e atividades, com vistas a propiciar o desenvolvimento da aprendizagem em ambientes que instigam a curiosidade epistemológica, estimulam a pergunta, a invenção/reinvenção e a transformação, como forma de avançar no conhecimento (VALENTE; ALMEIDA, 2013).

O olhar sobre a tecnologia depende de como funciona a escola, sua visão e suas práticas pedagógicas. De fato, para conviver com as incertezas e as ambiguidades dessa realidade, as pessoas precisam aprender a lidar com os fluxos contínuos de novas informações, com a evolução do conhecimento requerido para desempenhar suas funções no mundo do trabalho, com as mudanças na profissão e de área de atuação profissional, com o trabalho em equipe e com a tomada de decisões, diante das situações desafiadoras, tornando-se necessário repensar a concepção de currículo, cujas prescrições não dão conta de tratar do imprevisível. Contudo, se o currículo como prescrição está terminando, temos de admitir que a nova era do currículo no novo futuro social está ainda longe de ser bem evidente. (Goodson, 2008).

Atendendo a essa lógica da transmissão do conhecimento, as soluções baseadas em entretenimento educativo - conhecido naquele período como *Eduainment*²⁶ e que

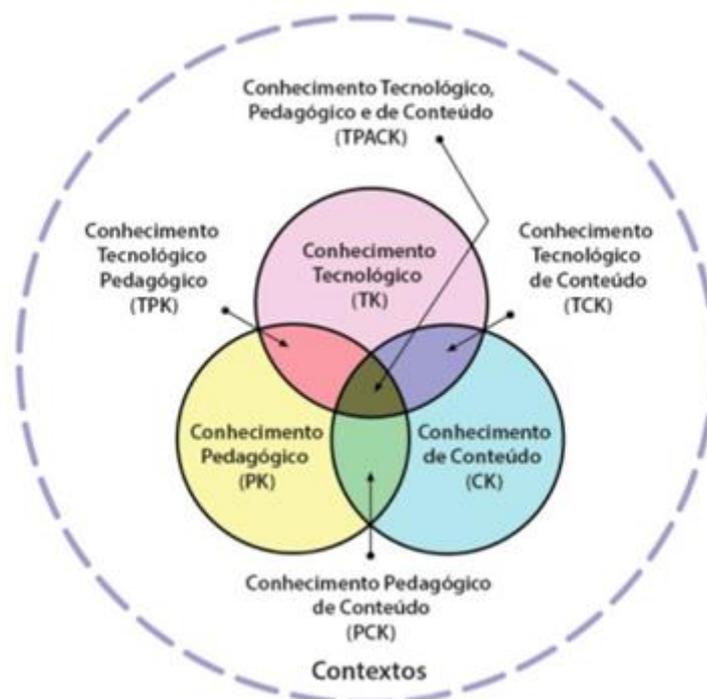
²⁶ *Eduainment* é a junção das palavras *Education* e *Entertainment*. Em 1990 produtores de jogos educativos de varejo ocupam espaço no incipiente mercado de tecnologia e educação formal, oferecendo soluções de que a tecnologia pode tornar o aprendizado mais divertido.

hoje nos remete às práticas de gamificação - e conteúdo pronto passaram a ocupar os recursos computacionais que iniciativas com a linguagem LOGO haviam tentado garantir. Após um início promissor, parece que se perdeu o rumo, o que leva a algumas indagações.

“Se a principal vantagem de usar a tecnologia é que ela será divertida para os alunos ou mais ‘motivadora’, considere seriamente porque isso acontece. Descobriremos que a tecnologia muitas vezes diminui a necessidade de atender seriamente ao conhecimento prévio, de usar estratégias metacognitivas, questionar ideias, gerar exemplos, comparar soluções alternativas, lidar com experiências, fazer sentido dessas novas experiências, fazer novas conexões e analisar se as conexões anteriores senso.” (Olson et al. 2001)

Aparentemente, a escola brasileira ainda não conseguiu sair da lógica lúdico-instrucionista. É sempre necessário que se considere esse processo de apropriação tecnológica na formação continuada do professor, em uma perspectiva que enfatize ações que privilegiam o aprender-fazendo e refleta sobre a prática pedagógica com o uso das tecnologias digitais de modo a propiciar a (re)construção da base do conhecimento profissional representado pelo *TPACK* na figura 36 (Zeichner, 1998 apud Lima, 2020). Essa formação continuada, moldada no aprender-fazendo não prevalece nem na rede pública nem na privada.

Figura 36 – TPACK



Fonte: www.tpack.org

A partir do modelo construído por Lee Schulman em 1986, chamado PCK (*Pedagogical Content Knowledge*), que fundamentava a necessidade da formação do professor nas teorias de aprendizagem, nas características didáticas da área de conhecimento específica e no entrelaçamento entre elas, que se constitui em um novo tipo de conhecimento, Mishra e Koeller propõem, em 2006, um novo componente, o tecnológico, que produz novos entrelaçamentos. O ensino de ciências, por exemplo, além de suas características básicas, alinhadas às possibilidades didáticas derivadas da leitura que cada diferente teoria de aprendizagem faz da didática das ciências, agora passa a contar com um campo adicional, mediado pelo uso de tecnologias, que modificam tanto a produção científica quanto a didática específica de seu ensino. A possibilidade de se usar simulação digital para a reprodução e a análise de fenômenos naturais, por exemplo, permite novas aproximações do aluno com o conhecimento outrora representado por esquemas, imagens, filmes e textos. O acesso a bases de dados reais para análise dos fenômenos e até mesmo a captura física desses dados, por meio de sensores, pelos alunos amplia-se de tal modo que se configuram novos arranjos didáticos e cognitivos que precisam ser estudados. As teorias de aprendizagem podem ser revistas à luz dessas novas

perspectivas didáticas do ensino apoiado em tecnologias. Essa perspectiva didática atravessada pela tecnologia não tem sido devidamente explorada nos programas de formação docente, seja no ambiente acadêmico, seja na formação em serviço.

Observe-se aqui que se inicia um momento de pressão sobre os currículos escolares que começam a ser definidos de fora da escola, pelos conteúdos das chamadas práticas sociais e suas determinações. As políticas públicas de formação de currículo perdem a força de definir conteúdos - e mesmo das habilidades da aprendizagem escolar - e começam gradualmente a sondar o que é ofertado pelos meios de comunicação de massa, ou são invadidos por eles. (Moreira; 2012)

À novidade do *edutainment*, incorporaram-se as ferramentas de produtividade - conhecidas inicialmente como ferramentas de escritório - as suítes de edição de texto, imagem, planilha e apresentação eletrônica. Estimula-se, então, um cunho instrumental ao projeto curricular da tecnologia educacional. A ideia da ferramenta e da respectiva fluência instrumental passou a fortalecer-se.

Um resultado adicional é que, essa imagem do sujeito descontextualizado tem sido usada para sublinhar as noções neoliberais do aluno como produto, com o engajamento digital visto como parte de uma “caixa de ferramentas” de competências consideradas portáteis, infinitamente transferíveis e, portanto, residentes apenas no indivíduo. (Gourlay, 2016)

Chega então a introdução das multimídias nas salas de aula e na produção escolar em geral, com o uso simultâneo de mídias como texto, vídeo, áudio e interatividade integrados em uma só aplicação. A escola passa a incorporar metáforas da comunicação e do design em suas práticas. Os CD-ROMs podiam favorecer representações orgânicas e não-lineares do conhecimento. A produção de multimídias, por parte do aluno, pode desenvolver nele a autoconstrução das linguagens envolvidas no processo (Incontri, 1996). É preciso alfabetizar-se o aluno nessas novas linguagens.

A estrutura que configura os sinais e códigos visuais é de natureza distinta da língua, a tal ponto, que uma pessoa pode saber ler e escrever signos verbais, mas não signos audiovisuais. O processo de leitura da imagem (sonora, audiovisual) implica, por um lado, a aprendizagem dos elementos que a configuram e, por outro, a possibilidade de converter-se em um comunicador em potencial. (Marinho, 1987)

Buckingham nos coloca um desafio ainda maior em relação à educação para as mídias, que levou a Inglaterra a incorporar, no início dos anos 1980, uma disciplina de educação midiática no currículo obrigatório das escolas secundárias no país e formar, em programas de pós-graduação, milhares de professores para poderem operar tecnicamente sobre esse conteúdo. Segundo ele,

“os formuladores de política tendem a ver alfabetização midiática como mera alternativa palatável a regulação centralizada, seu compromisso com ela muitas vezes se restringe a um conjunto de boas intenções retóricas. A alfabetização midiática significa muito pouco sem um programa sistemático de educação midiática”.

Seguimos um caminho parecido aqui no Brasil. Foram mantidas essa cultura e essa apropriação crítica tão indispensável na formação do homem contemporâneo, no campo da retórica e da utilização instrumental. (Buckingham, 2021).

