

DOI: [10.46943/VIII.CONEDU.2022.GT19.034](https://doi.org/10.46943/VIII.CONEDU.2022.GT19.034)

# EXTRAÇÃO DE DADOS, CAPTURA DE AFETOS: AGENCIAMENTOS ALGORÍTMICOS EM AMBIENTES DE APRENDIZAGEM

Amanda Valeria Silva

Mestra em Comunicação pelo Programa de Pós-Graduação em Comunicação da Universidade Federal de Pernambuco - UFPE e graduanda em Pedagogia pela UNIP, amandavaleria17@gmail.com;

## RESUMO

Neste artigo, objetivamos pôr luz sob algumas implicações da utilização de pilares tecnocêntricos no contexto educacional e a consequente utilização de dados apreendidos para geração de padrões, rastreamento de comportamentos, bem como a inferência de estados cognitivos e afetivos pela inteligência artificial, segundo um novo *ethos* condizente às dinâmicas do século XXI. A partir da explanação e problematização de alguns conceitos como Big Data (Jindal e Borah, 2013, Ferreira, 2013; Davenport, 2014;), Ambientes Virtuais de Aprendizagem, *Learning Analytics* (Chatti et al., 2012; Dias, 2017, Triantafyllou et al., 2018) e Computação Afetiva (Vicari, 2018), podemos problematizar a dinâmica de experimentos e correlações para extrair informações dos estudantes. Quando se concerne à formação de bancos de dados, as estratégias de personalização de aprendizagem são sempre colocadas em pauta como vantagens da aplicabilidade. O interesse ainda mais direcionado ao entendimento desses padrões de comportamentos e traços psicológicos acompanham uma dinâmica de ampla captura e utilização de informações psíquicas e emocionais extraídas dos dados de usuários nas plataformas digitais (Bentes, 2019). Para a pesquisadora Fernanda Bruno (2018) trata-se de uma *economia psíquica dos algoritmos*, em que os dados psicossociais e emocionais não

DOI: [10.46943/VIII.CONEDU.2022.GT19.034](https://doi.org/10.46943/VIII.CONEDU.2022.GT19.034)

EXTRAÇÃO DE DADOS, CAPTURA DE AFETOS:  
AGENCIAMENTOS ALGORÍTMICOS EM AMBIENTES DE APRENDIZAGEM

interessam tanto pelo perfil psicológico individual em si, mas por permitir estabelecer correlações entre os perfis psicológicos e os padrões de atividades dos usuários. Desse modo, sob à ótica do *capitalismo de vigilância* (2018), debatemos as consequências da naturalização do uso de metadados comportamentais, como a utilização de sensores fisiológicos, reconhecimento de expressões faciais, análise de voz e semântica, em Sistemas Tutoriais Afetivos. Objetivamos ampliar o debate em torno da ética, privacidade e de controle sociotécnicos em sistemas de inteligência artificial extremamente opacos em seu funcionamento, mas que são cada vez mais presentes em plataformas de aprendizagem.

**Palavras-chave:** Dados, Educação, Inteligência artificial, Privacidade.

## INTRODUÇÃO

Em uma conjuntura notadamente marcada por um intenso fluxo de dados e de agenciamentos algorítmicos, é perceptível a crescente utilização de tecnologias numéricas quantificáveis e rastreáveis. Para o pesquisador Lemos (2021), estamos vivenciando uma profunda e global dataficação da vida, em que as ações e comportamentos são processados por sistemas de inteligência algorítmica.

É um processo de tradução da vida em dados digitais rastreáveis, quantificáveis, analisáveis, performativos(...) A dataficação possibilita a conversão de toda e qualquer ação em dados digitais rastreáveis, produzindo diagnósticos e inferências nos mais diversos domínios. (Lemos, 2021, p.194)

A área educacional, naturalmente, é atravessada por essas transformações e absorve um ecossistema de processos e interfaces tecnológicas que visam aperfeiçoar as metodologias de ensino, segundo um novo *ethos* condizente às dinâmicas do século XXI. Enquanto beneficia nossa sociedade com o crescente acesso à educação e métodos inovadores de ensino, a conjuntura interconectada também apresenta muitos desafios. (Baldwin & Ching, 2019; Walder, 2017).

O exponencial crescimento do número de plataformas educativas e de sistemas de gestão de aprendizado implica, desse modo, uma geração de massas de dados que é tratada, minerada, correlacionada e analisada dentro de uma complexidade de fatores e agenciamentos. Dentro desse contexto, objetivamos pôr luz sob algumas implicações da utilização de pilares tecnocêntricos no contexto educacional e a consequente utilização de dados apreendidos para geração de padrões, rastreamento de comportamentos, bem como a inferência de estados cognitivos e afetivos pela inteligência artificial.

## METODOLOGIA

Para o desenvolvimento do estudo, a ferramenta metodológica apresenta discussões tecnocentradas com caráter exploratório visto que a temática de estudo, por sua natureza incipiente possui,

ainda, pouco material bibliográfico. Optamos por tentar compor um percurso a partir de diferentes enfoques nos agenciamentos de dados que demonstram uma transformação na dinâmica de sistemas e modelos de aprendizagem.

