

EDUCAÇÃO A DISTÂNCIA E O USO DA INTELIGÊNCIA ARTIFICIAL POR MEIO DE AGENTES COMO FATOR AGREGADO EM SISTEMAS INTELIGENTES

DISTANCE EDUCATION AND THE USE OF ARTIFICIAL INTELLIGENCE THROUGH AGENTS AS AN AGGREGATE FACTOR IN INTELLIGENT SYSTEMS

Geise Divino da Silva

ORCID 0000-0002-7807-3256

Instituto Federal de Educação, Ciência e Tecnologia do Triângulo Mineiro, IFTM
Ituiutaba, MG, Brasil
geisesilva@iftm.edu.br

Hugo Leonardo Pereira Rufino

ORCID 0000-0001-7687-3375

Instituto Federal de Educação, Ciência e Tecnologia do Triângulo Mineiro, IFTM
Uberaba, MG, Brasil
hugo@iftm.edu.br

Paula Teixeira Nakamoto

ORCID 0000-0001-8705-8587

Instituto Federal de Educação, Ciência e Tecnologia do Triângulo Mineiro, IFTM
Uberaba, MG, Brasil
paula@iftm.edu.br

Resumo. Postula-se averiguar as transformações tecnológicas que impulsionam a Educação a Distância (EaD) por meio da Inteligência Artificial (IA). Ela pode se transformar numa poderosa ferramenta, ampliando possibilidades de ter resultados mais assertivos e eficazes ao processo de avaliar o conhecimento obtido pelo aluno em conteúdos pedagógicos ministrado pelo professor. Os agentes são os recursos à técnica da IA, atuantes em Sistema de Tutor Inteligente (STI), que permitem flexibilizar parte deste processo da avaliação, pois suas características de responder a inferências do próprio ambiente, possibilitam a eles exibirem resultados futuros, com base em estatísticas, tornando-os autônomos e inteligentes. Este trabalho tem como proposta, apresentar um projeto ou sua inserção dos agentes em IA no STI, em específico à plataforma *MOODLE*, a qual permite flexibilizar uma melhor forma de aprendizagem em conformidade com as necessidades dos estudantes, respeitando o seu nível de conhecimento. Flexibilidade que ocorrerá por meio da classificação das atividades, a ser realizada pelos estudantes em lista de exercícios, com grau de dificuldades em níveis fácil, médio e difícil. O *MOODLE* armazena e disponibiliza ao discente todo o material preparado na aula do professor e, com a incorporação desta técnica da IA, o processo será adaptado ao mensurar cada estudante e respeitando o seu conhecimento prévio. Respeito ao seu perfil de escolaridade pela vivência aos limites do aspecto cognitivo, suas deficiências de conhecimento ao(s) conteúdo(s) não assimilado(s) no ensino médio ou em unidade(s) curricular(es) no curso da graduação, incentivando a galgar níveis de superação e aquisição da aprendizagem.

Palavras-chave: Educação a Distância; Inteligência Artificial; Agentes; Rede Neural Artificial; Aprendizagem.

Abstract. It is proposed to investigate the technological changes that drive Distance Education (EaD) through Artificial Intelligence (AI). It can become a powerful tool, expanding possibilities to have more assertive and effective results in the process of evaluating the knowledge obtained by the student in pedagogical content taught by the teacher. The agents are the resources to the AI technique, working in an Intelligent Tutor System (STI), which allow for flexibility in part of this evaluation process, as their characteristics of responding to inferences from the environment, enable them to display future results, based on statistics, making them autonomous and intelligent. This work proposes to present a project or its insertion of AI agents in the STI, specifically to the *MOODLE* platform, which allows for a better way of learning in accordance with the needs of students, respecting their level of knowledge. Flexibility that will occur through the classification of activities, to be performed by students in a list of exercises, with difficulty levels in easy, medium and difficult levels. The *MOODLE* stores and makes available to the student all the material prepared for the teacher's class and, with the incorporation of this AI



technique, the process will be flexible when measuring each student respecting their previous knowledge. Respect for their education profile by experiencing the limits of the cognitive aspect, their deficiencies in knowledge of the content(s) not assimilated in high school or in curricular unit(s) in the undergraduate course, encouraging to reach levels of overcoming and acquiring learning.

Keywords: Distance Education; Artificial intelligence; Agents; Artificial Neural Network; Learning.

1 INTRODUÇÃO

O Ensino a Distância (EaD) tem-se evidenciado como uma ‘mola propulsora’ na taxa de crescimento à demanda por inscrições em cursos nas Instituições de Ensino Superior (IES) no Brasil. Fato este que se comprova pela publicação do MEC (2018), Ministério da Educação e Cultura, em setembro de 2018, conforme as Figuras 1 e 2.



Figura 1. Matrículas por modalidade ensino.
Fonte: Ministério da Educação e Cultura (MEC)

Uma rápida análise no gráfico da figura 1, observa-se que a taxa de crescimento da EaD nos últimos 10 anos (2007-2017) permite identificar uma ‘impulsão’ quase 15% (de 7,0% para 21,2%) nesta modalidade, comparada ao ensino presencial.

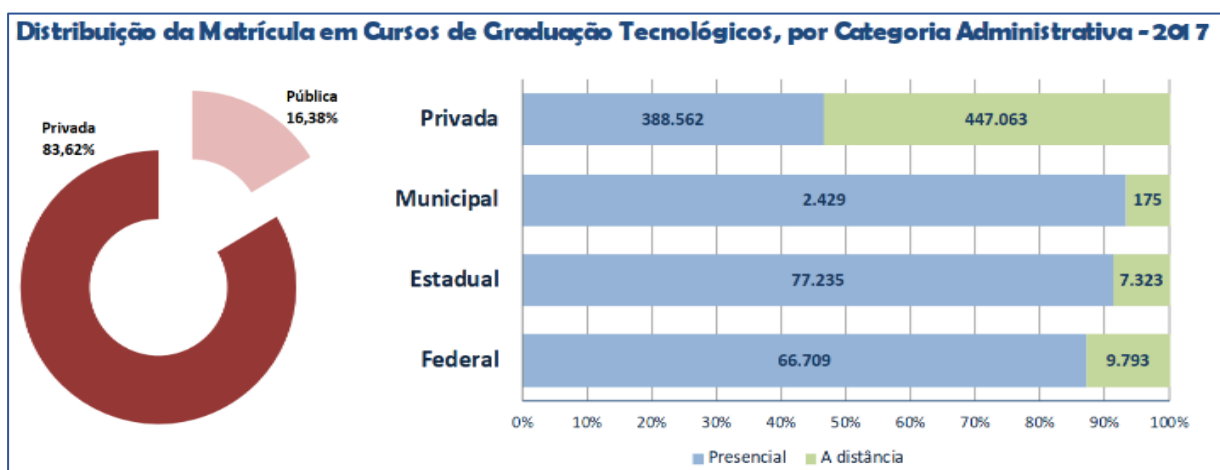


Figura 2. Matrículas em cursos tecnológicos
Fonte: Ministério da Educação e Cultura (MEC)

Na Figura 2, os cursos tecnológicos (de curta graduação) nas IES particulares, visualiza-se a participação de 86% a 92% ao número de matrículas efetivadas em EaD (nas esferas municipal, estadual e federal) que superam o ensino presencial.