Tudo se amplia a partir do final da década de 1990 (com importante atraso na rede pública em relação à rede privada - o acesso é ainda hoje precário ou nulo em cerca de 40% das escolas públicas - dados da pesquisa Tic Educação 2022²⁷ - com o advento da internet, que revoluciona o acesso à informação e as práticas de produção de texto, de leitura, de pesquisa, de comunicação e de produção coletiva de conhecimento. Nesse momento, “a educação poderia ser concebida como um sistema aberto, com mecanismos de participação e descentralização flexíveis, com regras de controle discutidas pela comunidade e decisões tomadas por grupos interdisciplinares” (Moraes, 1997, p. 68). Mas, “o currículo tradicional, com seu ritmo e seus rituais, ainda é um significativo ponto de estrangulamento; os mecanismos em voga de formação de professores precisam ser urgentemente revistos e atualizados”. (Santos, 2006)

Avança-se, então, para o emprego dos dispositivos móveis, tablets, notebooks, smartphones e das lousas digitais na sala de aula. Pulveriza-se o acesso ao conhecimento e se produzem estímulos para um ensino híbrido e ubíquo. “O que caracteriza o leitor ubíquo, uma das consequências desta ubiquidade no ensino, é uma prontidão cognitiva ímpar para orientar-se entre nós e nexos multimídia, sem perder o controle da sua presença e do seu entorno no espaço físico em que está situado” (Santaella, 2016). A aprendizagem ubíqua desafia a educação formal, criando oportunidades de acesso à

²⁷ Publicação anual do NIC-BR, com indicadores e estatísticas sobre a adoção de tecnologias na educação

informação no momento da necessidade efetiva, produzindo impacto no processo formal, mas requisitando dele a mediação necessária para a consolidação da informação em conhecimento, para o amadurecimento desse novo leitor-pesquisador diante da profusão de fontes, da formação crítica desse aluno na ubiquidade do acesso.

Estima-se que essa ubiquidade traria novas perspectivas ao trabalho em sala de aula, mediante um esforço de formação docente.

Desse modo, acredita-se que os futuros professores devam vivenciar situações que envolvam atividades com o *mobile-learning* durante a sua formação. Com isso, terão possibilidades para experimentar, explorar e criar conteúdo a partir dos dispositivos, com vistas a perceber e reconhecer a diferença entre educação a distância e aprendizagem móvel. Desse modo, o docente poderá escolher o melhor momento para planejar e implementar tarefas que envolvam a aprendizagem escolhida de acordo com o contexto, o público, a estrutura e os equipamentos disponíveis. Compreende-se que, somente com o conhecimento e a propriedade acerca de um tema e o tipo de aprendizagem, que se pode decidir e escolher a melhor estratégia de ação para desenvolvê-la em sala de aula. (Silveira Sonogo; Behar, 2018)

Mas, com a evolução das plataformas de mídia social²⁸, ampliando a perspectiva de análise sobre o poder de mídia destas plataformas, sua sedução deliberada à atenção de alunos (e de todos nós) passa a construir nova resistência ao uso de dispositivos móveis na sala de aula (Bucher, 2016). Tudo volta a reforçar a centralidade do conteúdo e da transmissão convencional deste.

A pesquisa acadêmica aponta a oscilação entre a prescrição de uma nova pedagogia e a crítica ao imobilismo, a resistência, a inércia.

“Nesse contexto, a aula expositiva deixou de ser importante, uma vez que o aluno consegue acessar essa mesma informação de modo mais interessante e, inclusive, com mais detalhes, incluindo o uso de recursos visuais, que facilitam a sua compreensão” ou o que as instituições de ensino estão proporcionando aos seus estudantes? Nada muito diferente ou inovador. Pelo contrário, ainda oferecem uma educação tradicional, baseada na informação que o professor transmite e em um currículo que foi desenvolvido para a era do lápis e papel. (Valente, 2018)

²⁸ adotamos aqui essa denominação para WhatsApp, Facebook, Instagram, Twitter, entre outras

Neste caso, tanto na formação de professores, quanto na relação professor-aluno, em sala de aula, parece ser importante o que Freire salienta ao dizer que “ensinar exige saber escutar”. E continua chamando a atenção para o fato de que asfixiando a própria liberdade e, por extensão, a criatividade e o gosto da aventura do espírito. A liberdade de mover-nos, de arriscar-nos vem sendo submetida a uma certa padronização de fórmulas, de maneiras de ser, em relação às quais somos avaliados. (Freire, 1996, p. 128).

Não obstante a literatura registre duas concepções de currículo - técnica planificada e prática emancipatória (Pacheco, 2000) - o currículo que se coaduna com a cultura digital se aproxima da segunda concepção, caracterizada como um processo de construção sócio cultural (Pacheco, 2000; Moreira, 2012), uma prática de produção ativa da cultura que interrelaciona conhecimentos sistematizados com conhecimentos do cotidiano, materiais didáticos, tecnologias, interações e recursos mobilizados no ato pedagógico. (Almeida, 2018)

Houve, ao longo destes 50 anos, uma enorme evolução da qualidade do debate. Superamos a dicotomia entre o tecnomessianismo e o tecno-catastrofismo, para uma visão de maior reflexão teórica também a partir da prática, como sustentam Almeida e Moreira (2018). Mas a reflexão acadêmica não alcança o professor. Na área pública, adotamos estratégias a partir de definições construídas centralizadamente, induzindo pouca autonomia da escola, do município e por vezes do próprio estado e “incorporamos sugestões menos apropriadas ou ideais para, pragmaticamente, “dotar de movimento” a proposta”. (Amiel et al., 2018). Na rede privada, invade-se a realidade do professor e “para além dos discursos, parece faltar um compromisso diário, também nas universidades, de valorização dos professores e da sua profissão (Novoa, 2018).

Em particular, rótulos da tecnologia educacional (Selwyn, 2015) – por exemplo, “aprendizagem adaptativa”, “metodologias ativas” e “pensamento computacional”, apenas para mencionar alguns dos mais recentes – tendem a ocultar formas contestáveis de reducionismo (por exemplo, a redução da discussão sobre a educação a uma discussão sobre a aprendizagem) e determinismo tecnológico.

Postman postula um conjunto de perguntas que ajudam a questionar, de um modo original, o caminho, aparentemente inexorável, da inserção tecnológica na vida humana e claro, na vida escolar.

1. Qual é o problema para o qual a tecnologia se afirma como solução?
2. De quem é o problema?

3. Que novos problemas serão criados com a resolução do problema velho?
4. Que pessoas e instituições serão mais prejudicadas por esta nova tecnologia?
5. Que mudanças de linguagem estão sendo promovidas por essas novas tecnologias?
6. Que redirecionamentos de poder econômico e político podem resultar dessa nova tecnologia?
7. Que usos alternativos poderiam ser feitos da tecnologia?

Segundo Selwin, a tecnologia não é neutra e sempre favorece fins específicos enquanto obscurece outros. As tecnologias são produtos de uma indústria em expansão e que envolve muitos “interessados”, entre os quais se destacam as grandes editoras, os conglomerados educacionais e os grandes players (Ferreira, 2016). A ideia da tecnologia como ferramenta estimula o que Morozov chama de “solucionismo tecnológico” que é o inebriamento pela ferramenta-solução que passa a ficar, quando incorporada, à procura de um problema para resolver (Morozov, 2020).

Cada vez que o ‘digital’ é usado como um modificador ou como um termo qualificador em qualquer um dos sentidos sugeridos acima, ele exerce um efeito normativo. Em primeiro lugar, o ‘digital’ sinaliza progresso, desenvolvimento e mudança. Cidadania, alfabetização e direitos não são propriedades fixas, mas estão consagrados na lei, nas normas sociais e nas práticas sociais. Quando o modificador ‘digital’ é adicionado, tais práticas parecem estar em fluxo e agora não podem mais ser compreendidas sem referência ao digital. (Pangrazio; Sefton-Green, 2021). E agora, com a chegada da inteligência artificial?

5.3. Recomendações e perguntas que podem orientar educadores e instituições a pensarem em como utilizar tecnologias baseadas em IA

5.3.1. Reflexões para as instituições escolares

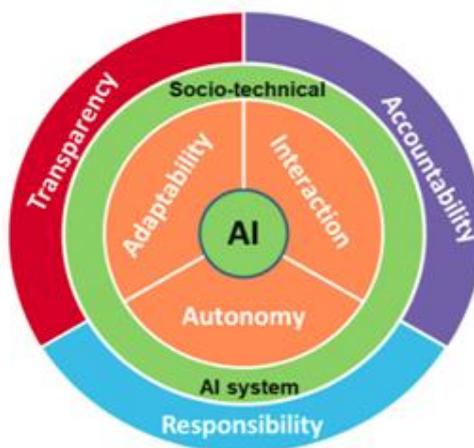
Como avançar e incluir entre os desafios da escola, pública e privada, dos professores, dos processos de formação docente e das políticas públicas de educação, as questões que as soluções baseadas em IA trarão? Mais uma tecnologia que chega e que adiciona novas questões ao quadro de expectativas e receios que as recentes ondas tecnológicas trouxeram. Vale a pena se fazer perguntas. Talvez seja preciso fazer-se novas perguntas.