A partir da explanação e problematização de alguns conceitos como BigData (Jindale Borah, 2013, Ferreira, 2013; Davenport, 2014;), Ambientes Virtuais de Aprendizagem, *Learning Analytics* (Chatti et al., 2012; Dias, 2017, Triantafyllou et al., 2018) e Computação Afetiva (Vicari, 2018), discorreremos e lançamos luz sobre determinadas práticas de dataficação no contexto educacional.

## BIG DATA E EDUCAÇÃO

Um conceito bastante relevante e controverso no tocante a dados e informações é o de Big Data. Segundo Davenport (2014), o desafio de entender o tema parte de três aspectos iniciais: a) a múltipla natureza dos dados; b) o uso de processamento em nuvem, que se relaciona ao uso ilimitado de recursos computacionais e com processamento em larga escala, com a possibilidade de redução de custos; c) uso de tecnologias específicas, tais como processamento de rotinas em paralelo e ferramentas para otimização, além de abordagens de *Machine Learning*<sup>1</sup> e *Analytics*<sup>2</sup>. Para Taurion (2013) o termo se refere ao agrupamento de soluções tecnológicas capaz de lidar com dados digitais em 3Vs, volume, variedade e velocidade inéditos até os dias atuais. Outros especialistas de dados já consideram 5 Vs: Volume, Velocidade, Variedade, Veracidade e Valor. o volume é a característica mais reconhecida neste conceito, e diz respeito ao tamanho do repositório de dados e dos arquivos armazenados, bem como a capacidade de processar esses dados, que é denominada de Big Data Analytics. A velocidade está ligada ao tempo de processamento (tempo real ou não) dos dados no Big Data. A variedade está interligada as categorias de dados que podem advir de sistemas estruturados e não estruturados (e-mail, Facebook, etc). A veracidade diz respeito à autenticidade e sentido

1 Aprendizado de máquina

2 Inteligência analítica

dos dados. O valor é o retorno do investimento que deve existir quando uma solução de Big Data é implantada. (Patricio, Magnoni, 2018)

No que diz respeito ao campo de educação, é inegável as potencialidades que a utilização do Big Data pode proporcionar aos gestores, constituidores de políticas públicas, educadores e educandos. No entanto, para que se possa projetar estratégias e implementar metodologias de aprendizagem a partir dos dados coletados é necessária uma melhor compreensão do conceito e de seu intercâmbio com áreas como psicologia, ciências sociais e computação. Para Sin e Muthu (2015) a proporção que a geração de dados se eleva no campo educacional, torna-se indispensável a utilização de técnicas de Big Data para a mineração e transformação dos dados em informações relevantes.

Os métodos de produção do Big Data a partir de *small data*<sup>3</sup>, das ações e caminhos percorridos pelos educandos em ambientes de aprendizagem apoiam-se em processos de Data mining e envolvem diferentes grupos. Para Jindal e Borah(2013), os grupos podem ser classificados como Grupo primário( abrange os participantes diretamente envolvidos no contexto educacional, como professores e estudantes), Grupo secundário( pessoas envolvidas de forma indireta como familiares dos estudantes e ex-alunos) e por fim o Grupo híbrido (formado por pessoas relacionadas no processo administrativo, como planejadores, empregadores).

O tratamento e o enfoque atribuídos a uma ampla base de dados coletada variam, desse modo, de acordo com a finalidade a que se destinam. Seja pelo desenvolvimento de soluções mais refinadas para gestão escolar, personalização de recursos de aprendizagem ou na predição de desempenhos acadêmicos, infundáveis são as aplicações advindas dos processos algorítmicos de mineração.

Nesse contexto, Ferreira (2013) argumenta que os tipos de informações mais tencionadas na coleta e análise das aplicações

---

3 São 'traços digitais', registros de atividades que são armazenadas à medida que interagimos com o ambiente. Estes traços são produzidos passivamente quando utilizamos ferramentas e serviços que mantêm registros (HSIEH et al, 2018, p.1)

que processam grandes volumes de dados educacionais versam sobre:

- a. Dados relacionados à identificação dos usuários: quem são, quais as suas permissões de uso, localização e informações demográficas;
- b. Dados que se relacionam à interação do usuário em ambientes de aprendizagem: são os que referem à experiência dos estudantes e envolvem diferentes tipos de métricas, como visualização de páginas e taxas de cliques.;
- c. Dados inferidos acerca dos conteúdos: versam sobre o entendimento de evidências que sejam capazes de apontar o nível de desempenho concernente na relação entre um conteúdo escolar e a proficiência na aprendizagem.;
- d. Dados relacionados aos sistemas de informação disponíveis nas organizações educacionais: relacionam-se aos dados de natureza mais burocrática já tradicionalmente coletados pelas escolas.;
- e. dados de inferência sobre os estudantes: São os dados mais difíceis de serem gerados pela complexidade requeridas na coleta e tratamento bem como porque dizem respeito ao comportamento de cada estudante durante o processo de aprendizagem de um conteúdo, que pode ser afetado por diferentes situações, fatores e recursos instrucionais utilizados.