A comprovação destes indicadores foi divulgada pela Agência Brasil (2022) onde o quantitativo de matrículas em cursos presenciais diminuiu 13,9%, enquanto nos cursos EAD aumentou 428,2%, sendo que em 2010, a participação percentual dos novos alunos em cursos superiores online era de 17,4% e alcançou 53,4% dos estudantes. É neste cenário que se identifica o real crescimento da EaD onde o Ambiente Virtual de Aprendizagem (AVA) tem um papel importantíssimo, pois ele compreende um conjunto de software de gerenciamento educacional, o Learning Management System (LMS). Aliado a vasta oferta de acesso rápido à internet pela infraestrutura das telecomunicações, se transforma em um vultoso repositório de dados e em uma IES armazena, em banco de dados, as entidades de cursos, discentes, tutores, docentes, turmas, provas, notas, atividades diversas (fórum, chat, módulos, questionários e outras).

Um destes AVA é o MOODLE (2021), o Modular Object-Oriented Dynamic Learning Environment, uma plataforma livre (sem ter que pagar licenças a fornecedor) que se torna uma das mais importantes. Isto pelo momento em que o mundo vivenciou a pandemia da COVID-19, pois as atividades de aulas, antes presenciais, migraram às remotas pelo uso em massa da internet que tornou essencial na educação, em um momento de anormalidade.

Pandemia esta que lamentavelmente erradicou a normalidade, transformando por completo as formas de trabalho, tendo a convivência pessoal experimentado a metamorfose do distanciamento social a fim de evitar uma maior contaminação deste vírus e, no segmento educacional não foi diferente, conforme:

O confinamento aguçou nosso olhar para a educação como encontro vivo entre pessoas – todos os envolvidos – que desenvolvem competências cognitivas, socioemocionais e éticas. Mostrou a importância da empatia, da resiliência, do acolhimento, da escuta ativa, do estabelecimento de vínculos, do compartilhamento de saberes, da flexibilidade para entender que a situação e necessidades de cada um são diferentes. Muitos perceberam a fragilidade da vida, a importância do afeto, de valorizar-se, de desenvolver projetos interessantes, de gostar de aprender e de viver de forma mais simples [...] O ineditismo do confinamento tão longo, causou intenso estresse em todos, mas permitiu experimentar diversas soluções para a comunicação frequente com alunos e famílias, manter da melhor forma a dinâmica do ensino e aprendizagem. MORAN (2020, pag.1-2).

Moran (2020) ao sinalizar a possibilidade de experimentar alternativas para melhor comunicar com os discentes aliado ao intenso estresse causado pelo longo confinamento, nos leva a uma reflexão, em obter novas competências e habilidades a fim de aplicar outros métodos de ensino e aprendizagem, isto na tentativa de minimizar este desgaste emocional. Importante destacar que este isolamento social ou confinamento, introduziu as aulas remotas na educação que foram utilizadas por muitas das IES e permitiu instigar a visão para competências socioemocionais e cognitivas.

1.1 Contextualização de IA e agentes em sistemas de tutores inteligentes

Algumas destas competências relatadas por Moran (2020) podem ser obtidas utilizando-se da técnica de IA, os agentes inteligentes, a fim de incluir nos Sistemas de Tutor Inteligente (STI), agregando uma maior flexibilidade a plataforma de ensino e aprendizagem, para uma melhor estruturação dos conteúdos a ser ministrados nas atividades aos discentes, de maneira específica. Isto possibilitará que os estudantes de uma mesma turma tenham acesso a material

didático customizado, conforme a estruturação pedagógica de cada docente onde as tarefas de assimilação de conteúdo, proposta ao aluno, ocorram por lista de exercício personalizada.

Importante destacar alguns conceitos, inicialmente o de IA que no meio acadêmico é um ramo da ciência/engenharia da computação que visa desenvolver sistemas computacionais na resolução de problemas, extrapolando assim os algoritmos os quais contém um determinado número de ações ou passos finitos para solucionar um problema em específico. Wooldridge (1997) define um agente inteligente como um sistema computacional encapsulado que está situado em algum ambiente, sendo capaz de ação autônoma e flexível naquele ambiente, a fim de cumprir seus objetivos. STI são sistemas complexos que envolvem vários tipos diferentes de especialidade: conhecimento do domínio, conhecimento dos estudantes, conhecimento pedagógico e se caracteriza por incorporar técnicas de IA no seu projeto de desenvolvimento que atua auxiliando no processo de ensino e aprendizagem (SANTOS et al. 2001).

Neste contexto, os agentes do STI classificarão o nível de aprendizagem adquirida pelos alunos, mensurado por meio da sua nota, obtida no desempenho de cada lista, em um período específico do curso à plataforma MOODLE. Uma das características de um agente em STI, compreende responder a inferências do ambiente e exibir o estado futuro com base em estatísticas. Outra, não menos importante, a de aumentar a capacidade autônoma em si – a inteligência sinalizada por Brener, Zarnekow e Wittig (1998) – adquirida por meio da técnica de IA usando uma base de conhecimento e o raciocínio que se consolidam como autônomo e inteligente.

O ensino e aprendizagem apresentam uma característica base, o inter-relacionamento, que entre uma de suas finalidades, a de mensurar o conhecimento adquirido pelo estudante, visa transformar e absorver comportamentos motores, cognitivos, afetivos e sociais. Desta forma, a atividade avaliativa tem por objetivo mensurar se o conhecimento está sendo atingido e em que grau ele ocorre, isto para ajudar o aluno a avançar na aprendizagem e na construção do seu saber. Araújo e Gouveia (2002) relatam que o ato de avaliar, assume um sentido orientador e cooperativo pela classificação do nível de aprendizagem.

Ao incorporar a técnica de IA aos agentes em STI na plataforma MOODLE permitirá que esta abordagem, a avaliação da aprendizagem seja mais assertiva. Isto porque flexibilizará o contexto ao mensurar cada estudante com respeito ao seu conhecimento prévio, seus limites ao aspecto de cognição, suas deficiências de escolaridade ao conteúdo não assimilado no ensino médio ou em unidades curriculares no curso na graduação, incentivando a galgar níveis de superação e a aquisição deste conhecimento.

E esta flexibilização do MOODLE se faz necessário para mensurar as atividades por meio das atividades personalizadas, porque irá consolidar o grau de conhecimento a ser adquirido pelos alunos, com níveis de aprendizado diferenciados, como facilitadores e incentivadores na busca pela melhor qualidade no ensino.

Assim exposto, Araújo e Gouveia (2002) corroboram no sentido da cooperação, seja por implementar o método de classificação do nível de aprendizagem – ao avaliar a lista de exercícios transformando em grau de conhecimento – para que o discente possa evoluir com e pela construção do conhecimento, o seu próprio saber. Seja pela inserção dos agentes neste ambiente do MOODLE, inicialmente por atividades pré-definidas em lista de exercícios onde os níveis evoluir-se-ão por meio desta arquitetura que se complementarará no uso de recursos da IA por meios destes agentes autônomos e inteligentes.