O argumento é que as tentativas de prever e automatizar aspectos do desempenho educacional por meio da aplicação de tecnologias de IA fazem parte de formas complexas de reducionismo. Embora isso não seja em si uma afirmação original, há algo novo na maneira como métodos computacionais como redes neurais, "propriedade" de uma pequena elite de especialistas em dados impulsionados por mentalidades e incentivos comerciais, sobrepõem múltiplas camadas de complexidade algorítmica em entendimentos simplificados (e altamente controversos) da aprendizagem humana. (Perrotta,2019)

No que se refere a rastrear a aprendizagem seria necessária uma intensa discussão envolvendo a ciência da computação, a avaliação educacional e a pesquisa crítica em educação. As descobertas anunciadas pelo uso de aprendizado de máquina na aprendizagem escolar são contestáveis, sob diversos aspectos (Perrota; Selwyn, 2019). "A menos que discutamos seriamente nossas premissas filosóficas antes que a IA se mova de maneira significativa para a sala de aula, limitaremos o escopo, a eficácia e as contribuições positivas que a IA pode trazer para o aprendizado." (Aiken; Epstein, 2000).

Em um mundo onde as máquinas podem encontrar (todas) as respostas, torna-se imperativo que todas as pessoas sejam bem treinadas para perguntar e avaliar as respostas. (Dignum, 2019). Antes de se comprometer com um futuro em que a IA permeie a aprendizagem, educadores e tecnólogos precisam orientar a sociedade e os governos para entender o potencial das implicações sociais e éticas dessa tecnologia. Em vez de se preocupar com a IA a dominar o mundo (ou pelo menos a sala de aula), como no medo da singularidade tecnológica alertada por alguns (Bostrom et al., 2016), a principal preocupação deve ser a prontidão para aceitar cegamente a tecnologia como um dado, o que leva a problemas, incluindo no uso indevido, excesso de confiança, ignorância ou subutilização, abuso e uso sem preocupação com as consequências (Parasuraman; Riley, 1997).

Figura 37 – modelo de análise de impacto de sistemas de IA



Fonte: <https://tinyurl.com/yfzrwxjs>

Dignum desenvolveu um modelo de análise do impacto da IA baseado em três eixos, como vê-se na figura 37.

Prestação de Contas refere-se à necessidade de o sistema prestar contas, ou seja, explicar e justificar suas decisões aos usuários e outros atores relevantes. Para garantir a responsabilidade, as decisões devem ser derivadas e explicadas pelos mecanismos de tomada de decisão usados. Também requer que os valores morais e normas sociais que informam o propósito do sistema, bem como suas interpretações operacionais, tenham sido expostos de forma aberta, envolvendo todas as partes interessadas.

A *responsabilidade* refere-se ao papel das próprias pessoas em sua relação com os sistemas de IA. À medida que a cadeia de responsabilidade cresce, são necessários meios para vincular as decisões de um sistema de IA aos seus dados de entrada e às ações das partes interessadas envolvidas na decisão do sistema. Responsabilidade não é apenas fazer regras para governar máquinas inteligentes, mas também sobre o papel das pessoas e das instituições nos efeitos do desenvolvimento e uso do sistema.

A *transparência* indica a capacidade de descrever, inspecionar e reproduzir os mecanismos pelos quais os sistemas de IA tomam decisões e aprendem a se adaptar ao seu ambiente e à proveniência e à dinâmica dos dados que são usados e criados pelo sistema. Além disso, a confiança aumentará se pudermos garantir a abertura dos negócios em tudo o que está relacionado ao sistema. Como tal, ser transparente também é ser

explícito e aberto sobre escolhas e decisões relativas a sistemas proprietários ou de código aberto, fontes de dados, processos de desenvolvimento e partes interessadas. As partes interessadas também devem estar envolvidas nas decisões sobre todos os modelos que usam dados humanos, afetam seres humanos ou têm outros impactos moralmente significativos. (Dignum, 2019)

Como diz Chomsky, em recente artigo sobre o ChatGPT e a essa onda de IA generativa, “o importante não é frearmos o desenvolvimento dessas novas tecnologias, até porque isso redundaria impossível, mas sim educar as pessoas para que estejam preparadas para compreender e atuar para mitigar seus efeitos negativos”. É aí que reside a força da educação digital. A educação deve focar o entrelaçamento de três tipos de alfabetização que fomentarão as competências requisitadas pelas novas vagas de trabalho (Aoun, 2017), expostas a seguir.

- *Alfabetização de dados*: preparar os estudantes para ler, analisar, interpretar e usar uma vasta gama de dados, como a *Big Data*, orientando-se diante do constante fluxo e bombardeio de informações em seus dispositivos digitais e extraindo dessas informações seus significados e contextos sociais, econômicos, políticos e culturais.
- *Alfabetização tecnológica*: fornecer aos estudantes a compreensão dos princípios de codificação, linguagem de programação e engenharia a partir dos quais as máquinas e os programas digitais funcionam.
- *Alfabetização humana*: preparar os estudantes para o meio social. Enquanto a alfabetização em dados nos mostra o “como”, a alfabetização humana nos ensinaria o “porquê”. Ela envolve o ensino de humanidades ligadas às artes liberais, à comunicação social e digital e ao design. Em um mundo em que os limites entre a tecnologia e a humanidade estão evaporando, até um engenheiro precisa desenvolver interfaces humanas, e um programador precisa saber contar histórias.

Os temores iniciais de que as máquinas substituiriam os humanos foram seguidos pela percepção de que as pessoas já estão trabalhando ao lado de máquinas e é preciso entender muito melhor como os humanos poderiam cooperar com a IA de maneiras que contribuem para sua inteligência e bem-estar. Há cada vez menos dúvidas de que a IA reconfigura a distribuição de inteligência, trabalho e poder entre humanos e máquinas, e

assim novos tipos de capacidades são necessários (Luengo-Oroz et al., 2020). No entanto, essas capacidades ainda são pouco identificadas e compreendidas. Que tipos de capacidades as pessoas precisam para uma cooperação bem-sucedida, com bom funcionamento e bem-estar em um mundo interconectado e em rápida mudança num mundo permeado com IA? Como podemos conceituar essas capacidades? Como podemos ajudar os alunos a desenvolvê-los? Como podemos empiricamente estudar e avaliar o seu desenvolvimento?

“um projeto científico, técnico e político que visa tornar as pessoas mais inteligentes com computadores, em vez de tentar tornar os computadores mais inteligentes do que pessoas. Assim, a inteligência coletiva não é o contrário de estupidez coletiva nem o oposto da inteligência individual. Isso é o oposto da inteligência artificial. É uma forma de crescer um renovado sistema cognitivo humano/cultural, explorando nosso crescente poder de computação e nossa memória onipresente.” (Peters, 2015, p. 261 apud Jandric et al., 2019, p. 164).

5.3.2. Reflexões para educadores:

O Ministério da Educação dos EUA, (*US Department of Education*) lançou, em maio de 2023, um conjunto de recomendações a educadores e agentes públicos sobre a IA e o futuro do ensino e da aprendizagem. A publicação convoca esses educadores, que já estão submetidos aos algoritmos baseados em aprendizado de máquina em suas vidas pessoais e em muitos casos, na própria sala de aula, a buscarem referências e se prepararem para a intensificação do uso desses algoritmos nas práticas escolares. O documento articula três razões para justificar sua publicação, mencionadas a seguir.

1. A IA pode permitir, especialmente na educação pública, alcançar prioridades educacionais de maneiras melhores, em larga escala e com custos mais baixos.
2. a urgência e a importância surgem por meio da conscientização dos riscos no nível do sistema e da ansiedade sobre potenciais riscos futuros.
3. a urgência surge devido à escala de possíveis consequências não intencionais ou inesperadas.

Em seguida, foram publicadas várias questões dirigidas aos educadores para que reflitam sobre a adoção em curso ou sobre as possibilidades de adoção de soluções baseadas em IA.

- Até que ponto a IA está permitindo a adaptação aos pontos fortes dos alunos e não apenas aos déficits? A IA está permitindo melhor suporte para alunos com deficiência e alunos de inglês?
- Como a voz dos jovens está envolvida na escolha e uso da IA para aprendizagem?
- A IA está levando a atividades mais restritas (por exemplo, problemas de matemática processual) ou a atividades mais completas como as atividades destacadas no Plano Nacional de Tecnologia Educacional (NETP), que enfatiza recursos como aprendizado personalizado, aprendizado baseado em projetos, aprendizado de visualizações, simulações e realidade virtual, bem como aprendizagem em toda a escola, comunidade e ambientes familiares?
- A IA está apoiando o aluno como um todo, incluindo as dimensões sociais da aprendizagem, permitindo que os estudantes sejam participantes ativos em pequenos grupos e aprendizagem colaborativa? Por exemplo, a IA contribui para aspectos da colaboração estudantil que valorizamos, como atenção, envolvimento mútuo, ajuda dos colegas, autorregulação?
- Quando a IA é usada, a privacidade e os dados dos alunos são protegidos? Os alunos e seus tutores são informados sobre o que acontece com seus dados?
- Quão fortes são os processos ou sistemas para monitorar o uso de IA pelos alunos para bloquear vieses ou outras consequências indesejáveis do uso de IA pelos alunos?
- Estão disponíveis pesquisas ou avaliações de alta qualidade sobre os impactos do uso do sistema de IA para aprendizagem do aluno? Sabemos não apenas se o sistema funciona, mas para quem e em que condições?