Cumprе problematizar, destarte, algumas dessas fontes de dados coletados, como plataformas interativas educacionais que se destacam cada vez mais pelo refinamento da inteligência artificial e dinamismo no processo de coleta e extração de informações. Para Dias (2017, p.5),

o âmbito da mineração de dados educacionais cria e ajusta técnicas e algoritmos utilizados atualmente, ao passo de compreender e contextualizar para a educação, considerando as plataformas de interação, tais como Ambientes Virtuais de Aprendizagem (AVAs), Redes Sociais, Sistemas Tutores Inteligentes (STIs). Com essa metodologia, pretende-se conhecer melhor o estudante em sua aprendizagem.

## AMBIENTES VIRTUAIS DE APRENDIZAGEM E AS LEARNING ANALYTICS

Considerando a proliferação de sistemas remotos de ensino e a crescente adoção de plataformas de aprendizagem, diversas são as perspectivas e discussões concertadas acerca de sua utilização. As potencialidades da educação à distância – amplamente difundidas principalmente após o isolamento social causado pela pandemia da Covid-19 – assentadas em suportes tecnológicos extremamente refinados demonstram novas possibilidades de arranjos, técnicas e intervenções nos modelos de ensino-aprendizagem.

Neste sentido, nos Ambientes Virtuais de Aprendizagem (AVAs) grandes quantidades de dados são coletadas, processadas e analisadas para o desenvolvimento de diagnósticos com informações relevantes sobre o percurso educacional em contextos híbridos ou totalmente remotos. Para Dias (2017, p.3) “os AVAs potencializaram a atividade, o dinamismo e a personalização do processo de ensino-aprendizagem, que operam no ciberespaço para permitir a interação e secundar o espaço entre os agentes do processo e a interatividade com o material a ser estudado”. Carvalho et. al. (2014), por sua vez, considera a utilização desses expedientes, em um contexto híbrido, como de grande potencial para o desenvolvimento de novos modos de avaliação e acompanhamento contínuo dos discentes.

A integração de múltiplas mídias e recursos permite que haja uma interação entre os educandos e os objetivos de aprendizagem previamente estabelecidos, o sistema também analisa o desempenho dos alunos e fornece uma gama de informações de naturezas diversas. Dentro desse espectro, podemos situar as Learning Analytics (LA), área de pesquisa relativamente recente que a partir da medição, coleta, análise e relatório de dados se propõe a otimizar e aperfeiçoar os mais diversos ambientes de aprendizado.

As ferramentas de Learning Analytics fornecem dados de aprendizado acerca do envolvimento e da atividade individual dos usuários na plataforma, estatísticas genéricas sobre seu uso, bem como, informações sobre o intercâmbio de dados no sistema (Triantafyllou et al., 2018).

LA está relacionada com o processo de aprendizado por meio da tecnologia. Essas tecnologias geram grandes quantidades de dados educacionais e variam de ferramentas cognitivas a ambientes sofisticados e complexos, como sistemas de gerenciamento de aprendizagem (LMS - do inglês Learning Management System), ambientes virtuais de aprendizagem (AVA) e os recentes cursos online massivos abertos (MOOC - do inglês Massive Open Online Course) (Zotou et al. 2016 apud Aguiar et al., 2021).


Ao confluir áreas de pesquisa como análises acadêmicas, mineração de dados educacionais, sistemas de recomendação e aprendizagem adaptativa, as LA na verdade são um termo genérico abrangente dos estudos de Technology Enhanced Learning (TEL), ou estudo das tecnologias sobre o aprendizado. Dentro dessa perspectiva as Learning Analytics se dedicam ao desenvolvimento de métodos de análise e detecção de padrões nos dados coletados em ambientes educacionais, e aproveita essas metodologias para apoiar a experiência de aprendizagem. Para Chatti *et al.* (2012), o processo geral das LA é geralmente um ciclo iterativo baseado em três etapas principais: (1) coleta e pré-processamento de dados, (2) análise e ação, e (3) pós-processamento.

Na primeira etapa, o esforço se assenta em coletar dados de vários ambientes e sistemas educacionais. A seleção de padrões úteis e a transformação de dados em formatos específicos acontecem nesse estágio, além da utilização de dados de tarefas de pré-processamento emprestadas do campo de mineração de dados. Na análise e ação, tendo como base os dados pré-processados e o objetivo da análise, é possível aplicar diferentes tipos de técnicas de L.A para identificar padrões ocultos que possam proporcionar uma experiência de aprendizagem mais eficaz.

Nessa etapa, além da análise e visualização de informações, há também ações que incluem monitoramento, previsão, intervenção, avaliação, adaptação, personalização, recomendação e reflexão. O estágio de pós-processamento pode abranger a compilação de novos dados a partir de outras fontes, refinamento de bases de dados específicas, determinação de novos atributos necessários para iterações, novos indicadores, métricas, modificação de variáveis de análise ou escolha de novos métodos de análise.



