



PREVENTING AND FIGHTING EARLY LEAVING FROM EDUCATION & TRAINING WITH AI

stAI

**Agir antes que aconteça: Prevenir e combater o
Abandono Precoce da Educação e Formação com
Inteligência Artificial**

T3.2 Apoio à decisão baseado em dados na Educação:
diretrizes que descrevem oportunidades, recomendações e
preocupações

Pacote de Trabalho 3

Autor: Consórcio STAI

INFORMAÇÃO DO PROJETO

Acrónimo do projeto:

stAI

Título do projeto: Agir antes que aconteça: Prevenir e combater o Abandono Precoce da Educação e Formação com Inteligência Artificial

Projeto N°:2023-1-IS01-KA220-SCH-000157308

Sub-programa ou KA:

KA220-SCH - Parcerias de cooperação no ensino escolar

Website: www.stai-edu.eu

Consórcio:



SCHOOL OF EDUCATION



ARTIFICIAL
INTELLIGENCE
RESEARCH GROUP



Colegiul Național de Artă
Octav Băncilă
Iași



Índice

Introdução	5
Oportunidades	6
1. Aprendizagem Personalizada	6
Abordagens de Aprendizagem Centradas no Aluno	6
Adaptação do Conteúdo de Aprendizagem Orientada por Dados	6
Percursos personalizados reduzem o desinteresse.	6
Apoiar objetivos e definições de sucesso diferenciados	7
Promover a flexibilidade e a continuidade da aprendizagem	7
Apoiar a Autoconsciência na Aprendizagem	7
Condições para uma implementação bem-sucedida	8
2. Intervenção Precoce	8
Introdução	8
Contexto e definições europeias	8
Quadro estratégico e políticas europeias	9
Intervenção precoce – conceito e mecanismos	9
Impacto e benefícios da intervenção precoce	10
Conclusões	10
3. Estratégias de Ensino Melhoradas	10
Estratégias de Ensino Melhoradas	10
Da Intuição à Pedagogia Baseada em Evidências	11
Aprendizagem Mista e Ativa como Pedagogias Estratégicas	11
Capacitação Profissional e Prática Reflexiva	11
O Papel em Evolução da IA na Pedagogia	12
Implicações Estratégicas e um Futuro Centrado no Humano	12
Preocupações	13
1. Privacidade e Segurança de Dados	13
Recolha e Processamento de Dados Pessoais	13
Base Legal e Consentimento Parental	14
Armazenamento, Segurança e Retenção de Dados	14
Preocupações Específicas da IA nas Ferramentas Educacionais	14
Partilha de Dados com Terceiros e Conformidade	15
Avaliação de Risco e Transparência	15
Proteção de Dados por Design e Controlo do Utilizador	15
Garantia de Idade e Salvaguardas para Crianças	16
2. Dependência Excessiva de Dados	16
Equilibrar a quantidade e a qualidade dos dados	17

Melhorar a qualidade dos dados	17
Permitir que os modelos aprendam e se adaptem ao longo do tempo	19
Integrar dados com experiência prévia, conhecimento especializado humano e conhecimento do domínio	20
Melhorar a transparência, orientar a tomada de decisões e construir confiança e compreensão	21
3. Considerações Éticas	22
Conclusão	25
Referências	27

Introdução

A educação está a entrar numa nova era, na qual os dados e a Inteligência Artificial (IA) se tornam ferramentas poderosas para apoiar alunos e educadores. Este documento centra-se na criação de orientações práticas e acessíveis que ajudem escolas e sistemas educativos a utilizar eficazmente ferramentas baseadas em IA para enfrentar os desafios do abandono precoce da educação e formação (APEF). Estas ferramentas podem ajudar a identificar alunos em risco, recomendar estratégias de apoio e tornar os processos de tomada de decisão mais informados e proativos.

Este documento baseia-se nos conhecimentos adquiridos em trabalhos anteriores, com o objetivo de explorar como os sistemas potenciados por IA podem ser integrados em contextos educativos reais. Pretende-se garantir que estas tecnologias sejam não apenas eficazes, mas também éticas, transparentes e inclusivas. Ao examinar os potenciais benefícios, tais como uma melhor monitorização dos alunos e intervenções personalizadas, juntamente com as preocupações que suscitam, incluindo questões de privacidade, dados tendenciosos e equidade nas decisões da IA, procuramos criar uma abordagem equilibrada em que as escolas possam confiar.

Em última análise, este documento visa apoiar educadores e decisores políticos a navegar neste cenário complexo, mas empolgante. As orientações aqui desenvolvidas irão providenciar conselhos claros e práticos sobre a utilização da IA de forma a apoiar os alunos e promover a igualdade, a inclusão e a transparência. Através da colaboração com os parceiros do projeto e da recolha de contributos de contextos educativos reais, estas orientações abrirão caminho para ferramentas mais seguras, inteligentes e eficazes na redução das taxas de abandono escolar, oferecendo a cada aluno uma melhor oportunidade de sucesso.

Oportunidades

1. Aprendizagem Personalizada

Abordagens de Aprendizagem Centrada no Aluno


A personalização da aprendizagem representa uma mudança transformadora na educação, afastando-se da padronização dos currículos caminhando para uma abordagem centrada no aluno que se adapta ao percurso único de cada um. Em vez de agrupar os alunos por idade ou níveis predefinidos, os sistemas personalizados adaptam-se continuamente às necessidades, preferências e ritmo dos alunos. Esta mudança de foco capacita os alunos a assumirem um papel ativo no seu percurso de aprendizagem, promovendo um maior envolvimento e controlo do seu percurso educativo.

Adaptação do Conteúdo de Aprendizagem Baseada em Dados

A inteligência artificial desempenha um papel central na implementação da aprendizagem personalizada. Ao analisar dados estruturados, como resultados de avaliações e padrões de assiduidade, bem como dados não estruturados, como o tempo gasto em tarefas e padrões de interação, a IA pode construir perfis de aprendizagem detalhados. Estes perfis informam a adaptação dinâmica de materiais, formatos e níveis de complexidade, garantindo que a cada aluno são apresentadas tarefas que não são demasiado simples nem demasiado complexas. A adaptabilidade em tempo real do sistema cria um ambiente de aprendizagem em evolução que responde ao progresso e às necessidades dos alunos, ajudando assim a manter a motivação e a reduzir a frustração.

Percursos personalizados reduzem o desinteresse.

Uma vantagem fundamental da aprendizagem personalizada é a sua capacidade de abordar as causas subjacentes do desinteresse pela escola antes que estas aumentem. Quando



os alunos não se conseguem identificar com os conteúdos, sentem que estão consistentemente atrás dos seus pares e começam a ver a escola como irrelevante, a sua motivação diminui. No entanto, ao oferecer múltiplos percursos de aprendizagem que estão alinhados com os interesses e capacidades individuais, a aprendizagem personalizada pode restaurar a importância e o objetivo da experiência educativa dos alunos. Isto é particularmente importante para os alunos que não se enquadram nos modelos educativos tradicionais ou que sofreram reveses.