Outra estratégia relevante para se lidar, na escola, com esta nova tecnologia, é ensinando-a. Segundo Paulo Freire, “Quem ensina aprende ao ensinar e quem aprende ensina ao aprender” (Freire, 1996). A Unesco produziu em 2021 um estudo envolvendo 20 países que já tem currículos de IA aprovados e em execução em seus sistemas educacionais. Nesse estudo, conforme quadro 5, apresentam-se documentos aprovados nos diversos encontros internacionais sobre educação, ressaltando-se o mais conhecido,

o Consenso de Beijing de 2019²⁹. O Consenso aprova uma abordagem humanística para “preparar todas as pessoas com os valores e as habilidades apropriadas necessárias para uma colaboração homem-máquina eficaz na vida, aprendizagem e trabalho, e para o desenvolvimento sustentável”

Foram recomendadas abordagens específicas e interdisciplinares para a IA na educação, incluindo a construção de currículos de TIC existentes, bem como a integração de análises das oportunidades e dos impactos da IA nos cursos de ciências humanas, ciências naturais e artes (Miao; Holmes, 2021).

Quadro 5 - competências consideradas críticas para uma alfabetização em IA.

Competência	Descrição/resultados de aprendizagem
1. Reconhecimento da IA	Distinguir entre artefatos tecnológicos que utilizam e não utilizam IA.
2. Compreensão da inteligência	Analisar e discutir com senso crítico os recursos que tornam uma entidade “inteligente”. Discutir as diferenças entre inteligência humana, animal e de máquina.
3. Interdisciplinaridade	Reconhecer que há muitas maneiras de pensar e desenvolver máquinas “inteligentes”. Identificar uma variedade de tecnologias que utilizam IA, incluindo tecnologia que abrange sistemas cognitivos, robótica e Aprendizagem de Máquina.
4. IA geral vs. restrita	Distinguir entre IA geral e restrita.
5. Pontos fortes e fracos da IA	Identificar os tipos de problemas nos quais a IA se distingue ou não. Determinar quando é apropriado utilizar a IA e quando impulsionar as habilidades humanas.
6. Imaginar a IA do futuro	Imaginar possíveis aplicações futuras de IA e considerar os efeitos de tais aplicações no mundo.
7. Representações	Entender o que é uma representação de conhecimento e descrever alguns exemplos dessas representações.
8. Tomada de decisão	Reconhecer e descrever exemplos de como os computadores raciocinam e tomam decisões.
9. Etapas da Aprendizagem de Máquina	Entender as etapas envolvidas na Aprendizagem de Máquina, bem como as práticas e os desafios que cada etapa envolve.
10. O papel humano na IA	Reconhecer que os seres humanos desempenham um papel importante na programação, na escolha de modelos e no ajuste fino dos sistemas de IA.
11. Alfabetização em dados (<i>data literacy</i>)	Entender os conceitos básicos de alfabetização em dados.
12. Aprendizagem a partir dos dados (<i>learning from data</i>)	Reconhecer que, em geral, os computadores aprendem a partir dos dados (incluindo os próprios dados).
13. Interpretação crítica de dados (<i>critically interpreting data</i>)	Entender que os dados requerem interpretação. Descrever como os exemplos de treinamento fornecidos em um conjunto de dados inicial podem afetar os resultados de um algoritmo.
14. Ação e reação	Entender que alguns sistemas de IA possuem a capacidade de agir fisicamente no mundo. Essa ação pode ser direcionada por raciocínio de nível superior (por exemplo, caminhar ao longo de uma trajetória planejada) ou impulsos reativos (por exemplo, pular para trás para evitar um obstáculo percebido).
15. Sensores	Entender o que são sensores e que os computadores percebem o mundo por sensores. Identificar sensores em uma variedade de dispositivos. Reconhecer que diferentes sensores oferecem apoio a diferentes tipos de representação e de raciocínio sobre o mundo.
16. Ética	Identificar e descrever diferentes perspectivas sobre as principais questões éticas em torno da IA: privacidade, emprego, desinformação, <i>singularidade</i> ¹³ , tomada de decisão, diversidade, vies, transparência e responsabilidade.
17. Programabilidade	Entender que os agentes são programáveis.

Fonte: (Long, Magerko; 2000)

²⁹ Documento resultante da Conferência Internacional de Educação e IA, promovida pela UNESCO e realizada em Beijing, China em maio de 2019. Disponível em <https://unesdoc.unesco.org/ark:/48223/pf0000372249> Acesso em 10 dez. 2023

Documentos promovendo uma formação escolar voltada a compreensão da IA começam a ser produzidos. Publicação recente³⁰ de um grupo coordenado pela Profa. Rosa Vicari e por colegas do IFRS, traz um referencial curricular para que escolas possam refletir sobre a construção seu próprio planejamento pedagógico incluindo a IA como conteúdo curricular. (Vicari et al., 2023)

Caberá às políticas públicas de educação reconhecerem a urgência, em paralelo aos esforços de regulação, de pesquisa intensiva, de projetos de formação docente e da inclusão nos programas curriculares nacionais, de trabalhos para o desenvolvimento de competências em IA.

Os pesquisadores do departamento de Learning Science, da University College of London, liderados pela professora Luckin, desenvolveram um framework, que aparece no quadro 6, que pode ajudar gestores nas instituições de ensino a refletirem sobre a como se apropriar de soluções baseadas em IA. Inicialmente, colocam-se algumas questões básicas como: “No que somos bons, e no que as máquinas são boas? Como humanos e máquinas podem operar juntos? Quais as possibilidades e restrições da IA na aprendizagem e no ensino? Como estas tecnologias de IA podem ser integradas na sala de aula?” (Kent; Du Boulay ,2021)

Quadro 6 – Framework ações de preparação para IA na escola

Educar, Entusiasmar	O primeiro passo é envolver toda a equipe da sua organização em aprender sobre IA. O que é, o que pode e o que não pode fazer e como pode ajudar em seu ambiente educacional. Até agora, os professores têm estado em uma posição semelhante à da maioria do público. A IA era uma área “muito ocupada para incomodar” que eles talvez não tenham entendido ou em que particularmente confiaram, deram prioridades a outras áreas e não sentiam grande pressão em compreender. Mas com a tecnologia educacional sendo empurrada para a frente e para o centro durante a pandemia, houve uma mudança. A IA está cada vez mais vista como uma ferramenta valiosa para o ensino e a aprendizagem, e
---------------------	--

³⁰ Disponível em

https://www.researchgate.net/publication/367476204_Referencial_Curricular_Inteligencia_Artificial_no_Ensino_Medio Acesso em 10 dez. 2023

	um componente do conhecimento que as pessoas precisarão para se desenvolver.
ajustar e aprimorar	O segundo passo é concentrar seu pensamento em um determinado desafio que sua organização enfrenta e considere se é mesmo algo que a IA pode resolver. Existem recursos na estrutura da escola para ajudá-lo a mergulhar profundamente em seu desafio e trabalhar para filtrar o que pode e o que não pode ser feito e como a IA pode ajudar.
Identificar	A terceira etapa entra em jogo assim que você decidir qual desafio que você vai enfrentar. Você e seus colegas devem pensar em quais dados você tem em mãos e em que estado eles estão. É provável que seus dados atuais estejam espalhados por toda a sua organização, e você pode não ver imediatamente a riqueza sobre a qual está sentado, portanto, gastar tempo identificando-a e tornando-a adequado para o propósito será recompensador a longo prazo.
Coletar	O quarto passo é começar a coletar novos dados no que se refere a seu desafio. Isso pode envolver métodos de captura de dados, como pesquisas e entrevistas, mas deve ser feito de forma ética, com consideração pelas pessoas e sensibilidades envolvidas, como você deve garantir que o viés não se infiltre no conjunto de dados que irá distorcer seus resultados para todo o processo
Aplicar	A quinta etapa é aplicar técnicas de IA aos dados e começar para ver quais resultados surgem. Embora pareça que isso seria a parte crítica do processo, apenas 20% do seu tempo será gasto fazendo isso, com os outros 80% gastos identificando, limpando, e coletando todos os dados que alimentam a IA!

Aprender	A sexta etapa é ver os resultados de sua IA aplicada aos dados do desafio e aprender com eles. Essa é a etapa mais valiosa, pois as descobertas do processo ajudarão não apenas a moldar uma abordagem ou solução para o desafio, mas irão ajudá-lo a entender o seu desafio de uma forma maneira totalmente nova
Iterar	A sétima e última etapa é olhar para as descobertas que você acabou de ter e voltar para a etapa 2 novamente para verificar se seu desafio e sua IA são tão específicos e informativos quanto podem ser. Lembre-se de que a IA sozinha raramente produzirá uma solução - muito mais provável será que a IA combinada com a inteligência humana terão que trabalhar juntos para alcançar uma solução

Fonte: Empowering educators to be AI-ready. Disponível em <https://www.sciencedirect.com/science/article/pii/S2666920X22000315?via%3Dihub> Acesso em 10 dez. 2023

Os temores são razoáveis: que a quantificação e os sistemas autônomos forneçam uma nova onda de recursos poderosos para rastrear, controlar e quantificar a atividade humana – um sonho para burocratas, profissionais de marketing e pesquisadores – mas ofereçam pouco para avançar o ensino e o aprendizado cotidianos em direções produtivas. Esse medo é justificado em nossa era pós-Snowden de vigilância generalizada e violações de dados pós-Cambridge Analytics³¹. Em parte, porém, esse medo também nasce da falta de consciência sobre as diversas formas que o *learning analytics* e a inteligência artificial aplicado à educação assumem, o que é igualmente compreensível – para quem está de fora, essas são tecnologias novas e opacas.