Figura 1 Processo de Learning Analytics<sup>4</sup>



Os autores detalham ainda um modelo de referência em LA baseada em quatro dimensões: *o quê, quem, por quê e como*, com o intuito de facilitar o entendimento acerca do tipo de dados, dos objetivos, das técnicas e dos envolvidos. Neste artigo o enfoque é direcionado para o *por quê*, visto que o intento da pesquisa é entender as diversas finalidades das incursões tecnológicas e seus resultados. Há uma miríade de objetivos que varia de acordo com as perspectivas e estratégias de diferentes grupos de interesse. Consoante Chatti *et al.* (2012) e Atif *et al.*, algumas finalidades incluem:

- Monitoramento e análise
- Predição e intervenção
- Tutoria e Mentoria
- Avaliação e feedback
- Adaptação
- Personalização e recomendação
- Reflexão

Destacamos os objetivos de predição, intervenção, adaptação, personalização e recomendação enquanto ações de intervenção em que se naturalizam práticas de extração de dados para performar comportamentos. Esses procedimentos são sintomáticos de um arranjo de uma dinâmica neoliberal marcadas pelo controle, dataficação e agenciamentos que são passíveis de problematizações.

4 Chatti, M. A.; Dyckhoff, A. L.; Schroeder, U.; Thüs, H. A reference model for learning analytics. *International Journal of Technology Enhanced Learning*, v. 4, n. 5, p. 318-331, 2012.

## INFERÊNCIAS COGNITIVAS E AFETIVAS A PARTIR DA INTELIGÊNCIA ARTIFICIAL EM EDUCAÇÃO

Na atuação conjunta de plataformas e aplicativos, podemos observar o desenvolvimento de tecnologias de inteligência artificial que vão além do percurso de navegação na rede, ao colocar em análise indicadores afetivos ou fisiológicos dos usuários, por exemplo. Como materialidades de seu tempo, os sistemas educacionais são, desse modo, um campo profícuo de aplicação e testes para as tecnologias desse expediente. Em estudo prospectivo que identificou tendências mundiais em tecnologias baseadas em Inteligência Artificial para a Educação no período de 2017 a 2030<sup>5</sup>, o Sistema indústria constatou um crescente interesse no desenvolvimento de produções científicas que versam sobre o assunto.

A pesquisa sinaliza uma mudança significativa a curto e médio prazos em termos de interfaces de ambientes virtuais de aprendizagem, com a utilização de Processamento da Língua Natural (voz, escrita, tradução) e Afetividade.

As prospecções referentes ao Processamento da Língua Natural e à Afetividade são também suportadas pelas pesquisas nas bases de patentes. Várias delas nas buscas em bases estão relacionadas a empresas na área de Processamento de Língua Natural e Afetividade, dentre elas: Kairos, nViso, Afectiva, Emotion API, EmoVoice, Vokaturi, Google, IBM, Nuance, Microsoft e Skype. (Vicari, 2018, p. 44)

O Processamento de Língua Natural (PLN) abrange a geração e compreensão automática de línguas humanas naturais. Pode ser dividida em duas componentes (Fala e escrita). Na Fala, há a possibilidade de geração e compreensão automática de línguas humanas naturais que desenvolvem a tradução simultânea, já na Escrita além da comunicação entre humanos e as máquinas, existe a possibilidade de correção automática de textos escritos pelos discentes, além da geração de textos, pelos softwares, para os alunos.

5 Disponível em <https://www2.fiescnet.com.br/web/uploads/recursos/d1dbf03635c1a-d8ad3607190f17c9a19.pdf> Acesso em 19 de jul de 2022.

Os Sistemas Afetivos/Emocionais, por sua vez, detectam ou expressam emoções e podem reconhecer estados afetivos, como alegria, tristeza, frustração, humor, etc. Os respectivos sistemas são configurados a partir de várias tecnologias de I.A como representação do conhecimento e reconhecimento de padrões. Vislumbra-se que essa tecnologia propiciará que os programas capturem, analisem e traduzam diferentes estados afetivos dos discentes e utilizem as informações para personalização do processo de aprendizagem. Os sistemas computacionais, ainda, podem projetar emoções para se comunicar com os estudantes. Segundo o *Roadmap*<sup>6</sup> do Sistema Indústria, até 2030 as tendências apontam para a expansão de aplicações no campo Afetividade/Emoções em plataformas de *Learning Management System* ou Sistema de Gestão de Aprendizagem, MOOCs ou cursos abertos em ambientes virtuais e Robótica Educacional para análise de textos e voz, bem como para detecção de emoções por meio da face do aluno.

A pesquisadora Rosa Maria Vicari (2022) ainda aponta que a partir dos dados extraídos, a inteligência artificial consegue inferir, com relativo sucesso, o estado cognitivo, afetivo, estilo de aprendizagem, aptidões e, também, os pontos fracos de cada aluno. Com o uso dessas tecnologias é possível gerar sensações de participação e propiciar experiências antes só possíveis em laboratórios físicos, muitas vezes pouco acessíveis pelo custo.