Apoiar objetivos e definições de sucesso diferenciados

Os sistemas tradicionais dependem frequentemente de definições restritas de desempenho. Em contrapartida, a aprendizagem personalizada adota uma visão mais ampla do sucesso, incluindo não só a proficiência académica, mas também o progresso em competências como a colaboração, a resolução de problemas e a autorregulação emocional. As ferramentas de IA podem acompanhar estas dimensões e fornecer feedback que reconhece melhorias graduais. Isto incentiva a persistência e a autoconfiança - dois elementos críticos na prevenção do abandono escolar precoce.



Promover a flexibilidade e a continuidade da aprendizagem

A aprendizagem personalizada permite uma maior flexibilidade em termos de quando, onde e como os alunos aprendem. Isto é particularmente benéfico para os alunos que enfrentam desafios externos, como problemas de saúde, responsabilidades familiares ou barreiras socioeconómicas. Ao desvincular a aprendizagem de horários rígidos e locais físicos, os sistemas capacitados para IA ajudam a garantir a continuidade e o acesso, reduzindo assim a probabilidade de contratempos temporários que levam ao desinteresse permanente.

Apoiar o Autoconhecimento na Aprendizagem

Outra característica fundamental da aprendizagem personalizada é a sua capacidade de incentivar a metacognição. Mapas de controlo em tempo real, rastreadores de progresso e *feedback* inteligente orientam os alunos através do conteúdo e incentivam-nos a refletir sobre o seu processo de aprendizagem. A capacidade de compreender como aprendem, identificar estratégias eficazes e adaptar-se em conformidade

capacita os alunos a tornarem-se mais autónomos e resilientes.

Condições para uma implementação bem-sucedida

Para compreender todos os benefícios da aprendizagem personalizada, esta deve ser cuidadosamente integrada no ecossistema educacional mais amplo. Isto implica garantir o acesso equitativo à tecnologia, infraestrutura digital e plataformas de aprendizagem inclusivas e de fácil utilização. É essencial que os professores tenham formação não só na utilização de ferramentas de IA, mas também na compreensão de como interpretar os seus resultados, manter a autonomia pedagógica e gerir as implicações éticas da utilização de dados.

2. Intervenção Precoce

Introdução

O abandono escolar precoce é um grande desafio para todos os Estados-Membros da União Europeia. Afeta não só o percurso individual dos jovens, mas também a coesão social, a produtividade económica e a competitividade a longo prazo das sociedades europeias. Um jovem que abandona a escola antes de adquirir competências básicas corre um elevado risco de desemprego, exclusão social e oportunidades limitadas de desenvolvimento pessoal. A União Europeia reconheceu a gravidade deste fenómeno e estabeleceu metas ambiciosas para a sua redução. A intervenção precoce é considerada a estratégia mais eficaz para prevenir o abandono escolar, uma vez que aborda os fatores de risco atempadamente e fornece apoio personalizado aos alunos vulneráveis.

Contexto e definições europeias

O abandono precoce da educação e formação é definido como a percentagem de jovens entre os 18 e os 24 anos que concluíram, no máximo, o 3º ciclo do ensino básico e que não frequentam nenhum tipo de ensino ou formação profissional. Em 2023, a taxa média da UE foi de 9,5%, perto da meta de 2030 de abaixo de 9%. No entanto, as diferenças entre os Estados são significativas. Em alguns países nórdicos e da Europa Central, a taxa é inferior a 5%, enquanto nos países do sul e do leste excedem frequentemente os 12–14%.

Os principais fatores de risco são múltiplos e interligados:

- Individual: absentismo crónico, baixo rendimento escolar, falta de motivação, problemas de saúde mental;
- Familiar: baixa escolaridade dos pais, pobreza, falta de apoio à educação;

- Escolar: clima educativo pobre, falta de recursos, métodos de ensino não adaptados às necessidades dos alunos.
- Comunidade: falta de oportunidades locais, dificuldades de transporte, pressão para trabalhar numa idade precoce.

Quadro estratégico e políticas europeias

A União Europeia desenvolveu vários instrumentos para apoiar os Estados-Membros:

- Recomendação do Conselho “Caminhos para o Sucesso Escolar” (2022) – estabelece um quadro integrado baseado na prevenção, intervenção precoce e medidas compensatórias;
- Espaço Europeu da Educação 2030 – estabelece metas claras: reduzir o abandono escolar precoce para menos de 9%, garantir pelo menos 96% de participação na educação infantil e reduzir a percentagem de alunos com baixo desempenho na leitura, matemática e ciências para menos de 15%;
- Plano de Ação para a Educação Digital 2021–2027 – apoia a inclusão digital, fornece recursos para professores e alunos e combate as desigualdades no acesso à educação online;
- Garantia Europeia para a Infância (2021) – garante o acesso à educação de qualidade, cuidados de saúde, refeições saudáveis e condições de vida dignas;
- Fundos da UE: através do FSE+, Erasmus+ e RRF, os Estados-Membros recebem recursos para infraestruturas escolares, apoio aos professores e implementação de programas para reduzir o abandono escolar.

Intervenção precoce – conceito e mecanismos

A intervenção precoce é essencial para prevenir o abandono escolar precoce. Envolve ações oportunas e coordenadas quando um aluno começa a mostrar sinais de risco. Os mecanismos mais importantes incluem:

- Sistemas de alerta precoce (SAP): monitorizam o absentismo, a diminuição das notas e o comportamento problemático, permitindo que às escolas atuem rapidamente;
- Planos de apoio individualizados: adaptados às necessidades de cada aluno, incluindo orientação, explicações e atividades de recuperação;
- Aconselhamento psicológico e apoio emocional: essencial para alunos que enfrentam ansiedade, depressão ou problemas familiares;
- Envolvimento parental e comunitário: através de visitas domiciliárias, reuniões regulares, *workshops* e programas de apoio familiar;
- Transições assistidas: do 1º para o 2º ciclo ou do 3º ciclo para o ensino secundário para evitar o desinteresse e a adaptação difícil.

Impacto e benefícios da intervenção precoce

A intervenção precoce traz múltiplos benefícios:

- Aumenta as hipóteses de concluir a educação e integrar o mercado de trabalho;
- Reduz o risco de pobreza e exclusão social;
- Melhora o bem-estar dos alunos e das famílias;
- Acrescenta valor económico através de uma força de trabalho mais qualificada.

Estudos mostram que os investimentos na prevenção e na intervenção precoce são mais eficazes e menos dispendiosos do que as medidas compensatórias tomadas depois de um aluno já ter abandonado a escola.

Conclusões

O abandono escolar precoce continua a ser um problema complexo, mas a intervenção precoce é uma das soluções mais eficazes. A União Europeia fornece o quadro estratégico e os recursos, mas o sucesso depende da forma como cada Estado-Membro, incluindo a Roménia, consegue implementar medidas adaptadas ao seu próprio contexto. O objetivo de reduzir o abandono escolar precoce para menos de 9% até 2030 pode ser alcançado através da cooperação entre escolas, famílias, comunidades e instituições europeias.

3. Estratégias de Ensino Melhoradas

Estratégias de Ensino Melhoradas

Melhorar as estratégias de ensino é fundamental para criar ambientes de aprendizagem inclusivos, envolventes e equitativos, principalmente para alunos em risco de Abandono Precoce da Educação e Formação (APEF). Enquanto a aprendizagem personalizada e a intervenção precoce se centram no aluno, as estratégias de ensino melhoradas abordam os métodos e sistemas que os educadores utilizam para proporcionar uma instrução eficaz. A integração de ferramentas de apoio às tomadas de decisão baseadas em dados permite uma mudança do ensino reativo para o ensino proativo, apoiando práticas pedagógicas mais adequadas, informadas e inovadoras.