“Segue-se que, se não queremos ver alunos, pais e sindicatos preocupados protestando contra a IA na educação, precisamos comunicar com urgência em termos acessíveis quais são os benefícios dessas novas ferramentas e, igualmente, quão seriamente a comunidade está se envolvendo com seu potencial de ser usado em detrimento da sociedade (Luckin, 2019).

³¹ Empresa de consultoria política britânica, que produz perfis políticos para propaganda eleitoral nas mídias sociais e que ganhou destaque nos escândalos envolvendo diversos pleitos eleitorais.

Projetos como o *No Child Left Behind* nos EUA (2001), as crises dos sistemas nacionais de educação, os avanços das provas internacionais na avaliação externa dos sistemas nacionais de educação entre outros eventos de caráter global, impulsionam a preocupação com a responsabilidade e o uso mais intensivo de dados nas instituições escolares. Cunha-se o termo DDDM (*Data-Driven Decision Making*). Aliada a isso, a produção sem precedentes de dados de aprendizagem e de produção didática de alunos e professores nas plataformas digitais, acelerada pelas tentativas de ensino remoto e híbrido durante a quarentena forçada pela pandemia (2020-2022), promove situações absolutamente inéditas para o uso de dados educacionais na tomada de decisão (Dogan, 2021).

Devemos analisar esse movimento com atenção. Dewey já nos alertava, em 1940, para a simplificação embutida em análises das ciências exatas como modelo para a compreensão do humano, eliminando traços distintivos desse humano (Schelling, 2021). Ele argumentava que a “ciência da educação” é particularmente complexa e multifacetada, e fatores passados e presentes influenciam fortemente em quaisquer conclusões que se busca obter. Ele almejava uma ciência flexível e responsiva, que reconhecesse as dimensões lineares e não lineares do crescimento educacional, social e moral do indivíduo.

Em outra leitura, igualmente crítica, sobre o esforço de transformar a educação em um processo *data-driven*, em que, claramente, as aplicações baseadas em IA poderiam proliferar, Taylor_(2020), afirma que a comoditização dos dados, para que os atores institucionais, usando *data-as-capital*, possam acessar mais e melhores recursos, e a criação de ambientes de mercado dentro das instituições educacionais, amplificando a competição e o controle e erodindo a colaboração entre os atores institucionais, são faces do neoliberalismo e do capitalismo de vigilância que aparecem por detrás dos esforços do *Data Driven Decision Making*.

Mas é fato que, mesmo diante de todos esses fatores (neoliberalismo, controle, big data, ensino híbrido, crises dos sistemas educacionais públicos), podemos produzir muito a partir dos sistemas de análise baseados em IA e por isso merecem nosso estudo crítico e nossa atenção permanente.

A capacidade de calcular um valor numérico para representar o progresso de um indivíduo ou de uma instituição, até mesmo de um país, agora é fundamental para políticas e práticas baseadas em evidências. O contraponto a “valorizar o que medimos” é, obviamente, “o que conta nem sempre pode ser medido e o que é mensurável nem sempre conta”. Todas as instituições, a educação não sendo exceção, há muito lutam com a tensão de que as poderosas abstrações fornecidas pela análise quantitativa também perdem detalhes vitais à medida que o contexto é removido. Isso é o que torna o design de métricas para avaliar a qualidade de processos e resultados humanos diferenciados (como ensino e aprendizagem) tão controverso. (Luckin, 2020).

6. CONCLUSÃO:

Um dos primeiros insights que obtive no processo do mestrado foi aprender que o pesquisador e a pesquisa, em simbiose contínua, se interrelacionam-se, modificando-se mutuamente. Pesquisar esta nova onda tecnológica revigora o meu trabalho, abrindo novas questões, mostrando velhas incoerências a serem trabalhadas, exigindo atitude e ação, e a pesquisa e a dissertação, produtos aqui, expressam, de algum modo, toda experiência obtida ao longo destes 40 anos.

Inicialmente me vi atingido pela onda provocada pelo advento do ChatGPT em plena dissertação. Até novembro de 2022, IA era um campo de fronteira para a escola e para a pesquisa educacional. Terreno de ficção para grande parte dos educadores brasileiros. Sentia-me então tateando uma perspectiva que parecia potente porém ainda remota de aplicação na escola. Eis que tudo se acelera e todos passam a considerar, em pouquíssimas semanas, a possibilidade (e a necessidade) do uso dessa tecnologia. Minha escrita e minhas quase certezas se viram subitamente revolvidas, e uma sensação da obsolescência diária foi tomando conta do meu trabalho.

Precisei buscar ancoragem para seguir a viagem e esta veio da minha prática. Ao longo de 40 anos vivi de perto e de longe diversas ondas parecidas atingindo o tecido escolar. A maioria delas, como afirma Morozov, veio como solução para problemas que não haviam sido levantados, mera adaptação ao mercado e as pressões da contemporaneidade, os desafios da gestão na 4a. era industrial. Escola é um organismo conservador por natureza. Resiste aos modismos, quando pode. Mas sucumbe, muitas vezes, como parte de um organismo maior, em uma rede pública, por exemplo.

O que me permitiu alguma convicção nas análises que consegui construir diante das leituras que pude fazer é a certeza de que a questão do movimento da escola brasileira para produzir gente capaz de construir mundos melhores não passa pela tecnologia. Isso não quer dizer que não será preciso utilizá-la, mas ela não é a chave. O que a escola deve buscar é a construção coletiva de seres humanos responsáveis, autônomos e solidários. Toda tecnologia tem de vir nessa direção.

Outra convicção que foi central para esta dissertação é a de que tecnologia (e todas as suas manifestações) precisa ser objeto de estudo na escola. É fundamental que tenhamos na escola capacidade de julgar as soluções adotadas de modo crítico e construir e participar ativamente da construção dessas soluções. O trabalho da Rose Luckin é exemplar nessa direção. Isso me impulsionou a dar peso no capítulo 3, no qual descrevo

a IA nos modelos estatísticos e matemáticos. Reconheço a fragilidade acadêmica das análises ali presentes. Estatística é uma ciência que necessita, seja para ser utilizada, seja para ser compreendida, de grande repertório matemático, inacessível para a maioria dos educadores. Mesmo assim, insisti na tentativa de explicar alguns dos modelos mais encontrados no aprendizado de máquina para demonstrar que tudo que está por detrás da IA são correlações entre dados mesmo com a opacidade decorrente dos modelos de redes neurais, cujo processamento é tão intensivo que as torna impossíveis de explicar no detalhe. Tentei permitir que um educador, ao ler este trabalho, possa compreender melhor o que acontece por detrás da lógica dos algoritmos. Como educador de tecnologia, formado inicialmente como monitor da linguagem LOGO, sempre me debrucei sobre esse desafio de explicar o que está acontecendo por dentro de cada solução. A tarefa não é simples pela complexidade, pela limitação na linguagem e pelas aproximações “menos” acadêmicas que fui obrigado a fazer. Também espero que o meu interesse pelos modelos matemáticos desperte impulso semelhante nos colegas leitores, para que mais pesquisas possam acontecer e para que a escola possa participar ativamente da pesquisa e da construção de soluções baseadas em IA que a atendam.

Parece-me igualmente importante suscitar o debate, a experimentação e a pesquisa ativa do educador em serviço. A formação inicial dos educadores brasileiros apresenta muitas deficiências. Em particular, na formação para a cultura digital. E o educador é vetor fundamental para a formação dos jovens em vida digital. Daí que polemizar, pela pedagogia crítica de um Postman ou de um Selwin, leva-nos a reflexões fundamentais antes da tomada de decisão ou da própria imersão alienada a sistemas inteligentes baseados em dados.

A aprendizagem e a cognição humana são tão complexas que os sistemas, por mais processamento e dados que puderem absorver, só darão conta de realmente se tornarem relevantes como assistentes de estudo (papel que considero o mais promissor para as tecnologias baseadas em IA), se evitarmos o reducionismo neoliberal de produzirmos soluções mágicas, baseadas em tecnologias, para levarmos todos os estudantes ao sucesso acadêmico. Esse modelo econômico que prevalece aqui no Brasil, certamente nos impingirá reduções, como tratei no capítulo 3, em que rubricas pré-definidas serão usadas para produzir respostas “personalizadas” para cada estudante.

Finalmente, ter localizado pesquisas sobre a IA aprendiz, baseadas no conceito do *human-in-the-loop*, me permite acreditar em perspectivas que transcendam esse uso preditivo baseado em padrões reduzidos de aprendizagem. O advento do ChatGPT e dos

bots baseados na IA generativa torna mais clara a ideia de que podemos treinar a IA para atuar em parceria conosco. E esta possibilidade se conecta à perspectiva metacognitiva que me parece indispensável quando se trata de tecnologia aplicada à educação, uma educação voltada para a autonomia do aluno.