Portanto, a flexibilidade adquirida neste STI agregará uma nova expertise ao MOODLE permitindo o docente conhecer ainda melhor o seu aluno, pela realização das atividades, identificando o nível no qual se encontra, por meio do desempenho na aplicação dos agentes, customizando assim a próxima lista de exercício(s) ou de outros componentes.

2 METODOLOGIA

Serão apresentados três contextos que utilizara a IA com STI à plataforma MOODLE.

2.1 Aplicação de um modelo adaptativo de tutores inteligentes para disseminação do conhecimento em ambientes virtuais de ensino aprendizagem

Para fins de uma melhor compreensão dos agentes inteligentes, a figura 3 apresenta uma visão geral da proposta à plataforma AVA de ensino e aprendizagem, o MOODLE.




Figura 3. Proposta ao *MOODLE*. Fonte: Adaptada pelos autores

O processo inicia pelo professor que elabora sua lista de exercícios, conforme o conteúdo pedagógico ministrado, e as configura na plataforma MOODLE para que o “Agente 2”, em suas várias instâncias, use as técnicas de IA a fim de aplicar a flexibilidade a esta lista que contém três (3) níveis de dificuldade: 1-Fácil, 2-Médio e 3-Difícil. O estudante resolve a atividade proposta, inicialmente ao nível 1, e ao finalizá-la, o outro Agente, o de número 1 é instanciado para calcular a média de sua(s) nota(s) para fins de classificar o novo grau ou nível de conhecimento obtido. Após este cálculo da nota gerada pela média aritmética, o agente 1 continua o seu processamento para comparar o próximo nível a ser obtido pelo discente (parâmetros que podem ser atualizados conforme a necessidade – Tabela 1), utilizando uma tabela de critérios em conformidade aos parâmetros, 1 – Fácil: $2,5 < \text{Nota} \leq 5,5$, 2 – Médio: $5,5 < \text{Nota} \leq 7,9$ e 3 – Difícil: $\text{Nota} > 7,9$.

O aluno que tiver nota inferior a 2,5 ele não avança à próxima lista do conteúdo pedagógico, permanecendo com nível 0. Neste perfil, o “Agente 1” atualiza a sua nota em zero e permite uma nova tentativa naquela mesma lista de exercício. A figura 4 apresenta o fluxo dos “Agentes” 1 e 2.

Tabela 1. Critérios a classificação do nível do estudante

Parâmetro	Nota mínima	Nota máxima	Nível Obtido (Agente 1)
1	0,0	2,5	0-Nova tentativa
2	2,6	5,5	1-Fácil
3	5,6	7,9	2-Médio
4	8,0	10,0	3-Difícil

Fonte: Giuffra (2017)

desperta o aspecto cognitivo do estudante, de maneira subliminar, cuja pretensão é a de inferir na sua performance e se consolidar na aquisição do conhecimento da próxima atividade proposta.

2.2 STI em Agentes no MOODLE e apoio das atividades pedagógicas na UAB do Piauí

Esta proposta tem como referência aplicar agentes de STI por meio da técnica de Aprendizagem de Máquina, o Machine Learning, um ramo da IA que estuda o desenvolvimento de sistemas capazes de aprender com e pela experiência. Este aprendizado ocorre pela realização de uma determinada tarefa que obtém estas informações, permitindo processamento futuro desta mesma tarefa com um desempenho superior, conforme Mitchell (1997).

As três formas de se aplicar a técnica de aprendizagem de máquina, compreendem a supervisionada, não-supervisionada e reforço. Foi utilizada a não-supervisionada, permitindo classificar os estudantes em agrupamentos, (clusters), tornando possível a melhor recomendação das atividades pedagógicas a cada perfil.

Vale destacar que estes clusters ou agrupamentos são gerados por meio de algoritmos para que esta classificação ocorra de forma desejada. Dois algoritmos de Mineração de Dados (MD) foram utilizados e adaptados nesta proposta, o k-means e o J48. O primeiro, usa um parâmetro de entrada k, que determina a quantidade de clusters, isto ocorre por meio de uma coleção de objetos que são similares uns aos outros – de acordo com algum critério de similaridade pré-definido – ou dissimilares de objetos pertencentes a outros clusters; isto porque os agrupamentos possuem ‘n’ elementos (clusters podem ter esta quantidade diferentes). Após este processamento, a meta é detectar uma alta similaridade dos elementos de um grupo e baixa similaridade entre os clusters criados pelo primeiro algoritmo, o k-means. O segundo algoritmo, o J48, decide o valor de destino (variável dependente) de uma nova amostra com referência a diversos valores de atributos dos dados disponíveis, formando uma árvore de decisão. Nesta, os nós internos denotam os diferentes atributos; seus ramos que estão entre os nós, dizem os possíveis valores que esses atributos podem ter nas amostras observadas, enquanto os nós terminais nos apresentam o valor final (a classificação) da variável dependente, sinalizados por Foruzan et al (2013).

Os agentes ao STI da plataforma MOODLE à Universidade Aberta (UAB) do Piauí pretendem modificar suas bases de conhecimento, percebendo as intervenções do aprendiz, dotados da capacidade de aprender e adaptar suas estratégias de ensino mediante a interação com o estudante e auxiliando o papel do professor (tutor), presente na figura 5.

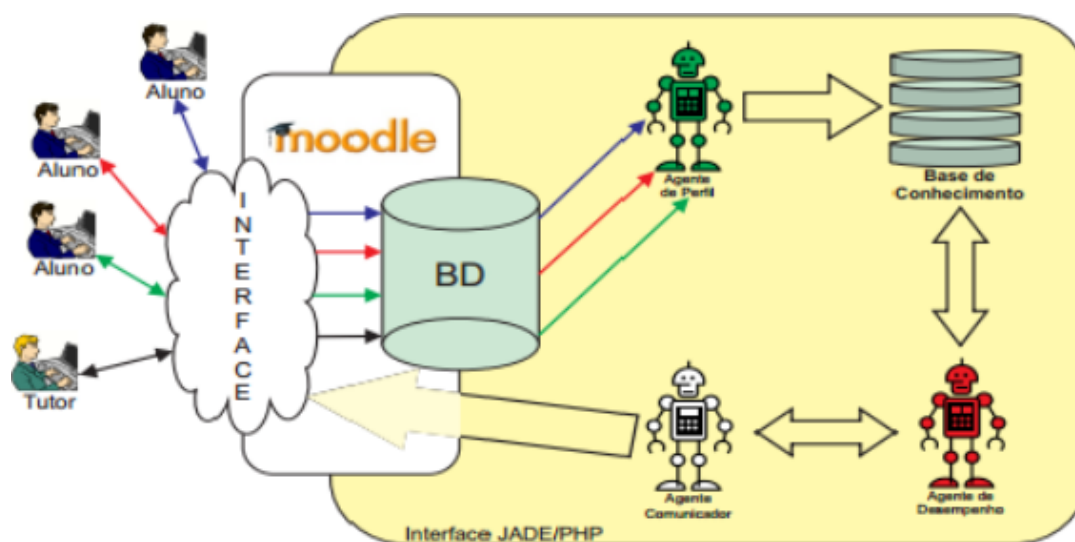


Figura 5. Arquitetura de agentes no MOODLE da UFPI

Fonte: Silva, Machado, Araujo (2014)

Conforme se observa na figura 5, há 3 agentes ao STI, 1 Perfil será responsável por captar o perfil do aluno, identificando suas deficiências e necessidades; 2 Desempenho irá proporcionar condições de decisão de que tarefa ou ação a ser executada e 3 Comunicador servirá de elo entre processo do STI e o tutor, colocando este a par das atividades exercidas pelos alunos e sugerindo intervenções pedagógicas. Além dos agentes que atuam no STI, tem-se a interface Java Agente Development Framework (JADE) que é uma estrutura de software livre que torna o desenvolvimento de aplicações multiagente mais rápido e a linguagem de script Hypertext PreProcessor (PHP) compreende a mesma linha de software livre ao desenvolvimento de aplicações web dinâmicas onde o código é executado no servidor.