A partir dessas inferências algumas problemáticas podem ser apontadas, visto que a naturalização do uso de metadados comportamentais abre um intenso debate em torno da ética, privacidade e de controle sociotécnicos. Os ambientes de aprendizagem tornam-se, desse modo, espaços privilegiados no qual a visibilidade e a extração de saber fazem parte de sua lógica de funcionamento. Estamos diante de plataformas que, em nome da assertividade baseada em dados, se utilizam de aplicações cada vez mais automatizadas que correlacionam informações de condutas, comportamentos e até mesmo, de emoções.

6 Roadmaps são ferramentas que possibilitam conectar as estratégias tecnológicas com as estratégias de negócio das empresas(Vicari, 2018)

## EXTRAÇÃO DE DADOS, PRIVACIDADE E COMPUTAÇÃO AFETIVA

A mediação que os algoritmos realizam por meio da inteligência artificial são balizados pelas grandes corporações que justificam seu uso pela eficiência, mas que trazem em seu bojo, incursões e procedimentos, por vezes invasivos e antiéticos. Ao analisar tecnologias de educação, podemos perceber que as plataformas se utilizam de proposições sofisticadas, em uma teia imbricada de experimentos e correlações para extrair informações dos estudantes.

As ferramentas de aprendizado da máquina e inteligência artificial ao examinar os percursos educacionais nos ambientes de aprendizagem, examinam mais do que as respostas assinaladas, erros ou acertos dos alunos. As interações são mais pervasivas e ampliam a compreensão sobre o comportamento dos alunos durante a aprendizagem, utilizando interfaces que são capazes de reconhecer palavras, captar gestos, verificar o movimento dos olhos e de diversos indicadores fisiológicos (tais como batimentos cardíacos e tensão muscular)<sup>7</sup>.

Percebemos dessa forma, uma naturalização da utilização de sensores e detectores de emoções através das faces dos alunos, bem como da realização de testes e desenvolvimentos de produtos a partir dessa extração de informações. Essas técnicas refinadas podem ser relacionadas ao que a pesquisadora Shoshana Zuboff (2019), denomina como *capitalismo de vigilância*, uma nova lógica de acumulação contemporânea que se apropria da experiência humana como insumos disponíveis e acessíveis de modo gratuito para a traduzir em dados comportamentais.

Esse *modus operandi* utiliza os dados comportamentais para aprimorar produtos e serviços e transformá-los em excedentes comportamentais.

O capitalismo de vigilância começa com o descobrimento do excedente comportamental. Produzem-se mais dados comportamentais que os estritamente

7 Inteligência artificial pode trazer benefícios na área da educação. Disponível em <<https://jornal.usp.br/universidade/inteligencia-artificial-pode-trazer-beneficios-na-area-da-educacao/>> Acesso em 25 de jul de 2022

requeridos para os aperfeiçoamento do serviço. O excedente resultante alimenta a inteligência da máquina – o novo meio de produção – que gera pre-dições da conduta do usuário. Esses produtos se vendem a clientes em novos mercados de futuros comportamentais. o ciclo de reinvestimento do valor comportamental fica assim subordinado a esta nova lógica (Zuboff, 2019,p.130)<sup>8</sup>

Nesta dinâmica, diversos exemplos de incursões que ferem a privacidade dos usuários de plataformas podem ser encontrados na rede. O aplicativo Ruangguru, por exemplo, recomendado pelo Ministério da Educação e Cultura da Indonésia e com parceria com 32 governos provinciais (de um total de 34) e 326 governos municipais e distritais da Indonésia possuía em 2020, 22 milhões de estudantes-usuários cadastrados. O respectivo programa coleta dados pessoais de seus alunos e os repassa para o Facebook, por meio do domínio graph.facebook.com, que os utiliza para publicidade comportamental. Essa prática é explanada em sua “política de privacidade” que admite coletar dados de seus alunos, combinar com dados desses mesmos alunos captados em outras fontes, e monetizar para fins publicitários.<sup>9</sup>

Ademais, A Human Rights Watch (HRW), organização internacional não governamental com foco na defesa dos direitos humanos publicou recentemente o relatório “How Dare They Peep into my Private Life?”, contendo os resultados de investigação, entre março -agosto de 2021, do aplicativo Ruangguru e de mais 164 produtos de EdTechs (Tecnologias Educacionais).A HRW apurou que a maioria das plataformas de aprendizado online colocaram em risco ou violaram diretamente a privacidade das crianças, entre outros direitos humanos: das 94 EdTechs analisadas em detalhe, 87 cederam os dados pessoais dos alunos à 199 AdTech (empresas de tecnologia

8 Inteligência artificial aplicada à educação: precisamos urgentemente de ética. Disponível em: <<https://epocanegocios.globo.com/colunas/IAgora/noticia/2022/06/inteligencia-artificial-aplicada-educacao-precisamos-urgente-de-etica.html>> Acesso em 31 de jul de 2022