Baseados nessas premissas, acredito que estamos no limiar de um tempo em que aplicações de IA se multiplicarão em todos os campos e chegarão em profusão às escolas. Embora a adrenalina esteja no desenvolvimento de aplicações interessantes, esta dissertação propõe um recuo crítico, uma reflexão coletiva que permita à escola aprender o mais profundamente que for possível, se aventurar a pensar e construir aplicações em parceria com universidades e mercado, criar uma geração de educadores conscientes e criativos para melhor absorver esse assistente de enorme potencial que o desenvolvimento humano nos propicia agora.

Bibliografia:

- AIKEN, Robert M.; EPSTEIN, Richard G. **Ethical guidelines for AI in education: Starting a conversation.** *International Journal of Artificial Intelligence in Education*, v. 11, n. 2, p. 163-176, 2000.
- ALEVEN, Vincent; AZEVEDO, Roger. **International Handbook of Metacognition and Learning Technologies.** New York, NY. Springer, 2013.
- ALMEIDA, Elizabeth; VALENTE, Jose. **Integração de Currículos de Tecnologias e a Produção de Narrativas Digitais.** *Currículo sem Fronteiras* v. 12, n. 3, p. 57-82, 2012.
- AMIEL, Tel; GONSALES, Priscila; SEBRIAM, Debora. **Recursos Educacionais Abertos no Brasil: 10 anos de ativismo.** *EmRede-Revista de Educação a Distância*, v. 5, n. 2, p. 246-258, 2018.
- AOUN, Joseph E. **Robot-proof: higher education in the age of artificial intelligence.** MIT press, 2017.
- AUSUBEL, David. **Aquisição e retenção de conhecimentos: uma perspectiva cognitiva.** Tradução de Lígia Teopisto. Lisboa: Plátano, 2000.
- BACHINSKI, Nara Ebres. Uma máquina poderia pensar?. **Cognitio-Estudos: revista eletrônica de filosofia**, v. 12, n. 1, p. 157-169, 2015.
- BARROS, R. C. et al. **A Survey of Evolutionary Algorithms for Decision-Tree Induction.** *IEEE Transactions on Systems, Man and Cybernetics, Part C (Applications and Reviews)*, v. 42, n. 3, p. 291–312, May 2012.
- SILVEIRA SONEGO, A. H.; BEHAR, P. A. **M-learning: o uso de dispositivos móveis por uma geração conectada.** *Educação*, v. 42, n. 3, p. 525, 31 Dec. 2019.
- BISWAS, G. et al. **LEARNING BY TEACHING: A NEW AGENT PARADIGM FOR EDUCATIONAL SOFTWARE.** *Applied Artificial Intelligence*, v. 19, n. 3–4, p. 363–392, 9 Mar. 2005.
- BITTENCOURT, Ig; ISOTANI, Seiji. **Informática na Educação Baseada em Evidências: Um Manifesto.** *Revista Brasileira de Informática na Educação*, Disponível em: <http://ojs.sector3.com.br/index.php/rbie>. Acesso em 24 jun 2022.
- BOCHIE, Kaylani et al. **Aprendizado profundo em redes desafiadoras: Conceitos e aplicações.** Sociedade Brasileira de Computação, 2020.
- BOSTROM, Nick; DAFOE, Allan; FLYNN, Carrick. **Public policy and superintelligent AI: a vector field approach.** Governance of AI Program, Future of Humanity Institute, University of Oxford: Oxford, UK, 2018.

BRAIKI, B. A. et al. **Artificial intelligence in education and assessment methods**. Bulletin of Electrical Engineering and Informatics, v. 9, n. 5, p. 1998–2007, 1 Oct. 2020.

BRUSILOVSKY, P. **Methods and techniques of adaptive hypermedia**. In: BRUSILOVSKY, P.; KOBASA, A.; VASSILEVA, J. (Eds.). . Adaptive hypertext and hypermedia. Dordrecht: Springer Netherlands, 1998. p. 1–43.

BUCKINGHAM, David. **Aprendizagem e Cultura Digital**. *Revista Pátio* n.44, 2008.

BUCKINGHAM, David. **Manifesto pela Educação Midiática**. São Paulo: Edições Sesc, 2022.

CAVIQUE, Luís. Ciência dos Dados. **Revista de Ciência Elementar**, v. 9, n. 2, 2021.

CHASSIGNOL, M. et al. **Artificial Intelligence trends in education: a narrative overview**. *Procedia Computer Science*, v. 136, p. 16–24, 2018.

CHOMSKY, Noam; ROBERTS, Ian; WATUMULL, Jeffrey. **Noam Chomsky: The False Promise of ChatGPT**. *The New York Times*, v. 8, 2023.

CHONG, Guana; JIAN, Moub; ZHIYING, Jianga. **Artificial intelligence innovation in education: A twenty-year data-driven historical analysis**. *International Journal of Innovation Studies* v. 4, n. 4, p. 134-147, 2020.

COOPER, S. Barry; VAN LEEUWEN, Jan (Ed.). **Alan Turing: His work and impact**. Elsevier, 2013.

CORTIZ, Diogo. **Computação afetiva deve afetar interações entre as pessoas**. https://c.lookcom.com.br/pucsp/site/m014/noticia.asp?cd_noticia=139964973 Acesso em 09 dez. 2023

COSTA, Izanete de Medeiros. **O estudo da metodologia elêntica dos diálogos platônicos e a argumentação crítica no Ensino Médio**. 125 f. Dissertação (Mestrado Profissional em Filosofia) - Universidade do Estado do Rio Grande do Norte, Natal, 2019

DHAR, Vas and Pant. **Data Science and Prediction**. *Communications of the ACM*, v.56, n.12, p.64-73,2013.

DIGNUM, V. **The role and challenges of education for responsible AI**. *London Review of Education*, v. 19, n. 1, 13 Jan. 2021.

DIJCK, J. V. In data we trust? **The implications of datafication for social monitoring**. *Matrizes*, v. 11, n. 1, p. 39, 30 Abr. 2017. Disponível em <https://www.revistas.usp.br/matrizes/article/view/131620>. Acesso em 25 ago 2023.

DOGAN, Emine; DEMIRBOLAT, Ayse Ottekin. Data-Driven Decision-Making in Schools Scale: A Study of Validity and Reliability. **International Journal of Curriculum and Instruction**, v. 13, n. 1, p. 507-523, 2021. ESTEVEZ ALMENZAR, Marina et al. Glossary of human-centric artificial intelligence. 2022.

- DOMINGOS, Pedro. **O Algoritmo Mestre**: Como a busca pelo algoritmo de machine learning definitivo recriará nosso mundo. Brasil: Novatec Editora. 2017
- DU BOULAY, B. **Escape from the Skinner Box**: The case for contemporary intelligent learning environments. *British journal of educational technology : journal of the Council for Educational Technology*, v. 50, n. 6, p. 2902–2919, Nov. 2019.
- ELSHAWI, R. et al. **Big data systems meet machine learning challenges**: towards big data science as a service. *Big Data Research*, v. 14, p. 1–11, May 2018.
- FARAG, N.; HASSAN, G. **Predicting the survivors of the titanic kaggle, machine learning from disaster**. Proceedings of the 7th International Conference on Software and Information Engineering. Anais, New York, NY, USA: ACM, 2 May 2018
- FERREIRA, Giselle Martins et al. **Metaphors We’re Colonised By?** The Case of Data-Driven Educational Technologies in Brazil. *Learning, Media and Technology* v. 45, n. 1, p. 1–15, 2019. Disponível em: <https://www.tandfonline.com/doi/abs/10.1080/17439884.2019.1666872?journalCode=cjem20>. Acesso em 11 jun 2022.
- FERREIRA, G. M. dos S.; LEMGRUBER, M. S. **Educational technologies as tools**: Critical considerations on a fundamental metaphor. *Education Policy Analysis Archives*, 26, 112. Disponível em: <https://doi.org/10.14507/epaa.26.3864>. Acesso em 10 jun 2022.
- FERREIRA, GISELLE MARTINS DOS SANTOS. **Educação e Tecnologia**: abordagens críticas Giselle Martins dos Santos Ferreira; Luiz Alexandre da Silva Rosado; Jaciara de Sá Carvalho. Rio de Janeiro: SESES, 2017. Disponível em <https://ticpe.files.wordpress.com/2017/04/ebook-ticpe-2017.pdf> . Acesso em 25 ago 2023.
- FLAVELL, J. H. **Speculation about the nature and development of metacognition**. In F. Weinert & R. Kluwe (Eds.), *Metacognition, motivation, and understanding* (pp.21 - 29). Hillsdale, NJ: Lawrence Erlbaum, 1987.
- FLORIDI, L. **AI and Its New Winter**: from Myths to Realities. *Philosophy & technology*, v. 33, n. 1, p. 1–3, Mar. 2020.
- FLORIDI, L. **What the near future of artificial intelligence could be**. *Philosophy & technology*, v. 32, n. 1, p. 1–15, Mar. 2019.
- FREIRE, Paulo. **Pedagogia da Autonomia** – Saberes Necessários à Prática Docente. 19º ed. Paz e Terra, São Paulo 1996.
- GERHARDT, Tatiana E.; SILVEIRA, Denise T.. **Métodos de pesquisa**. Plageder, 2009.
- GIL, Antonio Carlos. **Métodos e técnicas de pesquisa social**. 6. ed. Editora Atlas SA, 2008.
- GONSALES, Priscila. **Inteligência além da Artificial**: Educar para o Pensar Complexo. São Paulo: Z Edições, 2022.