2.3 Os estilos de aprendizagem em EaD com IA por meio das Redes Neurais Artificiais

Os estilos de aprendizagem compreendem o modo pelo qual cada indivíduo começa a concentrar, processar e reter novas informações, exprimindo diferenças no processamento de informações, apresentando três componentes: 1 Maneira de processar a informação; 2 Seleção dinâmica das estratégias de aprender e 3 Sua própria percepção da pessoa com respeito a como aprender. No intuito de conseguir aprendizagens eficazes, estudiosos em educação têm identificado diferentes formas como as pessoas percebem e processam novas informações; como certas estratégias de aprendizagem trabalham a informação e como a mente é influenciada pelas percepções de cada pessoa.

Um destes estudiosos, Kolb (1984) apresenta um modelo o qual compreende as dimensões estruturais básicas do processo de aprendizagem experimental e as formas de conhecimento básico resultantes, figura 6.



Figura 6. Estilos de aprendizagem

Fonte: Martins, Meireles, Melo e Nalini (2003)

Neste modelo, os quatro extremos definem as fases do ciclo de aprendizagem onde o eixo horizontal traz o discernimento entre observação reflexiva (assistindo) e experimentação ativa (fazendo), enquanto o eixo vertical divide a preferência entre experiência concreta (sentindo) e conceitualização abstrata (pensando). Foram identificados quatro tipos diferentes de estudantes (estilos de aprendizagem): 1 diversificador, 2 assimilador, 3 solucionador e 4 adaptador, são formados a partir da combinação das dimensões opostas das duas atividades de aprendizado.

Esta proposta tem a IA sendo aplicada pelas Redes Neurais Artificiais (RNAs) e Haykin (2000) explicita que ela imita a maneira do cérebro humano processar informações, como estruturas de processamento distribuído e paralelo, utilizando software ou hardware, onde a solução em grande parte não é vantajosa, isto por ter um processamento que demanda muito mais recurso computacional. Visando facilitar o entendimento desta imitação, é importante compreender o funcionamento do neurônio biológico cuja estrutura está ilustrada na figura 7.




Figura 7. Estrutura do neurônio biológico
Fonte: sites.icmc.usp.br (2021)

Esta célula tem três seções distintas e inter-relacionadas: 1 componente que recebe os impulsos nervosos, constituída pelos dendritos; 2 o corpo da célula que recebe os impulsos através dos dendritos e transforma-os em outro tipo de impulso nervoso; e 3 o axônio que transmite o impulso gerado pelo corpo da célula para outros neurônios. A conexão feita entre o axônio de um neurônio e o dendrito de outro neurônio é denominada “sinapse”. As sinapses formam as ligações entre os neurônios, compondo assim as redes neurais. Fausett (1994) exemplifica as sinapses ao funcionamento das válvulas, sendo capazes de controlar a transmissão de impulsos (fluxo de informação) entre os neurônios na rede neural, isto porque o efeito das sinapses é variável e esta variação implementa a capacidade de adaptação ao neurônio.

Ciente que as estruturas do neurônio biológico e a RNA são semelhantes, ver figura 8, o artificial (computacional) é conhecido por nodos onde os dendritos se formam pelas entradas (x_1, x_2, \dots, x_n), são combinadas com os pesos (w_1, w_2, \dots, w_n) e responsáveis pelo reforço ou atenuação do estímulo. O corpo do nodo é o local onde os estímulos são somados (Σ) e, caso, atinjam um valor pré-estabelecido pela função limiar (Θ), produzirão uma saída, conforme Fausett (1994) e apresentada na figura 8.

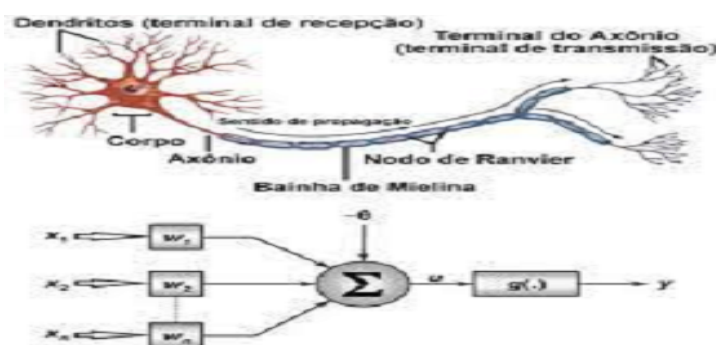


Figura 8. Analogia do neurônio biológico e o artificial
Fonte: utfpr.edu.br (2021)

Os neurônios, analogamente ao que ocorre no cérebro, são interconectados, formando a rede neural artificial, conforme a figura 9. Assim, é possível criar estruturas para generalização de padrões através de variadas entradas, produzindo uma ou mais saídas que poderão

representar uma ação ou objeto do mundo real (padrão) como resposta aos diferentes dados apresentados na entrada. A fase de aprendizado – normalmente descrita como “treinamento da rede” – trata do ajuste adequado dos pesos, possibilitando a retenção das características de padrões conhecidos e, inclusive, o emprego da rede na generalização/classificação de novos padrões.




Figura 9. Interconexão do neurônio artificial
Fonte: docs.ufpr.br (2021)

3 RESULTADOS E DISCUSSÃO

Em relação ao subtópico 2.1, Giuffra (2017) defendeu a sua tese pela técnica da IA utilizando agentes inteligentes no curso “Cálculo Básico” e configurou o MOODLE da IES, a Universidade Federal de Santa Catarina (UFSC), com dois “Módulos” e dois outros tópicos, um de “Fundamentos” e “Suplementos”, conforme figura 10.