9 Inteligência artificial aplicada à educação: precisamos urgentemente de ética. Disponível em: <<https://epocanegocios.globo.com/colunas/IAgora/noticia/2022/06/inteligencia-artificial-aplicada-educacao-precisamos-urgente-de-etica.html>> Acesso em 31 de jul de 2022

para publicidade), sem consentimento das crianças nem de seus pais. A maioria dessas plataformas instalou tecnologias de rastreamento, que permitia acompanhar a “navegação” das crianças na internet, mesmo, fora da “sala de aula virtual”, assim gerando bancos de dados mais volumosos, refinando a oferta de mídia hiper segmentada para anunciantes.<sup>10</sup>

Quando se concerne à formação desses bancos de dados, as estratégias de personalização de aprendizagem são sempre colocadas em pauta como vantagens da aplicabilidade. O interesse ainda mais direcionado ao entendimento desses padrões de comportamentos e traços psicológicos acompanham uma dinâmica de ampla captura e utilização de informações psíquicas e emocionais extraídas dos dados de usuários nas plataformas digitais (Bentes, 2019). Para a pesquisadora Fernanda Bruno (2018) trata-se de uma *economia psíquica dos algoritmos*, em que os dados psicossociais e emocionais não interessam tanto pelo perfil psicológico individual em si, mas por permitir estabelecer correlações entre os perfis psicológicos e os padrões de atividades dos usuários. Esses modelos buscam, destarte, revelar padrões supra-individuais ou inter-individuais que permitiriam fazer predições em larga escala.

Na educação, as análises preditivas tomam como base o desempenho dos alunos baseados em seu desempenho prévio, em indicadores fisiológicos ou expressões faciais, como nos Sistemas Tutoriais Afetivos. Esses sistemas computacionais educacionais têm o objetivo de promover instrução imediata e customizada aos estudantes a fim de proporcionar um ensino individualizado, considerando também os estados afetivos. (Ammar et al., 2010; Sarrafzadeh et al., 2011; Calvo e D’Mello, 2012). Os STAs encontram-se dentro da área de Computação Afetiva, um campo de pesquisa que estuda e investiga os sistemas que dão aos computadores a habilidade de reconhecer, interpretar, processar, expressar e simular emoções humanas. Ademais esses sistemas devem a partir da interpretação da emoção dos usuários, se adaptar e gerar uma resposta adequada (Picard, 1997, Tao e Tieniu, 2005).

---

10 Tradução livre

Desse modo, os STAs estão na primeira subárea da Computação afetiva: *Emoções em Interação Humano-Computador*.

Esses sistemas devem ter mecanismos para detectar as emoções dos estudantes para que assim possam responder a esses estados afetivos de forma personalizada. Jaques e Vicari (2007) classifica o reconhecimento da emoção do usuário em quatro grupos centrais: **(i) expressões faciais**, **(ii) sinais fisiológicos** (batimentos cardíacos, tensão muscular, condutividade da pele e respiração), **(iii) dados comportamentais**, que são ações e escolhas do usuário na interface do sistema (e.g. opções de escolha, velocidade, de digitação), e **(iv) linguística** (voz e semântica) (Reis, Maillard e Isotani, 2018, p.80).

As expressões faciais analisadas podem ser variadas, como movimentos de olhos, da cabeça, elevação de sobrancelhas ou alteração de diâmetro da pupila. As emoções, por sua vez, podem ser medidas por meio de dispositivos tecnológicos, como os rastreadores oculares que extraem características faciais durante as aulas. (D’Mello et al., 2010; Jaques et al., 2014). Na esteira do reconhecimento de emoções, os sensores fisiológicos são também capazes de detectar desde mudanças físicas externas do estudante (e.g. mudança de postura), até mudanças internas (e.g. frequência cardíaca ou condução elétrica da pele) e podem ser aplicados em diversos domínios e conteúdo (Reis, Maillard e Isotani, 2018).

Segundo Jaques e Vicari (2007), é possível inferir as emoções, outrossim, a partir dos dados comportamentais do estudante, suas ações na interface do ambiente educacional, como por exemplo, tempo para realizar um exercício, sucesso ou equívocos na realização de tarefas, velocidade da digitação do estudante, entre outros. (Lagud e Rodrigo, 2010; Doddannara et al., 2013). Por fim, o uso da análise da voz e semântica também são utilizados para reconhecimento das emoções. A técnica mais empregada nesses sistemas é a transformação das palavras pronunciadas em textos, com a análise do conteúdo das palavras (Rajkumar e Ramalinga, 2015; Mao e Li, 2010).

## CONSIDERAÇÕES FINAIS

Podemos constatar uma miríade de agenciamentos e generalização do uso de dispositivos que se aprofundam ao analisar os mais sutis comportamentos dos estudantes, sinalizando um estágio acurado de processos extrativos de metadados. A bem da verdade, a inteligência artificial pode detectar expressões faciais, mas não os pensamentos e sentimentos por detrás delas.

Mais do que isso, com a promessa de maior eficiência em métodos de ensino, cada vez mais camadas das individualidades humanas são perscrutadas, capturadas em uma constante dinâmica de experimentação. As fronteiras entre o laboratório e a vida social, política e subjetiva tornam-se demasiadamente tênues e o que se presencia é um laboratório-mundo ou uma ciência de plataforma. (Bruno, Bentes e Faltay, 2019).