- GONSALES, Priscila. **Inteligência Artificial, educação e pensamento complexo: caminhos para religação de saberes.** 2022. 131p. Dissertação: Mestrado. Pontifícia Universidade Católica de São Paulo, Programa de Estudos Pós-Graduados em Tecnologias da Inteligência e Design Digital. São Paulo, 2022.
- GOODSON, Ivor. **Schooling, curriculum, narrative and the social future.** The future of educational change: International perspectives, p. 123-135, 2008.
- GOURLAY, Lesley. **Multimodality, argument and the persistence of written text.** In: Multimodality in Higher Education. Brill, 2016. p. 79-90.
- HAEBERLE, Heather S. et al. **Artificial intelligence and machine learning in lower extremity arthroplasty: a review.** The Journal of arthroplasty, v. 34, n. 10, p. 2201-2203, 2019.
- HINTON, Geoffrey; LECUN, Y. **The deep learning revolution.** Turing Lecture at FCRC, 2019.
- HOLMES, Waine; BIALIK, Maia; FADEL, Charles. **Artificial Intelligence in Education: Promises and Implications for Teaching and Learning.** Boston, MA: Center for Curriculum Redesign, 2019.
- HOU, M.; FIDOPIASTIS, C. **A generic framework of intelligent adaptive learning systems: from learning effectiveness to training transfer.** Theoretical Issues in Ergonomics Science, v. 18, n. 2, p. 167–183, 4 Mar. 2017.
- INCONTRI, Dora. **Multimídia na educação.** Comunicação & Educação, n. 7, p. 16-20, 1996.
- JANDRIĆ, Petar et al. **Postdigital dialogue: Postdigital science and education,** v. 1, p. 163-189, 2019.
- JOHRI, P. et al. **Natural language processing: history, evolution, application, and future work.** In: ABRAHAM, A.; CASTILLO, O.; VIRMANI, D. (Eds.). . Proceedings of 3rd international conference on computing informatics and networks: ICCIN 2020. Lecture notes in networks and systems. Singapore: Springer Singapore, 2021. v. 167p. 365–375.
- JOSEPH, Olive; CAITLIN, Christianson; McCARY, John . **Handbook of Natural Language Processing and Machine Translation.** Arlington, VA: Springer, 2011.
- JOVANOVIĆ, Mladan; CAMPBELL, Mark. **Generative artificial intelligence: Trends and prospects.** Computer, v. 55, n. 10, p. 107-112, 2022.
- KALDARAS, L.; YOSHIDA, N. R.; HAUDEK, K. C. **Rubric development for AI-enabled scoring of three-dimensional constructed-response assessment aligned to NGSS learning progression.** Frontiers in Education, v. 7, 25 Nov. 2022.
- KARPATHY, A.; JOHNSON, J.; FEI-FEI, L. **Visualizing and Understanding Recurrent Networks.** arXiv, 2015.

KASNECI, E. et al. **ChatGPT for good?** On opportunities and challenges of large language models for education. *Learning and individual differences*, v. 103, p. 102274, Apr. 2023.

KAUFMAN, Dora. **A Inteligência Artificial Irá Suplantar A Inteligência Humana?** São Paulo: Estação das Letras e das Cores, 2019.

KAUFMAN, Dora. **Desmistificando a Inteligência Artificial**. Belo Horizonte: Autêntica, 2022.

KENT, Carmel; DU BOULAY, Ben. **AI for Learning**. Boca Raton, FL: CRC Press, 2022.

KERSSENS, Niels; VAN DIJCK, José. **The platformization of primary education in The Netherlands**. *Learning, Media and Technology* v. 46, n. 3, p. 250-263. Disponível em <https://doi.org/10.1080/17439884.2021.1876725>. Acesso em 12 jun 2022.

KOCHMAR, E. et al. **Automated personalized feedback improves learning gains in an intelligent tutoring system**. In: BITTENCOURT, I. I. et al. (Eds.). *Artificial intelligence in education: 21st international conference, AIED 2020, ifrane, morocco, july 6–10, 2020, proceedings, part II. Lecture notes in computer science*. Cham: Springer International Publishing, 2020. v. 12164p. 140–146.

KOJIMA, Takeshi et al. **Large language models are zero-shot reasoners**. *Advances in neural information processing systems*, v. 35, p. 22199-22213, 2022.

KOTU, Vijay; DESHPANDE, Bala. **Data science: concepts and practice**. Morgan Kaufmann, 2018.

KNOX, J; WILLIAMSON, Ben; BAYNE, Sian. **Machine behaviourism: Future visions of ‘learnification’ and ‘datafication’ across humans and digital technologies**. *Learning, Media and Technology* v. 45, n. 1, p. 31-45. Disponível em <https://doi.org/10.1080/17439884.2019.1623251>. Acesso em 11 fev 2023.

KUMAR, Sunil; SREE, RJ Rama. **Experiments towards determining best training sample size for automated evaluation of descriptive answers through sequential minimal optimization**. *ICTACT journal on soft computing*, v. 4, n. 2, p. 710-714, 2014.

LANG, Charles et al. **The Handbook of Learning Analytics**. Vancouver: SoLAR, 2022.

LEMOS, A. **Epistemologia da comunicação, neomaterialismo e cultura digital**. *Galáxia (São Paulo)*, n. 43, p. 54–66, Apr. 2020.

LIMA, Danielle Martins Leite Fernandes et al. **A base de conhecimento TPACK na formação continuada do tutor dos cursos de licenciatura em educação a distância da UEMA: um estudo de caso**. 2020.

LOPES, A. M. M.; NETTO, J. F. DE M. **Sistemas tutores inteligentes: um mapeamento das produções brasileiras**. *Anais do XXXI Simpósio Brasileiro de*

Informática na Educação (SBIE 2020). Sociedade Brasileira de Computação, 24 Nov. 2020

LUCKIN, Rosemary et al. **Empowering educators to be AI-ready.** *Computers and Education: Artificial Intelligence*. Elsevier, n.3. Disponível em <https://www.sciencedirect.com/journal/computers-and-education-artificial-intelligence>. Acesso em 25 nov 2022.

LUCKIN, R; CUKUROVA, M. **Designing Educational Technology in the Age of AI: A Learning Sciences Driven Approach.** *British Journal of Educational Technology*, v. 50, n. 6, p. 2824-2838, 2019. Disponível em https://discovery.ucl.ac.uk/id/eprint/10078866/3/Cukurova_Designing%20educational%20technologies%20in%20the%20age%20of%20AI.%20A%20learning%20sciences-driven%20approach_AAM.pdf Acesso em 25 ago 2023.

LUENGO-OROZ, Miguel et al. From artificial intelligence bias to inequality in the time of COVID-19. *IEEE Technology and Society Magazine*, v. 40, n. 1, p. 71-79, 2021.

MARKEL, J. M. et al. **GPTeach: Interactive TA Training with GPT-based Students** Proceedings of the Tenth ACM Conference on Learning @ Scale. **Anais...** In: L@S '23: PROCEEDINGS OF THE TENTH ACM CONFERENCE ON LEARNING @ SCALE. New York, NY, USA: ACM, 20 Jul. 2023

MASSCHELEIN, Jan; SIMONS, Maarten. **Em defesa da escola.** Belo Horizonte: Autêntica, 2020.

MATSUDA, N.; COHEN, W. W.; KOEDINGER, K. R. **Teaching the teacher: tutoring simstudent leads to more effective cognitive tutor authoring.** *International Journal of Artificial Intelligence in Education*, v. 25, n. 1, p. 1–34, Mar. 2015.

MAULUD, Dastan; ABDULAZEEZ, Adnan M. **A review on linear regression comprehensive in machine learning.** *Journal of Applied Science and Technology Trends*, v. 1, n. 4, p. 140-147, 2020.

MCCARTHY, John et al. **A proposal for the dartmouth summer research project on artificial intelligence**, august 31, 1955. *AI magazine*, v. 27, n. 4, p. 12-12, 2006..

MIAO, Fengchun et al. **AI and education: A guidance for policymakers.** UNESCO Publishing, 2021.

MOREIRA, Marco Antonio. **Mapas Conceituais e Aprendizagem Significativa.** *Currículum : Revista de Teoría, Investigación y Práctica Educativa*. La Laguna, n. 25, p. 29-56, 2012.

MORAES, Roberto. **Plataformização da Educação.** Laboratório Formação em Docências no Ensino Superior (GIZ-PROGRAD-UFGM). Disponível em <http://www.robertomoraes.com.br/2021/05/plataformizacao-da-educacao.html>. Acesso em 11 jun. 2022.

MORAES, Maria. **O paradigma educacional emergente: implicações na formação do professor e nas práticas pedagógicas.** *Em aberto*, v. 16, n. 70, 1996.

MOROZOV, Evgeny. **To Save Everything, Click Here: The Folly of Technological Solutionism**. PublicAffairs, 2013.

MUNIR, H.; VOGEL, B.; JACOBSSON, A. **Artificial intelligence and machine learning approaches in digital education: A systematic revision**. *Information*, v. 13, n. 4, p. 203, 17 Apr. 2022.