Módulo 1	Operações fundamentais	Fundamentos	Fundamentos da trigonometria
	Números reais		Identidades trigonométricas
	Relações numéricas		Matrizes (nomenclatura)
	Potências e raízes		Operações com matrizes
	Logaritmos		Limites Fundamentais
	Números complexos		Aterros calculo numérico
	Progressões e séries		Mais sobre números
	Binômio e produtos notáveis		Séries especiais
	Polinômios		Triângulo de Pascal e coeficientes binomiais
Módulo 2	Notações para resposta	Suplementos	Derivadas e a física
	Funções		Formulário de derivadas
	Limites		Funções primitivas e integrais
	Propriedades dos limites		
	Continuidade		
	Derivadas (I)		
	Derivadas (II)		
	Diferencial		
	Representação do diferencial		
Funções primitivas e integrais			

Figura 10. Conteúdos do curso “Cálculo Básico” incluídos no MOODLE da UFSC
Fonte: Giuffra (2017)

Os conteúdos ministrados foram incluídos na plataforma MOODLE, respeitando os perfis diferentes dos estudantes para considerar o desempenho individual e a evolução em três níveis de aprendizado (fácil, médio e difícil), além do nível geral quando a atividade tiver que ser disponibilizada aos estudantes por igual (por serem considerados muito relevantes pelos professores do curso ou, ainda, por ser um conteúdo que não ofereça muita opção de divisão por níveis de dificuldade), ver Figura 11.



Figura 11. Captura de tela na plataforma *MOODLE* da UFSC
Fonte: Giuffra (2017)

Um estudante fictício resolveu o conteúdo de “Funções” do Módulo 1, e obteve 44 como nota para análise, que o colocou no perfil 1-Básico. No tópico seguinte, sobre “Limites”, ele tirou uma nota maior, que o inseriu no perfil 2-Médio ao próximo tópico, sobre “Continuidade”. O discente não conseguiu tirar uma nota maior que 2,5 na primeira tentativa neste conteúdo e assim, o “Agente 1” apresentou-lhe o tópico de reforço, não obrigatório, sobre “Potências e raízes”, abrindo-o a ele, novamente, o questionário ao conteúdo “Continuidade”.

Na segunda oportunidade, o estudante ainda não obteve uma nota maior que 2.5. Diante desta situação, o “Agente 1”, sugere ao aluno fazer o tópico adicional que fora disponibilizado, inicialmente. Na terceira tentativa, mesmo que o estudante tenha realizado a lista ao tópico de reforço, ele não conseguiu a nota mínima para avançar ao conteúdo obrigatório. O “Agente 1”, disponibilizou um questionário ao tópico de “Continuidade”, todavia de nível 1-Básico, pois no nível 2-Médio o discente apresentou dificuldades para evoluir, presente na Figura 12.

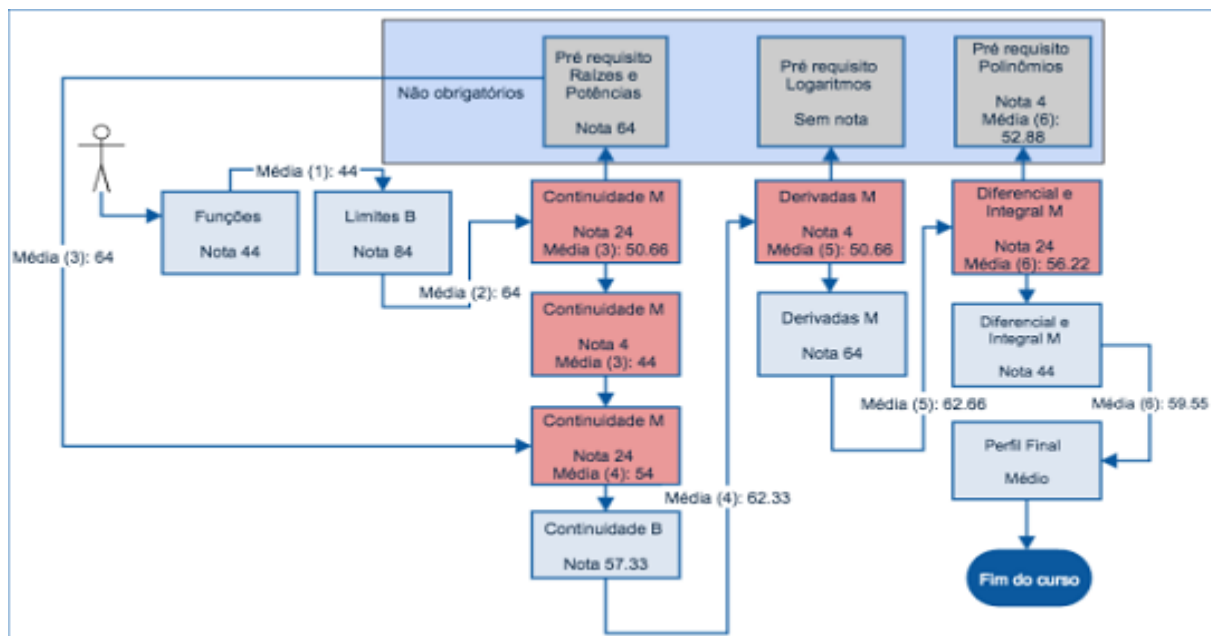


Figura 12. Fluxo de conteúdo “etapa pré-teste” ao aluno fictício no MOODLE da UFSC
Fonte: Giuffra (2017)

Pela nota obtida em “Continuidade” nível 1-Básico, o estudante consegue avançar ao tópico de “Derivadas”, todavia no perfil médio. O cálculo da média do estudante, em função de responder uma atividade de reforço, conquistou uma nota adicional de 64 que fora obtida no conteúdo pré-requisito sobre “Potências e raízes” e, fazendo que a média dele seja 62,33 ao

invés de 61,77.

E assim, este estudante continua os demais conteúdos até finalizar esta primeira fase denominada por Giuffra (2017) de “pré-teste”, isto porque suas respostas nos questionários, em alguns momentos, foram selecionadas de forma aleatória com a finalidade obter notas diferentes e verificar possíveis respostas, sem levar em conta o conhecimento dos conteúdos ministrados na disciplina em si. Por meio destas análises preliminares, formalizou-se um convite a outros estudantes, para testarem o sistema, pela participação em um curso de extensão em “Cálculo Básico”, formalmente oferecido pela UFSC por 3 meses, num total de 20 horas aulas, sendo denominado de “Etapa de testes” ou segunda fase.

Nesta outra fase, as configurações aos “Agentes 1 e 2” foram ajustadas com referência ao “pré-teste”, sendo ratificada a flexibilidade do professor inserir as características da técnica da IA pelo agentes inteligentes no seu espaço de ensino. Mesmo com os resultados, ainda que preliminares, estes acompanharam a tendência de pesquisas já realizadas com STI, que segundo Vanlehn (2011) se mostram mais eficientes e efetivos nos resultados dos estudantes, em comparação a sistemas tradicionais, e com alguns desses sistemas sendo tão efetivos quanto tutores humanos.

Após alguns conteúdos realizados por um outro estudante, também fictício, que fora avançado nos tópicos para esta outra fase, a “Etapa de testes”, seus resultados preliminares estão sinalizados na Figura 13.