Da Intuição à Pedagogia Baseada em Evidências

O ensino tradicional depende frequentemente da intuição e da experiência do educador. Embora valiosa, esta abordagem pode nem sempre identificar ou abordar os primeiros sinais de desinteresse. A análise de dados e as tecnologias de IA oferecem ferramentas para analisar sistematicamente o envolvimento dos alunos, o comportamento, e os resultados, apoiando os educadores na tomada de decisões educativas oportunas. Por exemplo, os sistemas baseados em IA podem ajudar os

professores a adaptar as suas estratégias, oferecendo painéis de controlo em tempo real e alertas inteligentes que solicitam ajustes pedagógicos oportunos. O sistema RADAR (Embarak & Hawarna, 2024) e as ferramentas PDAR/LIS (Baneres, Rodriguez-Gonzalez, & Guerrero-Roldan, 2023) exemplificam como os ciclos de feedback de dados em tempo real permitem que os educadores detetem e respondam precocemente aos problemas de aprendizagem, muitas vezes antes que as avaliações tradicionais sinalizem uma preocupação. Embora estes sistemas tenham sido desenvolvidos para o ensino universitário, os princípios subjacentes da análise preditiva e da monitorização contínua são igualmente relevantes no contexto escolar.

Aprendizagem Combinada e Ativa como Pedagogias Estratégicas

As estratégias de ensino que combinam ferramentas digitais com métodos colaborativos e baseados em projetos podem ser altamente eficazes na prevenção do APEF. As iniciativas islandesas *Austur-Vestur Sköpunarsmiðjur* (Austur-Vestur Sköpunarsmiðjur, s.d.) e *Mixtúra* (Mixtúra, s.d.) ilustram como as tecnologias criativas e os espaços de criação podem estabelecer uma ligação mais forte com os alunos, enfatizando a aprendizagem prática, a resolução de problemas e a autonomia. Estes ambientes dão aos alunos novas formas de demonstrar a aprendizagem e promover competências como a persistência, o trabalho de equipa e a criatividade. Da mesma forma, a iniciativa italiana *Classe AI* (Classe AI, 2025) integra a educação em IA nas atividades da sala de aula, incentivando tanto os professores como os alunos a explorar a IA de forma crítica e criativa. Isto apoia o desenvolvimento da literacia digital e desmistifica tecnologias que são frequentemente vistas como distantes ou opacas.

Capacitação Profissional e Prática Reflexiva

As estratégias de ensino melhoradas só são sustentáveis quando os educadores são apoiados no seu desenvolvimento profissional. Como se pode ver no *Mistura* centro, a incorporação da aprendizagem profissional contínua na política de educação local cria uma cultura onde a inovação é uma prática sistémica, e não uma iniciativa pontual. O Programa Nacional de Promoção do Sucesso Escolar de Portugal enfatiza a planificação de ações lideradas por professores e adaptadas localmente, onde as escolas desenvolvem estratégias específicas para o seu contexto com base em dados de autoavaliação. Isto reforça a autonomia dos docentes e promove a mudança, incentivando os educadores a refletirem sobre a sua prática e a monitorizarem o seu impacto, criando um ciclo de melhoria contínua. A inteligência artificial pode apoiar ainda mais este processo ao criar percursos de desenvolvimento profissional altamente personalizados para os professores, sugerindo investigação relevante, módulos de formação ou até oferecendo orientação baseada em IA, de acordo com os desafios específicos da sua sala de aula.

O Papel em Evolução da IA na Pedagogia



Olhando para o futuro, o papel da IA pode expandir-se para além das aplicações atuais para se tornar um verdadeiro "parceiro cognitivo", tanto para professores como para alunos. Os assistentes de ensino de IA avançado podem atuar como copilotos sofisticados, não sinalizando apenas os alunos em risco, mas também sugerindo abordagens pedagógicas para tópicos difíceis, automatizando a criação de diversas ferramentas de avaliação e lidando com tarefas administrativas de rotina. Isto libertaria os professores para se concentrarem na interação direta com os alunos e no complexa planificação pedagógico. Para os alunos, os tutores de IA podem envolvê-los em diálogos socráticos para estimular o pensamento crítico ou ajudá-los a visualizar as suas próprias etapas de aprendizagem, a fim de desenvolverem competências metacognitivas e de autorregulação.

Implicações Estratégicas e um Futuro Centrado no Ser Humano

Estas estratégias de ensino melhoradas contribuem diretamente para reduzir o risco de abandono escolar, aumentando o envolvimento dos alunos, oferecendo diversos caminhos para o sucesso e criando ambientes de aprendizagem de apoio onde os alunos se sentem vistos e motivados. No entanto, várias considerações estratégicas são fundamentais para aproveitar estas possibilidades futuras. À medida que a IA se torna mais integrada, é imprescindível garantir quadros éticos robustos, fortes proteções de privacidade (como o RGPD) e a mitigação ativa de preconceitos algorítmicos. A tecnologia deve ser sempre posicionada como uma ferramenta para aumentar e capacitar os professores, e não para substituir o seu julgamento profissional ou a ligação humana. Para tomar uma decisão crucial, é essencial que haja sempre intervenção humana. Finalmente, garantir a equidade digital - onde todos os alunos e professores têm acesso à tecnologia e às competências necessárias - será fundamental para evitar que a IA alargue as desigualdades existentes.

Preocupações

1. Privacidade e Segurança de Dados

À medida que as instituições de ensino dependem cada vez mais da inteligência artificial (IA) e da tomada de decisões baseada em dados para personalizar as experiências de aprendizagem, otimizar o desempenho dos alunos e melhorar a eficiência administrativa, as preocupações com a privacidade, a segurança e o cumprimento dos regulamentos da União Europeia (UE) tornaram-se mais prementes. A implementação da IA na educação deve ser cuidadosamente avaliada para garantir a utilização ética, o cumprimento legal e a proteção dos direitos fundamentais dos alunos.

Uma das principais preocupações nas ferramentas educativas orientadas por IA é a acessibilidade destes sistemas a menores. De acordo com o **Artigo 8 do RGPD**, o tratamento de dados pessoais de jovens com menos de 16 anos (ou 13 em alguns países da UE) exige o consentimento dos pais. Se o sistema de IA for concebido para grupos vulneráveis, como alunos neurodivergentes ou indivíduos com deficiência, devem ser implementadas salvaguardas adicionais para evitar preconceitos e garantir a transparência.



Muitas aplicações educativas alimentadas por IA exigem acesso aos dispositivos dos utilizadores, recolhendo frequentemente dados de listas de contactos, ficheiros multimédia, microfones, câmaras, geolocalização e até sensores biométricos. Este acesso extensivo a dados levanta sérias preocupações relativamente aos princípios de minimização de dados ao abrigo do **Artigo 5.º do RGPD**. As instituições e os fabricantes de tecnologia devem avaliar se as permissões solicitadas são estritamente necessárias para a funcionalidade da ferramenta e se os utilizadores podem dar o seu consentimento informado antes de conceder o acesso.