Cabe enfatizar e problematizar, nesse sentido a ética nos sistemas de inteligência artificial, visto que há uma extrema opacidade nos cálculos que são feitos a partir de matéria-prima humana, bem como são pouco conhecidas as destinações dos dados. Com a proliferação de plataformas virtuais e de avanços muito rápidos na tecnologia, mecanismos de proteção em legislações na área de educação são necessários e prementes.

## REFERÊNCIAS

AGUIAR, Francisco et al. **Learning Analytics e Problem-Based Learning: Mapeamento Sistemático da Literatura**. In: **Anais do VI Congresso sobre Tecnologias na Educação**. SBC, 2021. p. 110-119.

AMMAR, M. B.; NEJI, M.; ALIMI, A. M. E GOUARDÈRES, G. (2010). **The Affective Tutoring System**. *Expert Systems with Applications*, 37(4): 3013-3023. doi: 10.1016/j.eswa.2009.09.031.

ATIF, A., RICHARDS, D., BILGIN, A. & MARRONE, M. (2013). **Learning Analytics in Higher Education: A Summary of Tools and Approaches**. In *Proceedings of Electric Dreams. Proceedings ascilite 2013 Sydney* (pp. 68-72). Australasian Society for Computers in Learning in Tertiary



Education. Retrieved August 2, 2022 from <https://www.learntechlib.org/p/162009/>.

BALDWIN, Sally J.; CHING, Yu-Hui. **Online course design: A review of the Canvas course evaluation checklist**. International Review of Research in Open and Distributed Learning, v. 20, n. 3, 2019.

BENTES, ANNA. A indústria da influência e a gestão algorítmica da atenção. **VI Simpósio Internacional Lavits**, 2019.

BRUNO, Fernanda. **A economia psíquica dos algoritmos: quando o laboratório é o mundo**. NEXO Jornal, Brasil, p. 1-3, 12 jun. 2018.

BRUNO, Fernanda Glória; BENTES, Anna Carolina Franco; FALTAY, Paulo. **Economia psíquica dos algoritmos e laboratório de plataforma: mercado, ciência e modulação do comportamento**. Revista Famecos, v. 26, n. 3, p. e33095-e33095, 2019.

CALVO, R. E D'MELLO, S. (2012). **Frontiers of affect-aware learning technologies**. in *IEEE Intelligent Systems*, 27(6):86-89. doi: 10.1109/MIS.2012.110.

CARVALHO, R. S et al. **Discussão sobre as Tecnologias de Acompanhamento e Avaliação da Aprendizagem no Blended Learning**. In: Anais dos Workshops do Congresso Brasileiro de Informática na Educação. 2014. p. 223.

CASATTI, Denise. **Inteligência artificial pode trazer benefícios na área da educação. Disponível em** <<https://jornal.usp.br/universidade/inteligencia-artificial-pode-trazer-beneficios-na-area-da-educacao/>> Acesso em 20 de jul de 2022

CHATTI, M. A.; DYCKHOFF, A. L.; SCHROEDER, U.; THÜS, H. **A reference model for learning analytics**. International Journal of Technology Enhanced Learning, v. 4, n. 5, p. 318-331, 2012.

DAVENPORT, T. H. **Big Data at Work: Dispelling the Myths, Uncovering the Opportunities**. Harvard Business Review Press Books. 2014

DIAS, Robson Santos. **Caracterização do learning analytics na educação a distância.** Anais do Seminário de Pesquisa e Inovação Tecnológica-SEPIT, 2017.

D'MELLO,S.; LEHMAN, B.; SULLINS, J.; DAIGLE, R.; COMBS, R.; VOGT, K. (2010). **A time for emoting: when affect-sensitivity is and isn't effective at promoting deep learning.** J. Kay, V. Aleven (Eds.), Proceedings of 10th International Conference on Intelligent Tutoring Systems, Springer, Berlin/Heidelberg, pp.245–254. doi:10.1007/978-3-642-13388-6\_29.

DODDANNARA, L.; GOWDA, S.; BAKER, R.; GOWDA, S. E DE CARVALHO, A. (2013). **Exploring the relationships between design, students' affective states, and disengaged behaviors within an its,** 7926:31-40. doi: 10.1016/S0164-1212(99)00102-8.

FERREIRA, J. (2013) **Big data in education: The five types that matter.** Disponível em <http://publicservicesalliance.org/wp-content/uploads/2013/07/Big-Data-in-Education-The-5-Types-That-Matter-Knewton-Blog.pdf> Acesso em 15 de jun de 2022

HSIEH, C.; ALQUADDOOMI, F.; OKEKE, F.; POLLACK, J.; GUNASEKARA, L.; ESTRIN, D. **Small Data: Applications and Architecture.** Working Paper. UCLA/CORNELL. Disponível em: [https://destrin.smallldata.io/papers/small\\_data\\_applications\\_\\_alldata\\_2018.pdf](https://destrin.smallldata.io/papers/small_data_applications__alldata_2018.pdf)

JAIQUES, N.; CONATI, C.; HARLEY, J. & AZEVEDO, R. (2014). **Predicting affect from gaze data during interaction with an intelligent tutoring system.** v8474. pp 29-38. doi: 10.1007/978-3-319-07221-0\_4.