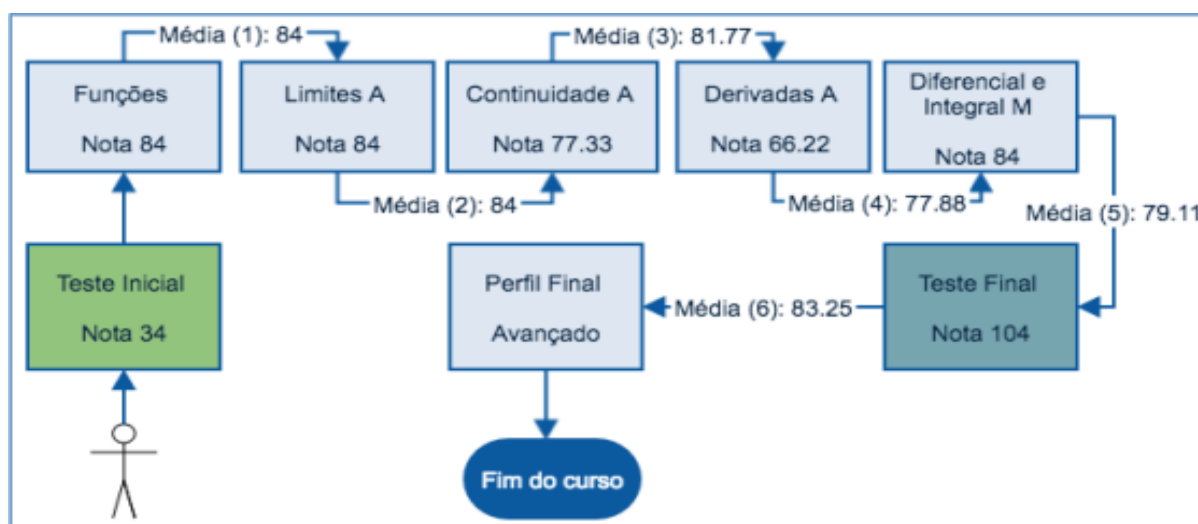


Figura 13. Fluxo de conteúdo “etapa de testes” ao aluno fictício no MOODLE da UFSC
Fonte: Giuffra (2017)

Quanto ao subtópico 2.2, entre os agentes sinalizados a serem incluídos no MOODLE, implementaram o Agente de Perfil (AP) cuja funcionalidade é a detecção do perfil dos estudantes nesta plataforma da UAB/PI. Isto porque o tempo do projeto priorizava identificar estes perfis nas Bases de Dados (BD) do MOODLE (fóruns, chats, tarefas, atividades [lista de exercícios], notas etc.) utilizando os algoritmos k-means e o J48, criaram os agrupamentos destas BD em similaridades, conforme a participação de cada estudante por meio do registro de log (rastreamento de suas ações).

O fluxo deste processo para o Agente Perfil, inicia pela interação do estudante o qual tem suas ações rastreadas na plataforma MOODLE, conforme a Figura 14, sendo que estes novos dados resultantes são armazenados em uma nova BD, em destaque na Figura 15.

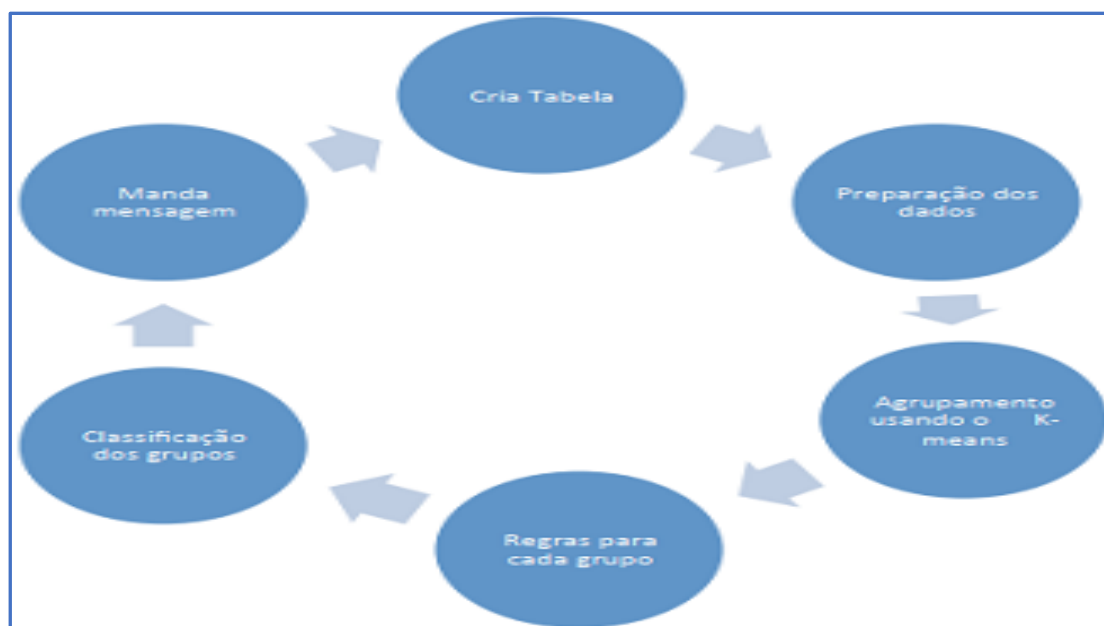


Figura 14. Fluxo a ação do Agente Perfil (*MOODLE* da UABPI)
 Fonte: Silva, Machado & Araujo (2014)

usu...	chat	upload	blog	course	forum	library	message	wiki	discussion
4597	0	18	2	481	2473	1804	1	0	1
4600	0	17	23	2002	986	102	13	0	13
4601	0	14	3	632	2576	1750	8	0	1
4607	9	10	3	341	419	50	3	1	1
4608	4	19	1	372	1247	570	0	0	1
4609	37	21	0	673	977	66	4	7	1
4610	3	17	1	406	738	310	5	4	0
4611	4	16	3	334	470	54	19	3	2
4613	19	13	1	671	731	92	7	21	0
4614	10	1	0	110	112	65	5	3	0
4615	85	0	9	654	355	48	29	11	0
4616	111	17	13	1506	1966	1167	45	2	1
4618	7	3	3	372	159	49	1	1	0
4619	28	15	17	760	612	52	7	28	1
4620	25	1	1	520	1545	944	4	15	0
4623	18	1	1	251	111	49	13	1	0
4624	29	9	1	573	1315	13	2	1	0
4627	1	1	2	121	221	52	11	3	0
4628	12	9	0	561	378	51	1	4	0
4629	22	38	0	594	705	54	15	12	2
4630	62	30	4	2163	3019	51	8	22	1

Figura 15. Tabela BD (*MOODLE* da UABPI) as interações de alunos
 Fonte: Silva, Machado & Araujo (2014)

Em seguida, entra a fase da preparação dos dados, a seleção dos atributos que serão utilizados na classificação dos grupos onde cada atributo é discretizado de 1 até quatro faixas de valor, obtendo a diferença da maior até a menor quantidade desta participação ao atributo e dividindo pelo número máximo da faixa (4) com a finalidade de ter o valor base ao cálculo do valor de cada faixa.

A última etapa deste fluxo compreende o processamento dos algoritmos, iniciando pelo K-means que classifica os alunos da turma pela sua participação em cada atributo identificado e continua este processo com o outro algoritmo, o J48, a fim realizar a identificação das regras usadas na classificação dos estudantes aos seus respectivos grupos. O resultado destes agrupamentos envolve os conceitos ruim, regular, bom e ótimo e finaliza o ciclo com um envio de mensagem aos alunos e tutores cuja responsabilidade passa a ser do Agente de Desempenho.