Recolha e Tratamento de Dados Pessoais

O tipo e a extensão dos dados pessoais recolhidos pelos sistemas de IA devem ser justificados ao abrigo do **Artigo 9.º do RGPD**, que impõe condições rigorosas ao tratamento de categorias especiais de dados, como informações biométricas, registos de saúde ou análises comportamentais. Os sistemas de IA utilizados na educação recolhem frequentemente grandes quantidades de dados, incluindo os registos biográficos dos alunos, os padrões de interação e até as respostas emocionais.

Se a recolha de dados for desproporcionada em relação à finalidade pretendida, viola o princípio da **proporcionalidade dos dados** e pode levar à exposição desnecessária de informações confidenciais.

Base Legal e Consentimento Parental

As instituições de ensino e os fornecedores de IA devem estabelecer uma base legal para o tratamento de dados pessoais. Dependendo do caso de utilização, esta pode ser o **consentimento explícito, a necessidade contratual ou o interesse legítimo**. No entanto, se o sistema de IA envolver a definição de perfis, a tomada de decisões automatizada ou o rastreamento comportamental, o **Artigo 22.º do RGPD** concede aos indivíduos o direito de contestar e recusar esse tratamento. Além disso, as instituições devem garantir que os mecanismos de consentimento parental para menores são robustos, impedindo a recolha não autorizada de dados de crianças sem salvaguardas adequadas.

Armazenamento, Segurança e Retenção de Dados

Um aspeto crucial da governação da IA na educação é a **localização e duração do armazenamento** dos dados recolhidos. Se os dados dos alunos forem armazenados fora da UE, devem ser implementadas **Cláusulas Contratuais-Tipo (CCT)** para garantir a conformidade com o RGPD. Além disso, o princípio da **limitação do armazenamento (Artigo 5.º do RGPD)** exige que os dados só sejam conservados durante o tempo necessário para cumprir a sua finalidade.



Os riscos de cibersegurança também representam um desafio significativo, uma vez que o acesso não autorizado aos dados educativos pode levar ao roubo de identidade, à publicidade direcionada ou mesmo à manipulação dos registos dos alunos. As instituições devem implementar **encriptação, controlos de acesso rigorosos e técnicas de anonimização** para mitigar estes riscos e evitar violações.


Preocupações Específicas da IA nas Ferramentas Educativas

Para além das preocupações habituais com a privacidade, as plataformas de educação baseadas na IA introduzem **riscos únicos** que exigem uma supervisão especializada:

- **Aprendizagem Adaptativa e Rastreamento Comportamental:** Os sistemas de IA que analisam as interações dos alunos e adaptam o conteúdo em conformidade

devem ser transparentes quanto à utilização dos dados.

- **Reconhecimento de Emoções e Biometria:** Se as ferramentas de IA utilizarem **reconhecimento facial, análise de voz ou sensores corporais**, devem cumprir o **Artigo 9.º do RGPD** e justificar a necessidade de tal recolha de dados.



- **Realidade Aumentada (RA) e Digitalização do Ambiente:** As funcionalidades de **RA baseadas na IA** que digitalizam o ambiente do utilizador podem captar inadvertidamente **dados de terceiros** sem consentimento.
- **IA Generativa e Assistentes Virtuais:** Se os *chatbots* de IA ou os agentes de tutoria interagirem dinamicamente com os alunos, devem existir mecanismos para evitar a **desinformação, os preconceitos ou o armazenamento não autorizado de dados**.

Partilha de Dados com Terceiros e Conformidade

O envolvimento de fornecedores terceiros na educação alimentada por IA levanta preocupações adicionais sobre **partilha de dados**. Se os dados dos alunos forem transferidos para terceiros para **análise, marketing ou treino de modelos de IA**, **Os Acordos de Processamento de Dados (APD) ao abrigo do Artigo 28.º do RGPD** são obrigatórios. As instituições devem garantir **total transparência** relativamente a que entidades têm acesso aos dados e para que fins.

Avaliação de Riscos e Transparência

Para mitigar os riscos associados à IA na educação, as instituições devem realizar **Avaliações de Impacto sobre a Proteção de Dados (AIPD) conforme exigido pelo Artigo 35.º do RGPD**. As AIPD ajudam a identificar **riscos potenciais, avaliar estratégias de mitigação e garantir a conformidade com as normas legais e éticas**. Além disso, as instituições de ensino devem fornecer políticas de privacidade claras e adequadas à idade para alunos e pais, garantindo que compreendam os seus direitos e as implicações das decisões baseadas em IA.

Proteção de Dados por Design e Controlo do Utilizador

Seguindo o princípio da **Privacidade por Conceção (Artigo 25.º do RGPD)**, as ferramentas de IA devem ser configuradas para recolher **o mínimo de dados necessário** por defeito. Os alunos e os pais devem ter fácil acesso a **definições de privacidade, mecanismos de exclusão e opções de eliminação de dados**. Além disso, as instituições devem garantir a conformidade com os **direitos do titular dos dados** (Artigos 15.º a 22.º), permitindo aos utilizadores **aceder, corrigir, eliminar ou portar os seus dados** quando necessário.

Garantia de Idade e Salvaguardas para Crianças

Com crescentes preocupações sobre a **verificação da idade**, as plataformas de educação baseadas em IA devem equilibrar a segurança com a privacidade. Embora os mecanismos de garantia de idade possam ajudar a proteger os menores, as soluções mal implementadas podem introduzir **novos riscos**, como a recolha excessiva de dados ou métodos de identificação falhos. As instituições devem priorizar soluções que forneçam **salvaguardas eficazes sem violar os direitos de privacidade**.

O apoio à decisão baseado em dados na educação tem um imenso potencial para revolucionar as experiências de aprendizagem, oferecendo uma **educação personalizada, com acessibilidade melhorada e com processos administrativos eficientes**.

7 PRINCIPLES OF PRIVACY BY DESIGN

1



Proactive not reactive; preventative not remedial

Take a proactive rather than reactive approach to privacy. Identify and mitigate privacy risks before they happen.

2



Privacy as the default setting

Design privacy-by-default features to ensure that consumers don't have to take extra measures to protect privacy.

3



Privacy embedded into design

Take a privacy-first approach right from the initial stages of a product's development and design.

4



Full functionality – positive-sum, not zero-sum

Privacy is a positive-sum goal, not a zero-sum goal. Avoid the false idea of trade-offs between privacy and other functionalities.

5



End-to-end security – lifecycle protection

Prioritise the security of user data throughout its lifecycle, from data collecting to its deletion.

6



Visibility and transparency

Implement transparency by documenting and communicating actions clearly, through privacy and data-sharing policies.

7



Respect for user privacy

Keep the interests of your users at the core by building strong privacy safeguards and user-friendly systems.

Source:
www.cookieyes.com/blog/privacy-by-design

CookieYes

f t in /CookieYesHQ

No entanto, estes benefícios acarretam **desafios significativos de privacidade, segurança e ética**. Ao aderir aos regulamentos da UE, implementar **medidas rigorosas de proteção de dados, realizar avaliações de risco e garantir a transparência**, as instituições de ensino podem aproveitar o potencial da IA, salvaguardando os direitos e interesses dos alunos.