JAIQUES, P. E VICARI, R. (2007). **A BDI approach to infer student's emotions in an intelligent learning environment.**Computers & Education. 49(2): 360–384. doi: 10.1016/j.compedu.2005.09.002.

JINDAL, Rajni; BORAH, Malaya Dutta. **A survey on educational data mining and research trends.** International Journal of Database Management Systems, v. 5, n. 3, p. 53, 2013.

LAGUD, M. E RODRIGO, M. (2010). **The affective and learning profiles of students using an intelligent tutoring system for Algebra.** Intelligent Tutoring Systems, 6094:255-263. doi: 10.1007/978-3-642-13388-6\_30.

LEMOS, André. **Dataficação da vida.** Civitas-Revista de Ciências Sociais, v. 21, p. 193-202, 2021.

MAO, X. E LI, Z. (2010). **Agent based affective tutoring systems: A pilot study.** Computers & Education, 55(1):202-208. doi: 10.1016/j.compedu.2010.01.005.

PATRICIO, Thiago Seti; MAGNONI, Maria da Graça Mello. **Mineração de dados e Big Data na educação.** Revista GEMInIS, v. 9, n. 1, p. 57-75, 2018.

PICARD, R.W. (1997). **Affective Computing.** MIT Press, Cambridge, MA. [GS Search]

RAJKUMAR, N. E RAMALINGAM, V. (2015). **Cognitive intelligent tutoring system based on affective state.** Indian Journal of Science and Technology, [S.l.], sep. 2015. ISSN 0974 -5645. Available at: <<http://www.indjst.org/index.php/indjst/article/view/80145>>. Date accessed: 22 Oct. 2016. doi:10.17485/ijst/2015/v8i24/80145.

REIS, Helena Macedo; MAILLARD, Patrícia Augustin Jaques; ISOTANI, Seiji. **Sistemas Tutores Inteligentes que Detectam as Emoções dos Estudantes: um Mapeamento Sistemático.** Revista Brasileira de Informática na Educação, v. 26, n. 03, p. 76, 2018.

SARRAFZADEH, A.; SHANBEHZADEH, A. E OVERMYER, S. (2011). Capítulo 7: **E-Learning with Affective Tutoring Systems.** Intelligent Tutoring Systems in E-Learning Environments: Design, Implementation and Evaluation. Editores: Stankov, S.; Glavinic, V. e Rosic, Marko. Nova York. pp. 129-139. doi: 10.4018/978-1-61692-008-1.

SENAI. (2018). **Tendências em inteligência artificial na educação no período de 2017 a 2030: SUMÁRIO EXECUTIVO** / SENAI, Serviço Social da Indústria, Rosa Maria Vicari. Brasília: SENAI.

SIN, Katrina; MUTHU, Loganathan. **Application of Big Data in Education Data Mining and Learning Analytics – A Literature Review**. ICTACT Journal on Soft Computing: Special Issue on Soft Computing Models for Big Data, vol. 5, 2015. Disponível em: < [http://ictactjournals.in/paper/IJSC\\_V5\\_I4\\_paper6\\_1035\\_1049.pdf](http://ictactjournals.in/paper/IJSC_V5_I4_paper6_1035_1049.pdf)>. Acesso em: 01 abr. 2018.

TAO, J.; TIENIU, T. (2005). **Affective Computing: A Review**. *Affective Computing and Intelligent Interaction*. LNCS 3784. Springer. pp. 981-995. doi:10.1007/11573548.

TAURION, C. **Big Data**. Editora Brasport: Rio de Janeiro, 2013. Disponível apenas em formato de livro eletrônico

TRIANTAFYLLOU, E., XYLAKIS, E., ZOTOU, M., TAMBOURIS, E., AND TARABANIS, K. (2018b). **Applying learning analytics in problem-based learning engineering semester projects**. In Proceedings of the 46th SEFI Annual Conference. Technical University of Denmark (DTU).

VICARI, Rosa Maria. **'Inteligência artificial já consegue inferir estado cognitivo e estilo de cada aluno'**. Portal Terra, 2022. Disponível em <<https://www.terra.com.br/noticias/educacao/inteligencia-artificial-ja-consegue-inferir-estado-cognitivo-e-estilo-de-cada-aluno,38a8ea0e8fdcc2a71d64f32e288221ee5db709hm.html>> Acesso em 20 de jul de 2022

WALDER, Anne Mai. **Pedagogical Innovation in Canadian higher education: Professors' perspectives on its effects on teaching and learning**. *Studies in Educational Evaluation*, v. 54, p. 71-82, 2017.

ZUBOFF, S. (2019). **The Age of Surveillance Capitalism: The fight for a human at the new frontier of power**. NY: Public Affair