Para este fluxo, foram rastreados os estudantes da modalidade EaD na UAB/PI do curso de Graduação em Administração Pública, totalizando 2.210 registros ao ano de 2011. Aqueles atributos que tiveram a melhor performance resultante, foram considerados como contribuições efetivas de cada aluno, por unidade curricular nas ferramentas de interação do MOODLE, conforme a nova tabela sinalizada na Figura 15.

O agrupamento deste processamento obteve os quatros grupos – ruim, regular, bom e ótimo – pela participação deles na plataforma MOODLE, evidenciados na Tabela 3 e as regras identificadas pelo algoritmo J48 foram:

1. Se a participação no atributo *course* está na faixa 1 (0 a 5508) e participação no *wiki* está na faixa 1 (0 a 107) e participação no chat está na faixa 1 (0 a 404) então o usuário pertence ao grupo ruim;
2. Se a participação no atributo *course* está na faixa 2 (5509 a 11016) então o usuário pertence ao grupo regular;
3. Se a participação no atributo *course* está na faixa 1 (0 a 5508) e participação no *wiki* está na faixa 1 (0 a 107) e participação no chat está na faixa 2 (405 a 808) então o usuário pertence ao grupo bom;
4. Se a participação no atributo *course* está na faixa 1 (0 a 5508) e participação no *wiki* está na faixa 2 (108 a 214) então o usuário pertence ao grupo ótimo.

Tabela 3. Características do agrupamento obtido

G1: Ruim	G2: Regular	G3: Bom	G4: Ótimo
<i>course</i> = 1	<i>course</i> = 2	<i>course</i> = 1	<i>course</i> = 1
<i>wiki</i> = 1		<i>wiki</i> = 1	<i>wiki</i> = 1
<i>chat</i> = 1		<i>chat</i> = 2	

Fonte: Silva, Machado & Araujo (2014)

Após a execução do algoritmo, esta classificação resultante agregará em subsídios para que o Agente de Desempenho (AD) possa, de acordo com a deficiência detectada pelas regras, por meio destes atributos, incentivar as participações na plataforma. Uma opção dessas ações poderia ser, enviar mensagem a todos os alunos pertencentes ao grupo que tiver pouca participação em vários atributos, de forma a inferir suas ações nestas ferramentas de interação, *course*, *wiki* e principalmente, o chat.

O último trabalho abordado, o subtópico 2.3, aos estilos de aprendizagem em EaD com IA pela RNA, compreende um projeto de STI, todavia sem a sua implementação na plataforma MOODLE. Visando facilitar a sua estrutura, algumas das etapas necessárias a futura aplicação, estão presentes na Figura 16.




Figura 16. Etapas de um projeto com base em RNA

Fonte: Martins, Meireles, Melo e Nalini (2003)

A coleta dos dados obtém as informações que serão processadas às fases treinamento e validação. Na etapa do pré e do pós-processamento dos dados, acontecem a formatação dos

dados por meio do padrão tradicional ao utilizado pela RNA e vice-versa. Projetar a estrutura da rede compreende definir detalhes da RNA.

No treinamento, uma amostra representativa da população que se pretende classificar, é utilizada como “aprendizagem”. Quanto mais assertiva na representação for esta amostra, melhor será a capacidade de resposta da rede em identificar estes novos padrões. Após o treinamento, avalia-se a rede com outro tipo de amostra, denominada “conjunto de validação”, extraída da mesma população do conjunto de treinamento. A partir dela, é verificado se o índice de resposta da rede é pertinente aos padrões apresentados. Se estiver dentro de parâmetros esperados (pré-estabelecidos), a rede estará pronta a sua utilização.

Após treinadas e validadas, as RNA's são utilizadas em tarefas de classificação, otimização ou auto-organização, dependendo da natureza do problema a ser tratado. Este ato de classificar um dado individual é a forma de associar esse dado a uma classe de padrões já conhecida pela rede. Esta fase de associação, faz o reconhecimento do dado individual com base em aspectos deste ou de outros dados individuais. A tarefa de otimização, procura encontrar soluções ótimas, atendendo a um conjunto de restrições e, finalmente, a auto-organização direciona a rede a uma melhor forma de organizar os dados individuais, adaptando-se a detecção especializada de cada dado no futuro, expressado em Fu (1994).

Importante sinalizar que projeto proposto tem o cerne de usar apenas uma rede em toda a navegabilidade, isto porque a RNA passa a definir os padrões por meio da distribuição de probabilidades da navegação, pelos níveis identificados aos estilos de aprendizagem e uma adaptação ao inserir questionários específicos em navegações livres que continua a estabelecer o treinamento da RNA. Assim, os estilos de aprendizagem coletados a partir de aplicação web, por meio de questionários específicos, além do desempenho inicial do teste, como também as respostas do aprendiz ao questionário, são entradas da RNA que ficam comprometidas em fornecer o padrão de navegação guiada. A representação destas entradas será predominantemente binária, considerando todo o conjunto de respostas às questões, cuja tabulação é definida na estrutura do questionário. Neste contexto, a rede neural acessa estilos de aprendizagem do indivíduo e seu nível de conhecimento no conteúdo específico do tutorial.

Os padrões desta navegabilidade que foram coletados e selecionados na navegação livre, serão utilizados ao treinamento e validação da RNA. A análise do desempenho da navegação definirá os padrões que a rede deverá reconhecer para, a partir das informações da entrada, indicar o padrão de navegabilidade ao aprendiz. Uma complementação a decisão da navegação guiada, no sentido de exercer controle mais preciso e sensível ao desempenho local do estudante, em destaque na Figura 17, onde Kaplan e Rock(1995) estabelecem um conjunto de regras probabilísticas que é adicionado para lidar com situações óbvias. Exemplificando, não se deve permitir a navegação para o nível avançado quando o aprendiz não respondeu corretamente ao teste específico do nível facilitado.



Figura 17. Etapas de um projeto com base em RNA

Fonte: Martins, Meireles, Melo e Nalini (2003)

Na busca de uma melhor eficácia, o sistema proposto reduz a utilização de várias RNA's a uma única, sendo que esta é mais genérica. Esta nova estrutura, após sua validação, não causará demanda de novos treinamentos com a alteração do contexto atual ou, até mesmo, do conteúdo.

4 CONCLUSÃO

Esse artigo apresentou duas aplicações e um projeto de IA por meio de agentes inteligentes como fator agregado em STI na plataforma MOODLE que são pertinentes a EaD.