À medida que a IA na educação continua a evoluir, o **equilíbrio entre inovação e responsabilidade** permanecerá crítico. Os decisores políticos, os educadores e os programadores de IA devem trabalhar em colaboração para criar **sistemas de IA fiáveis, justos e compatíveis com a privacidade** que melhorem verdadeiramente a educação sem comprometer os direitos fundamentais.

2. Dependência Excessiva de Dados

A vasta quantidade de dados na sociedade levou à utilização de tecnologias orientadas por algoritmos, como a inteligência artificial (IA) e a aprendizagem automática (AA), para organizar e interpretar informações. No entanto, a dependência excessiva de dados pode ser problemática se estes sistemas não forem devidamente concebidos. A IA depende de informações quantificáveis, levantando preocupações sobre se as realidades complexas podem realmente ser reduzidas a dados. Em última análise, os preconceitos, as perceções e as visões do mundo humanas moldam a conceção e a avaliação destes sistemas, impondo maiores limitações do que a própria tecnologia. Mesmo quando as máquinas aprendem, os humanos definem o seu ponto de partida e a estrutura de aprendizagem (Kallberg, 2022).

A dependência excessiva de dados refere-se a uma dependência excessiva de modelos orientados por dados para a tomada de decisões, sem considerar o contexto, o julgamento humano ou fatores externos, especialmente quando os dados utilizados são falhos, limitados ou carecem de diversidade.

Equilibrar a quantidade e a qualidade dos dados

Os modelos de *machine learning*, especialmente os algoritmos de *deep learning*, exigem frequentemente quantidades substanciais de dados para identificar padrões complexos. No entanto, a qualidade nunca deve ser sacrificada em prol da quantidade (Pagadala, 2023). No intrincado domínio do *machine learning*, encontrar o equilíbrio perfeito entre a quantidade e a qualidade dos dados é como equilibrar-se numa corda bamba. Por um lado, mais dados proporcionam ao modelo uma perspetiva mais ampla, permitindo-lhe generalizar melhor para dados não visualizados. Por outro lado, dados de alta qualidade garantem que o modelo aprende com padrões fiáveis, resultando em previsões precisas. Enquanto a quantidade garante a abrangência, a qualidade garante a precisão.

- Quantidade em detrimento da qualidade: Se os dados forem abundantes, mas grande parte deles for de baixa qualidade, o modelo poderá aprender padrões incorretos, levando a previsões não fiáveis.
- Qualidade em detrimento da quantidade: Por outro lado, ter dados de alta qualidade, mas insuficientes, pode limitar a capacidade do modelo de generalizar para diversos cenários.

Melhorar a qualidade dos dados

Os dados, tal como definidos por Andrea Jones-Rooy, são uma aproximação imperfeita de algum aspeto do mundo num determinado momento e lugar (Jones-Rooy, 2019). Enquanto os dados forem considerados uma verdade fria, dura e infalível, corremos o risco de gerar e reforçar muitas compreensões imprecisas do mundo que nos rodeia. Por essa razão, a qualidade dos dados tem um impacto direto na IA o desempenho, a precisão e a fiabilidade dos modelos (Redman, 2018). Dados de alta qualidade permitem que os modelos façam melhores previsões e produzam resultados mais fiáveis, promovendo a confiança entre os utilizadores (Ataman, 2024).

Garantir a qualidade dos dados também significa abordar a parcialidade presente nos dados, o que é essencial para evitar a sua perpetuação e amplificação nos resultados gerados pela IA. Além disso, um conjunto de dados diversificado e representativo melhora a capacidade de um modelo de IA em diferentes cenários e tipos de informação, garantindo o seu desempenho e relevância em vários contextos e grupos de utilizadores. Em última análise, manter a qualidade dos dados é fundamental para concretizar todo o potencial dos sistemas de IA na entrega de valor, impulsionando a inovação e garantindo resultados éticos.

Os principais componentes dos dados de qualidade na IA são a precisão, a consistência, a abrangência, a atualidade, a relevância, a integridade, a diversidade e a representatividade.

- Precisão: Dados precisos e sem erros garantem que os modelos de IA aprendem com informações corretas, reduzindo o risco de previsões enganosas e tomada de decisões deficientes. Por outro lado, erros na entrada de dados podem levar a decisões incorretas ou *insights* equivocados, causando potencialmente danos significativos, tanto a organizações como a indivíduos.
- Abrangência: Conjuntos de dados abrangentes que capturam todas as variáveis relevantes evitam lacunas de informação, permitindo que o modelo identifique padrões e relações significativas. Pelo contrário, a falta de integridade dos dados refere-se à situação em que o conjunto de dados utilizado para treinar um modelo de *machine learning* carece de determinadas informações ou tem valores em falta para algumas das suas características. Conjuntos de dados incompletos podem impedir que os algoritmos de IA detetem padrões e correlações críticos, comprometendo a capacidade do modelo de generalizar eficazmente para dados novos e não visualizados.

- **Consistência:** Dados uniformes em todas as fontes e períodos de tempo evitam contradições e garantem que o modelo recebe informações coerentes, melhorando a estabilidade e a fiabilidade, enquanto dados inconsistentes podem levar à confusão e interpretação errada, prejudicando o desempenho dos sistemas de IA.
- **Relevância:** Os dados devem estar diretamente relacionados com o problema a ser resolvido. Dados relevantes contribuem diretamente para o problema em questão, ajudando os sistemas de IA a concentrarem-se nas variáveis e relações mais importantes. Dados irrelevantes podem sobrecarregar os modelos e introduzir ruído, reduzindo a eficácia do modelo.
- **Atualidade:** Dados atualizados garantem que o modelo reflete as tendências e os comportamentos atuais, o que é fundamental para a adaptação a ambientes em mudança, enquanto dados desatualizados resultam em resultados irrelevantes ou enganosos. Daí a importância de treinar sistemas com dados atualizados para garantir um elevado desempenho da IA.
- **Diversidade e Representatividade:** Conjuntos de dados diversos e imparciais ajudam os modelos a generalizar bem em diferentes populações e cenários, minimizando o risco de resultados tendenciosos. Se os dados recolhidos não forem representativos de toda a população, podem levar a conclusões tendenciosas. As previsões do modelo serão um reflexo direto desses dados.
- **Integridade:** Dados seguros e inalterados protegem contra a corrupção ou manipulação, garantindo resultados fiáveis.

Para ilustrar o impacto dos problemas de qualidade dos dados, particularmente a falta de dados, considere um sistema de previsão de abandono que se baseia exclusivamente em dados históricos dos alunos, como notas, assiduidade e indicadores de empenho. No entanto, o modelo ignora fatores não quantificáveis, como problemas de saúde mental ou desafios pessoais. Consequentemente, os alunos que estão a ter dificuldades emocionais, mas que mantêm um forte desempenho académico, podem passar despercebidos e não receber o apoio necessário, reduzindo, em última análise, a eficácia do modelo na identificação de alunos em risco.