NKAMBOU, Roger; BOURDEAU, Jacqueline; PSYCHÉ, Valéry. **Building intelligent tutoring systems: An overview**. *Advances in Intelligent Tutoring Systems*, p. 361-375, 2010.

NORVIG, Peter; RUSSEL, Stuart. **Inteligência Artificial**. Elsevier. São Paulo: 2014.

NOURI J., Ebner, et al., **Efforts in Europe for Data-Driven Improvement of Education – A Review of Learning Analytics Research in Seven Countries**. *International Journal of Learning Analytics and Artificial Intelligence for Education (iJAI)*, v. 1, n. 1, p. 8–27, 2019. Disponível em: <https://doi.org/10.3991/ijai.v1i1.11053>. Acesso em 11 jun 2022.

NÓVOA, A. **Os professores e a sua formação num tempo de metamorfose da escola**. *Educação & Realidade*, v. 44, n. 3, 2019.

PACHECO, José Augusto. **Políticas curriculares descentralizadas: autonomia ou recentralização?**. *Educação & Sociedade*, v. 21, p. 139-161, 2000.

PALINCSAR, A.S.. **Keeping the Metaphor of Scaffolding Fresh - A Response to C. Addison Stone's**. *Journal of Learning Disabilities*, v. 31, n. 4, p. 370-373. Dallas, TX: 1998.

PANGRAZIO, L.; SEFTON-GREEN, J. Digital rights, digital citizenship and digital literacy: what's the difference? **Journal of New Approaches in Educational Research**, v. 10, n. 1, p. 15, 15 Jan. 2021.

PAPERT, Seymour. **Mindstorms: Children, Computers and Powerful Ideas**. Basic Books, 1980.

PARASURAMAN, Raja; RILEY, Victor. **Humans and automation: Use, misuse, disuse, abuse**. *Human factors*, v. 39, n. 2, p. 230-253, 1997.

PERROTTA, C., SELWYN, N., **Deep Learning goes to school: toward a relational understanding of AI in education**, (2019),. Disponível em: <https://doi.org/10.31235/osf.io/48t7e>. Acesso em 13 dez. 2023

PITON GONÇALVES, Jean. **Desafios e perspectivas da implementação computacional de testes adaptativos multidimensionais para avaliações educacionais**. 2012. Tese de Doutorado. Universidade de São Paulo.

POHL, Jens. **The Five Tribes of Machine Learning: A brief overview**. InterSymp-2019. July 2019

POLLACK, Jordan B. **Mindless intelligence**. *IEEE Intelligent Systems*, v. 21, n. 3, p. 50-56, 2006.

POLIZZI, Gianfranco. **Digital literacy and the national curriculum for England: Learning from how the experts engage with and evaluate online content.** *Computers & Education*, v. 152, p. 103859, 2020.

POSTMAN, Neil. **Technopoly: The Surrender of Culture to Technology.** Vintage. New York, NY: 1993

PRETTO, Nelson De Luca, 1954. **Uma escola sem/com futuro : educação e multimídia**, 8. ed. rev. e atual. Salvador : EDUFBA, 2013.

NORVIG, Peter; RUSSELL, Stuart. **Inteligência artificial.** Rio de Janeiro: Grupo GEN, 2013.

ROMERO, C.; VENTURA, S. **Educational data mining and learning analytics: An updated survey.** *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, v. 10, n. 3, May 2020.

SAMUEL, Arthur. **The banishment of paper-work.** in *AI Magazine* v. 4, n. 2, Stanford, CA, 1983.

SANTAELLA, Lucia. **Humanos hiper híbridos.** SP: Paulus Editora, 2021

SANTAELLA, Lucia. **O ChatGPT veio para colocar a ética humana à prova.** *Sociotramas*, 14 mar. 2023. Disponível em <https://sociotramas.wordpress.com/2023/03/14/o-chatgpt-veio-para-colocar-a-etica-humana-a-prova/> . Acesso em 08 set. 2023.

SANTOS, G. L. **A internet na escola fundamental: sondagem de modos de uso por professores.** *Educação e Pesquisa*, v. 29, n. 2, p. 303–312, Dec. 2003.

SAUNDARAJAN, K. et al. **Learning Algebra using Augmented Reality: A Preliminary Investigation on the Application of Photomath for Lower Secondary Education.** *Int. J. Emerg. Technol. Learn.*. 2020 Aug 28

SAYAD, Alexandre. **Inteligência artificial e seu impacto no desenvolvimento do pensamento crítico.** 2022. 102p. Dissertação: Mestrado. Pontifícia Universidade Católica de São Paulo, Programa de Estudos Pós-Graduados em Tecnologias da Inteligência e Design Digital. São Paulo, 2022.

SCARDAMALIA Marlene; BEREITER, Carl. **Knowledge building: Theory, pedagogy, and technology.** In SAWYER, K (Ed.). *Cambridge Handbook of the Learning Sciences*. New York: Cambridge University Press, 2006, p. 97-118.

SEARLE, John. **Mentes, cerebros y programas.** D. Hofstadter y D. Dennett (Comps.), *El ojo de la mente: fantasías y reflexiones sobre el yo y el alma*, p. 454-493, 1983.

SELWIN, Neil. **Is Technology Good for Education?** Hoboken, NJ: Wiley, 2016.

SERRES, Michel. **Le tiers-Instruit.** Paris: François Bourin, 1991.

SILVA, William Daniel Colen de Moura; FINGER, Marcelo. **Improving CoGrOO: the Brazilian Portuguese Grammar Checker.** In: *Proceedings*. 2013.

SUTTON, Richard S. ; BARTO, Andrew.. **Reinforcement Learning**, second edition: An Introduction. MIT PRESS, 2018.

TAULLI, Tom. **Introdução a Inteligência Artificial** - uma abordagem não técnica. São Paulo: Novatec, 2020.

TORREY, Lisa; SHAVLIK Jude. **Transfer learning**. In Handbook of research on machine learning applications and trends: algorithms, methods, and techniques, pages 242–264. IGI global, 2010.

TROSHANI, I. et al. **Do we trust in AI?** role of anthropomorphism and intelligence. Journal of Computer Information Systems, v. 61, n. 5, p. 481–491, 3 Sep. 2021.

TURING, Alan. Turing. **Computing machinery and intelligence**. Mind, v. 59, n. 236, p. 433-60, 1950.

UNESCO - **Currículos de IA para a educação básica: um mapeamento de currículos de IA aprovados pelos governos**, 2022. Disponível em https://unesdoc.unesco.org/ark:/48223/pf0000380602_por . Acesso em 25 ago 2023.

VALENTE, José Armando. **Informática na educação: instrucionismo x construcionismo**. Revista Educação Pública, v. 2, n. 1, 2005.

VALENTE, José Armando; ALMEIDA, Maria Elizabeth. **Integração, Currículo e Tecnologias e a Produção de Narrativas Digitais**. Currículo sem Fronteiras, v.12, n.3, p.57 - 82, Set/Dez 2012

VASWANI, Ashish et al. **Attention is all you need**. 31st Conference on Neural Information Processing Systems, Long Beach, CA, 2017.

VICARI, Rosa. **Influências da Inteligência Artificial no Ensino**. Disponível em <https://doi.org/10.1590/s0103-4014.2021.35101.006>. Acesso em 08 mar 2023.

WANG, Pei. **On the working definition of intelligence**. Technical Report 94, Center for Research on Concepts and Cognition, Indiana University, 1995.

WANG, Xiaoyu; BENNING, Martin. **Generalised perceptron learning**. arXiv preprint arXiv:2012.03642, 2020.

WATTERS, A. (2015). **Education Technology and Skinner's Box**. Retrieved from <http://hackeducation.com/2015/02/10/skinners-box>

WEI, Jason et al. **Transactions on Machine Learning Research** v.2, Oct. 2022.

WEITEKAMP, D.; HARPSTEAD, E.; KOEDINGER, K. R. **An interaction design for machine teaching to develop AI tutors** Proceedings of the 2020 CHI Conference on Human Factors in Computing Systems. Anais... In: CHI '20: CHI CONFERENCE ON HUMAN FACTORS IN COMPUTING SYSTEMS. New York, NY, USA: ACM, 21 Apr. 2020

WICKHAM, Hadley; ÇETINKAYA-RUNDEL, Mine; GROLEMUND, Garrett. **R for data science**. " O'Reilly Media, Inc.", 2023.

WOOLF, Beverly Park. **Building intelligent interactive tutors: Student-centered strategies for revolutionizing e-learning.** Burlington, MA: Morgan Kaufmann, 2010.

WU, X. et al. **A survey of human-in-the-loop for machine learning.** Future Generation Computer Systems, v. 135, p. 364–381, Oct. 2022.

YALCIN, Orhan Gazi. **The Role of the Right to Explanation and Its Safeguards in the Realization of Trustworthy AI.** In: International Conference on Disruptive Technologies, Tech Ethics and Artificial Intelligence. Cham: Springer International Publishing, 2022. p. 178-187.

ZHAI, X. et al. **A Review of Artificial Intelligence (AI) in Education from 2010 to 2020.** Complexity, v. 2021, p. 1–18, 20 Apr. 2021.

ZIMMERMAN, Barry J.; MOYLAN, Adam R. **Self-regulation: Where metacognition and motivation intersect.** In: Handbook of metacognition in education. Routledge, 2009. p. 299-315.