O primeiro trabalho aborda este tema por meio do aspecto cognitivo prévio do estudante onde se implementou um sistema que fora validado e integrado ao ambiente virtual de aprendizagem de uma IES, a UFSC, com o intuito de observar a evolução do perfil do estudante e os resultados obtidos nestas duas fases de testes. Ambos foram considerados satisfatórios, isto porque as considerações foram levantadas, tendo como meta a proposta de um modelo de disseminação do conhecimento compatível com uma arquitetura de ambiente virtual flexível, permitindo assim a disseminação do conhecimento. Segundo Giuffra (2017) para se atingir os objetivos, geral e específicos, foram delineados pela análise da forma de avaliação em conjunto aos modelos propostos e referentes ao processo de uma plataforma flexível, com um grupo de participantes em um determinado curso na modalidade EaD. Aplicaram-se os agentes inteligentes em uma turma de “Cálculo Básico”, cujos conteúdos inicialmente ministrados foram criados ao “pré-teste”. Estes conteúdos foram revisados, ajustados por meio de configuração nestes agentes para que tivessem uma diversidade maior, possibilitando uma evolução deste no ambiente com a finalidade de realizar a avaliação das informações nas interações discente. Em trabalhos futuros, pretende-se efetuar um outro “Pré-teste” ou prova de dispensa para não precisar passar por todos os conteúdos, como também melhorias nas funções dos agentes e seus paradigmas e, finalmente, analisar a possibilidade de adaptar este modelo em outra plataforma AVA, aos cursos MOOCs, permitindo corroborar com o processo desses cursos livres na consolidação flexível de ensino e de aprendizagem.

O segundo, tem no seu destaque o STI por meio da técnica Machine Learning, o aprendizado de máquinas, que ocorre pelo uso da Mineração de Dados (MD) ao aplicar dois de seus algoritmos, o k-means e o J48. O agente de perfil foi aplicado em cursos da UAB/PI e, ao usar ambos os algoritmos, classificou os estudantes com base em suas ações utilizando-se da rastreabilidade, classificação esta que inferiu um total de 2.210 registros obtidos no ano de 2011 ao curso de Graduação em Administração Pública. Com este resultado obtido, os subsídios agregados e que futuramente complementarão o projeto, tanto o agente de desempenho quanto o comunicador, trarão um melhor acompanhamento do estudante e uma melhor interação no incentivo da sua participação mais efetiva. Isto ocorrerá por meio da identificação do nível de ensino e da aprendizagem específica de cada aluno, transformando em uma solução viável e ideal cuja objeto principal é filtrar a deficiência detectada pelas regras, gerando uma maior interação de ações nesta plataforma.

O último e, por se tratar de um projeto não implementado, contempla os fundamentos ao desenvolvimento de sistemas de STI conexionistas cujo objetivo é implementar o ensino por meio da utilização de estilos de aprendizagem. Mesmo sem ter a implementação efetiva na plataforma MOODLE, nota-se que a RNA obtém benefícios que agregam o uso de preferências da aprendizagem e permitem aproveitar a estrutura do STI, sem exigir novos treinamentos. Isto porque reduz o número de redes neurais envolvidas a somente uma única. Outro termo que merece atenção é o fator da navegabilidade livre, visto que ela direciona os resultados obtidos pela RNA, em conformidade às regras probabilísticas pré-estabelecidas, sendo totalmente parametrizadas.

Ressaltamos que os trabalhos analisados se consolidam em fundamentações teóricas e científicas, tanto na educação quanto na tecnologia por meio da IA. Independente da sua aplicabilidade na plataforma MOODLE ter se efetivado – seja de forma completa, parcial ou

não existir – identifica-se melhorias cuja eficácia podem proporcionar ao ensino em cursos ministrados na modalidade EaD, de forma a personalizar o conteúdo e, principalmente, respeitando o estudante. Fator este que é essencial nesta categoria de ensino visto que a ausência física do professor pode ser mitigada por estas ferramentas educacionais.

REFERÊNCIAS

AGÊNCIA BRASIL. (2022). Disponível em: [https://agenciabrasil.ebc.com.br/educacao/noticia/2022-02/censo-matriculas-em-cursos-superiores-de-ead-superam-presenciais#:~:text=Segundo%20o%20Inep%2C%20esse%20fen%C3%B4meno,%2C6%25\)%2C%20pelos%20presenciais](https://agenciabrasil.ebc.com.br/educacao/noticia/2022-02/censo-matriculas-em-cursos-superiores-de-ead-superam-presenciais#:~:text=Segundo%20o%20Inep%2C%20esse%20fen%C3%B4meno,%2C6%25)%2C%20pelos%20presenciais).

ARAÚJO, A. C. M.; GOUVEIA, L. B. (2002). Avaliação do rendimento escolar: como ferramenta de exclusão social. Disponível em:

<https://www.brazilianjournals.com/index.php/BRJD/article/view/21576>.

BRENER Walter, ZARNEKOW Rüdiger, WITTIG Hartmut. (1998). Intelligent Software Agents – Foundations and Applications. Springer-Verlag Berlin Heidelberg.

FAUSETT, L. V. (1994). Fundamentals of neural networks. Prentice Hall.

FORUZAN, K. Rouhollah, MOHAMMAD, D. B. S. MEHDI. (2013). Improving the methods of email classification based on words ontology. International Journal of Computer Science Issues.

FU, L. M. (1994). Neural networks in computer intelligence. McGraw-Hill.

GIUFFRÀ PALOMINO, Cecília Estela. (2017). Aplicação de um modelo adaptativo de tutores inteligentes para disseminação do conhecimento em ambientes virtuais de ensino aprendizagem. Florianópolis. UFSC.

HAYKIN, S. S. (2000). Redes neurais artificiais: princípio e prática. São Paulo, SP : Bookman.

KAPLAN, Randy; ROCK, Denny. (1995). New Directions for Intelligent Tutoring Systems. AI Expert.

KOLB, D. A. (1984). Experiential Learning Experience as The Source of Learning and Development. Prentice-Hall, Englewood Cliffs.

MEC. (2018). Disponível em: <http://portal.mec.gov.br/docman/setembro-2018-pdf/97041-apresentacao-o-censo-superior-u-ltimo/file2>.

MITCHELL, T. M. (1997). “Machine learning”.

MOODLE. (2022). Disponível em: https://moodle.org/?lang=pt_br.

MORAN, José Manuel. (2020). Transformações na Educação impulsionadas pela crise.. Disponível em: <http://www2.eca.usp.br/moran/?p=1070>.

SANTOS, C. T.; FROZZA, R.; DAHMER, A.; GASPARY, L. P. Dóris (2001). Um agente de acompanhamento pedagógico em sistemas tutores inteligentes. In: SBIE'01 Simpósio Brasileiro de Informática na Educação. Vitória - ES. Anais.UFES.

SILVA, Samuel B. J.; MACHADO, Vinicius Ponte; ARAÚJO Francisco N. C. (2014). Sistema tutor inteligente baseado em agentes na Plataforma MOODLE para apoio as atividades pedagógicas da universidade aberta do Piauí. 3o Congresso Brasileiro de Informática na Educação (CBIE).

WOOLDRIDGE, M. J. (1997). Agent-based software engineering. IEE Proceedings on Software Engineering, v.144, n.1, p.26-37.

VANLEHN, K. (2011). The Relative Effectiveness of Human Tutoring, Intelligent Tutoring Systems, and Other Tutoring Systems. In: Educational Psychologist, 46:4, 197-221.

WEBER, Martns; MEIRELES, Viviane; MELO, Francisco Ramos; NALINI, Lauro Eugênio. (2003). Estilos de aprendizagem a distância. Universidade Federal de Goiás.