Permitir que os modelos aprendam e se adaptem ao longo do tempo

O ambiente em que a aprendizagem automática opera pode evoluir ou diferir daquele para o qual os algoritmos foram inicialmente desenvolvidos. Embora isto possa acontecer de muitas formas, duas das mais frequentes são a deriva de conceito e a mudança de covariável. Com a primeira, a relação entre as entradas de dados que o sistema utiliza e as suas saídas não é estável ao longo do tempo ou pode ser mal especificada (Babic, Cohen, Evgeniou, & Gerke, 2021).

Suponha que uma universidade utiliza um modelo de aprendizagem automática treinado com dados pré-pandemia para prever o risco de abandono dos alunos. O modelo baseia-se em fatores como a assiduidade às aulas, a participação em atividades no campus e a utilização de apoio académico presencial. No entanto, durante e após a pandemia de COVID-19, a universidade mudou para o ensino online

e híbrido. Os comportamentos e os padrões de envolvimento dos alunos mudam: a assiduidade é agora virtual, as atividades no campus são limitadas e os alunos dependem mais de recursos digitais.

O modelo, treinado com dados de aprendizagem presencial, não tem em conta estas mudanças comportamentais. Sinaliza incorretamente os alunos como de alto risco porque os indicadores tradicionais (como a assiduidade física) já não se aplicam. Por outro lado, pode ignorar os alunos em risco que estão a ter dificuldades com a aprendizagem *online* devido ao mau acesso à Internet, ao isolamento ou a problemas de saúde mental.

A precisão preditiva do modelo diminui porque a relação entre os dados de entrada e o risco de abandono mudou. Esta mudança nos padrões de dados reflete a deriva de conceito, destacando a necessidade de voltar a treinar o modelo com dados atualizados para se adaptar ao novo ambiente de aprendizagem.

É crucial capacitar os modelos para aprender e se adaptarem continuamente ao longo do tempo, sem exigir um novo treino completo. A implementação da aprendizagem contínua e por transferência permite que os modelos aproveitem eficazmente o conhecimento de tarefas relacionadas, melhorando a adaptabilidade e o desempenho.

As mudanças de covariáveis ocorrem quando os dados introduzidos num algoritmo durante a sua utilização diferem dos dados que o treinaram. Isto pode acontecer mesmo que os padrões que o algoritmo aprendeu sejam estáveis e não haja deriva de conceito (Babic et al., 2021). A mudança de covariáveis é um tipo específico de mudança de conjunto de dados frequentemente encontrado na aprendizagem automática. Ocorre quando a distribuição dos dados de entrada muda entre o ambiente de treino e o ambiente em direto.

Uma universidade desenvolve um modelo de aprendizagem automática para prever o risco de abandono dos alunos com base em dados históricos. O modelo utiliza características como as pontuações padronizadas nos testes, os registos de assiduidade e a participação em atividades extracurriculares para avaliar o risco.

A universidade adotou posteriormente uma política de admissão opcional em relação aos testes, reduzindo significativamente o número de estudantes que submetem resultados de exames padronizados. Além disso, o ensino online tornou-se mais comum, alterando os métodos de monitorização da assiduidade.

Embora a relação entre os indicadores e o risco de abandono (a distribuição condicional) permaneça a mesma, a distribuição das características da entrada de dados (covariáveis) mudou. Por exemplo, o modelo agora recebe menos resultados de exames padronizados, tornando esta característica menos informativa. Além disso, os dados de assiduidade recolhidos em plataformas online diferem dos registos tradicionais presenciais. Como resultado, o desempenho do modelo deteriora-se porque foi treinado com dados onde os resultados dos testes padronizados e a assiduidade

presencial eram indicadores fiáveis. Esta mudança na distribuição dos dados de entrada sem alterar a relação de resultados exemplifica uma mudança de covariável. Para resolver este problema, o modelo deve ser reajustado ou ajustado para ter em conta as novas distribuições de características.

Para mitigar as mudanças de covariáveis – alterações na distribuição dos dados de entrada entre o treino e o teste – podem ser utilizadas várias estratégias. A adaptação ao domínio procura alinhar as distribuições dos dados de treino e de teste através de técnicas como a normalização de características e o *adversarial learning*. A ponderação por importância ajusta a influência das amostras de treino com base nas diferenças de distribuição, enquanto a **seleção robusta** de características se foca em variáveis estáveis para minimizar a sensibilidade a mudanças. Os métodos de regularização melhoram a capacidade de generalização, e a *data augmentation* introduz cenários diversos. Os métodos de ensemble combinam vários modelos para equilibrar variações na distribuição dos dados, enquanto o *online learning* permite atualizações contínuas do modelo com novos dados. Além disso, a adaptação das estatísticas de normalização por lotes ao domínio-alvo melhora ainda mais a robustez. Em conjunto, estas abordagens ajudam a manter um desempenho consistente do modelo perante distribuições de dados variáveis.

Integrar dados com experiência prévia, conhecimento especializado humano e conhecimento do domínio

Como Andrea Jones-Rooy escreve no Quartz (Jones-Rooy, 2019), os dados só existem em primeiro lugar porque os humanos escolheram recolhê-los e recolheram-nos utilizando ferramentas feitas pelo homem. Portanto, os dados são tão falíveis quanto as pessoas. Os dados são essenciais para a descoberta, mas exigem o julgamento humano para selecionar, refinar e transformar em insights significativos. Em última análise, o valor dos dados depende da sua qualidade e da experiência e competências do indivíduo que os interpreta e utiliza (Jones-Rooy, 2019; Taylor, 2020). Além do manuseamento correto dos dados, é crucial ter em conta o conhecimento do domínio, compreender o processo por detrás dos dados e considerar as informações contextuais para o desempenho eficaz dos modelos de *machine learning*. Estes elementos contribuem para resultados mais precisos, fiáveis e significativos.

O impacto de análises falhas é minimizado quando os dados são utilizados juntamente com outros fatores de tomada de decisão, como o julgamento de especialistas e a compreensão contextual, uma vez que estes fatores adicionais podem compensar potenciais imprecisões. No entanto, quando os dados são utilizados como base principal para a tomada de decisões, análises incorretas podem levar a erros significativos e a resultados insatisfatórios. A principal conclusão não é desvalorizar o valor dos dados, mas sim destacar a importância de integrar os dados e os insights analíticos com ferramentas complementares de apoio à decisão, como a experiência prévia e o conhecimento especializado do domínio. Confiar exclusivamente nos dados

como fonte absoluta de verdade pode comprometer o processo de decisão e aumentar o risco de erro. (Nolis, 2018).

Por exemplo, na previsão do risco de abandono escolar precoce, pode ser valioso incorporar potenciais relações causais identificadas pelos professores para complementar os *insights* derivados da análise de dados. As observações e experiências em primeira mão dos professores podem fornecer fatores específicos do contexto que os dados sozinhos podem negligenciar, levando a uma avaliação de risco mais abrangente e precisa.

Integrar o conhecimento especializado do domínio é essencial para melhorar o desempenho dos modelos, como, por exemplo, ao incorporar conhecimentos de especialistas na seleção de características, nas restrições do modelo e na lógica de decisão. Além disso, combinar modelos baseados em dados com sistemas de raciocínio simbólico ou baseados em regras pode aumentar a interpretabilidade e a fiabilidade. Também é importante conceber sistemas com intervenção humana, permitindo supervisão em processos de decisão críticos e possibilitando intervenções e feedback atempados para garantir resultados mais precisos e responsáveis. Para além disso, a inferência e o raciocínio causais reforçam os modelos preditivos ao identificar relações reais de causa e efeito, em vez de se basearem apenas em correlações.". Isso leva a previsões mais robustas e generalizáveis, pois os modelos conseguem entender melhor como as mudanças nas variáveis de entrada influenciam os resultados. Em consequência, os modelos tornam-se mais interpretáveis e fiáveis, particularmente em ambientes complexos ou dinâmicos onde a compreensão dos mecanismos causais é crucial para previsões precisas e com aplicabilidade prática.

Melhorar a transparência, orientar a tomada de decisões e construir confiança e compreensão

As pessoas escolhem estrategicamente se querem ou não interagir com uma explicação de IA, demonstrando empiricamente que existem cenários em que as explicações de IA reduzem a dependência excessiva (Vasconcelos et al., 2023). O uso de modelos interpretáveis ou ferramentas de explicabilidade torna as decisões de IA transparentes e compreensíveis para as partes interessadas. As explicações esclarecem a tomada de decisões, ajudando os utilizadores a identificar quando os modelos dependem demasiado de dados ou padrões tendenciosos. As explicações também capacitam os especialistas de domínio a intervir, garantindo que os insights orientados por dados sejam equilibrados com a experiência do mundo real.

3. Considerações Éticas

Embora a IA e as ferramentas orientadas por dados tenham um grande potencial para melhorar a educação e reduzir o Abandono Precoce da Educação e Formação (APEF), a sua utilização também levanta questões éticas importantes. Para garantir que estas

tecnologias sejam utilizadas de forma responsável, é essencial abordar as preocupações em torno da justiça, transparência, privacidade e o seu impacto geral nos alunos e educadores. Abaixo estão algumas considerações éticas importantes a ter em mente:

1. Evitar a Parcialidade e Garantir a Justiça

Os sistemas de IA dependem de dados para tomar decisões, mas se esses dados refletirem as desigualdades existentes, isso pode levar a resultados injustos. Por exemplo, os alunos de contextos desfavorecidos podem ser incorretamente sinalizados como "em risco" simplesmente por causa de padrões em dados históricos. Isso pode reforçar estereótipos e agravar as desigualdades. Para evitar isso, devemos examinar cuidadosamente os dados utilizados e garantir que representem todos os grupos de forma justa. As ferramentas de IA devem ser planeadas para promover a inclusão, não a discriminação, e para tratar cada aluno como um indivíduo.

2. Tornar as Decisões Claras e Compreensíveis

Os sistemas de IA funcionam frequentemente como caixas negras, tomando decisões que são difíceis de explicar ou compreender. Para professores, pais e alunos, esta falta de clareza pode ser frustrante e reduzir a confiança no sistema. Para resolver este problema, as ferramentas de IA devem fornecer explicações claras e fáceis de entender para as suas recomendações. Os educadores devem conseguir perceber por que motivo um aluno é sinalizado como 'em risco' e como o sistema chegou a essa conclusão.

3. Apoiar os Alunos Sem os Estigmatizar

Rotular alunos como 'em risco' pode, inadvertidamente, prejudicar a sua autoconfiança ou levar a expectativas mais baixas por parte dos professores. É fundamental que os insights gerados por sistemas de inteligência artificial sejam utilizados de forma positiva, centrando-se no potencial dos alunos e promovendo oportunidades de desenvolvimento. Estas ferramentas devem servir para capacitar os estudantes e fortalecer a relação entre educadores e aprendentes, e não para definir ou limitar os seus percursos futuros.



4. Proteger a Privacidade e Obter Consentimento

Os dados pessoais dos alunos devem ser tratados com cuidado e respeito. As escolas e as organizações precisam de seguir regulamentos de privacidade rigorosos, como o RGPD, garantindo que todos os dados são armazenados de forma segura e utilizados apenas para fins educacionais. Os alunos e as suas famílias devem entender como os seus dados serão utilizados e ter o direito de dar ou negar o consentimento.

5. Manter a Responsabilidade e a Supervisão

As ferramentas de IA devem complementar, e não substituir, o julgamento humano. Se um sistema fizer uma previsão incorreta, deve haver uma forma de rever e corrigir. Os educadores devem manter o controlo sobre a forma como as recomendações de IA são aplicadas e devem existir processos de responsabilização claros para resolver quaisquer erros.

6. Envolver as Pessoas Certas na Conceção

As ferramentas de IA devem ser concebidas com o contributo das pessoas que afetam: professores, alunos, pais e decisores políticos. Incluir estas perspetivas ajuda a garantir que as ferramentas abordam necessidades reais e são éticas e práticas para utilizar em ambientes educativos quotidianos.

7. Equilibrar a Tecnologia com a Ligação Humana

Por fim, embora a IA possa ser uma ferramenta útil, a educação é fundamentalmente sobre relações humanas. Os professores, e não os algoritmos, compreendem as necessidades e emoções únicas dos seus alunos. Qualquer sistema de IA deve ser

utilizado para melhorar, e não substituir, as ligações pessoais que são tão vitais na educação.

Conclusão

A integração da Inteligência Artificial (IA) e das ferramentas orientadas por dados no domínio da educação representa uma mudança de paradigma na forma como as escolas compreendem, apoiam e respondem às necessidades dos alunos. Conforme explorado ao longo deste documento, a utilização de tecnologias de IA oferece oportunidades promissoras para personalizar a aprendizagem, antecipar riscos como o Abandono Precoce da Educação e Formação (APEF) e melhorar os processos de ensino e administrativos. Estas tecnologias não são novidades futuristas, estão a tornar-se parte integrante do panorama educativo atual.

Uma das contribuições mais poderosas da IA é a sua capacidade de apoiar a aprendizagem personalizada e centrada no aluno. Ao ajustar dinamicamente o conteúdo, o ritmo e o feedback com base em dados em tempo real, os sistemas de IA capacitam os alunos a seguir percursos de aprendizagem individualizados. Esta capacidade de resposta ajuda a aumentar o envolvimento, a reduzir a frustração e a evitar que os alunos fiquem para trás. Estes sistemas adaptativos são especialmente valiosos em salas de aula diversificadas, onde os alunos podem ter diferentes origens, estilos de aprendizagem ou necessidades de apoio.

Além disso, a IA melhora a capacidade dos educadores e dos sistemas escolares de detetar sinais de alerta precoce de desinteresse. Através da análise preditiva e da análise de padrões comportamentais, torna-se possível sinalizar os alunos que podem estar em risco de abandonar a educação prematuramente. É importante salientar que estas informações permitem que as escolas tomem medidas proativas e direcionadas, que vão desde o apoio escolar a intervenções socioemocionais, mudando assim o foco da reação para a prevenção.

No entanto, a adoção da IA na educação não pode avançar sem uma base sólida na consciencialização ética e no cumprimento regulamentar. As preocupações relacionadas com a privacidade dos dados, especialmente quando se trata de menores, são sérias e multifacetadas. As instituições devem garantir que as práticas de recolha, armazenamento e processamento de dados estão totalmente alinhadas com o Regulamento Geral de Proteção de Dados (RGPD), proporcionando transparência e consentimento significativo aos alunos e às suas famílias. Além disso, devem ser implementadas salvaguardas para evitar o uso indevido de informações confidenciais e para defender os direitos e a dignidade de todos os utilizadores.

Igualmente importante é a questão da dependência excessiva de dados. Embora os dados quantitativos possam fornecer informações valiosas, estes devem ser contextualizados dentro das realidades mais amplas da vida dos alunos e do julgamento dos educadores. Os modelos treinados apenas com base no desempenho

passado ou em indicadores restritos correm o risco de negligenciar as dimensões humanas, sociais e emocionais da aprendizagem. Integrar dados com a experiência dos professores, o conhecimento da escola e as experiências vividas dos alunos cria um processo de tomada de decisão mais equilibrado e preciso.

À medida que as tecnologias de inteligência artificial evoluem, os modelos devem ser capazes de aprender e de se adaptar a ambientes educativos em constante mudança. Os conceitos de *deriva de conceito* e *mudança de covariáveis* recordam-nos que o comportamento dos alunos, os contextos de aprendizagem e as realidades sociais são dinâmicos. Sistemas concebidos para ambientes estáticos correm o risco de se tornarem obsoletos ou de produzir resultados enganadores se não forem regularmente treinados com dados atualizados, os modelos correm o risco de perder relevância e precisão. Assim, a avaliação contínua, a supervisão humana e a adaptação flexível são características essenciais de sistemas de inteligência artificial fiáveis no contexto educativo.

Outra consideração crítica é a justiça e a inclusão. Os sistemas de IA devem ser cuidadosamente concebidos para evitar perpetuar preconceitos incorporados em dados históricos. Por exemplo, se dados escolares anteriores sub-representarem grupos desfavorecidos, os algoritmos podem, involuntariamente, penalizar estes mesmos alunos. A IA ética na educação deve promover ativamente a equidade, corrigindo desequilíbrios sistémicos, garantindo que todos os alunos sejam tratados de forma justa, independentemente da sua origem, capacidade ou contexto.

Em última análise, a integração bem-sucedida da IA na educação depende da participação ativa de todas as partes interessadas. Professores, alunos, pais, diretores de escolas e decisores políticos devem estar envolvidos na conceção, implementação e avaliação das ferramentas de IA. O seu *feedback* garante que as tecnologias permanecem alinhadas com os valores educativos, as realidades da sala de aula e os melhores interesses dos alunos. O envolvimento de baixo para cima é particularmente importante para criar sistemas adaptáveis, inclusivos e recetivos aos desafios do mundo real.

Em conclusão, a IA não é uma solução mágica, mas uma ferramenta poderosa – que deve ser usada de forma sensata, ética e colaborativa. Quando devidamente concebida e implementada, a IA pode apoiar ambientes de aprendizagem mais recetivos, equitativos e envolventes. Através da responsabilidade partilhada, da reflexão contínua e de um compromisso com o bem-estar dos alunos, podemos garantir que a inovação tecnológica serve o objetivo de uma educação inclusiva e de qualidade para todos.

Referências Bibliográficas

1. Austur-Vestur sköpunarsmiðjur. (n.d). <https://sites.google.com/rvkskolar.is/austurvestur/>
2. Ataman, A. (2024). Data Quality in AI: Challenges, Importance & Best Practices. Retrieved from AIMultiple RESEARCH website: <https://research.aimultiple.com/data-quality-ai/>
3. Babic, B., Cohen, I. G., Evgeniou, T., & Gerke, S. (2021). When Machine Learning Goes Off the Rails: A guide to managing the risks. Retrieved from <https://hbr.org/2021/01/when-machine-learning-goes-off-the-rails>
4. Bañeres, D., Rodríguez-González, M. E., Guerrero-Roldán, A. E., & Cortadas, P. (2023). An early warning system to identify and intervene online dropout learners. *International Journal of Educational Technology in Higher Education*, 20(1). <https://doi.org/10.1186/s41239-022-00371-5>
5. Embarak, O. H., & Hawarna, S. (2024). Enhancing Student Success with XAI-Powered RADAR: An Automated AI-driven System for Early Detection of At-risk Students. *Procedia Computer Science*, 231(2023), 151–160. <https://doi.org/10.1016/j.procs.2023.12.187>
6. Jones-Rooy, A. (2019). I'm a data scientist who is skeptical about data. Retrieved from <https://qz.com/1664575/is-data-science-legit>
7. Kallberg, J. (2022). The risks of over-reliance on quantifiable data. Retrieved from <https://www.linkedin.com/pulse/risks-over-reliance-quantifiable-data-kallberg-ph-d-cism-cissp/>
8. Mixtúra. (n.d.). <https://reykjavik.is/en/residents-children-youth/mixtura>
9. Nolis, J. (2018). You're relying on data too much: Making decisions worse, not better. Retrieved from <https://towardsdatascience.com/youre-relying-on-data-too-much-250d4edc70c3>
10. Pagadala, S. (2023). Maximizing Machine Learning Success: The Data Dilemma Unraveled. Retrieved from <https://pagadala-saiteja.medium.com/maximizing-machine-learning-success-the-data-dilemma-unraveled-87b941236cf8>
11. Redman, T. C. (2018). If Your Data Is Bad, Your Machine Learning Tools Are Useless. Retrieved from <https://hbr.org/2018/04/if-your-data-is-bad-your-machine-learning-tools-are-useless>
12. Taylor, P. (2020). The Problem With An Over-Reliance On Data. Retrieved from <https://paulitaylor.com/2020/11/08/the-problem-with-an-over-reliance-on-data/>
13. Vasconcelos, H., Jörke, M., Grunde-McLaughlin, M., Gerstenberg, T., Bernstein, M. S., & Krishna, R. (2023). Explanations Can Reduce Overreliance on AI Systems During Decision-Making. *Proceedings of the ACM on Human-Computer Interaction*, 7(CSCW1), 1–38. <https://doi.org/10.1145/3579605>
14. European Commission. (2016). General Data Protection Regulation (GDPR) (Regulation (EU) 2016/679). Official Journal of the European Union. Retrieved from <https://eur-lex.europa.eu>
15. European Data Protection Board (EDPB). (2020). Guidelines on Data Protection by Design and by Default. Retrieved from <https://edpb.europa.eu>
16. Council of Europe. (2021). Artificial Intelligence, Education, and Human Rights: A Policy Brief. Strasbourg, France: Council of Europe.
17. Floridi, L., & Cows, J. (2019). A Unified Framework of Five Principles for AI in Society. *Harvard Data Science Review*, 1(1). <https://doi.org/10.1162/99608f92.8cd550d1>
18. Luckin, R., Holmes, W., Griffiths, M., & Forcier, L. B. (2016). *Intelligence Unleashed: An Argument for AI in Education*. Pearson Education.
19. Selwyn, N. (2022). *Should Robots Replace Teachers? AI and the Future of Education*. Polity Press.
20. UNESCO. (2023). *AI and Education: Guidance for Policy-Makers*. United Nations Educational, Scientific and Cultural Organization. Retrieved from <https://unesdoc.unesco.org>

21. West, S. M., Whittaker, M., & Crawford, K. (2019). Discriminating Systems: Gender, Race, and Power in AI. AI Now Institute. Retrieved from <https://ainowinstitute.org>