ISSN 2236-0158
Revista de Ensino de Engenharia

v. 45, 2026

MÉTODO REMBOT PARA O ENSINO REMOTO DE ROBÓTICA EDUCACIONAL COM APOIO DA INTELIGÊNCIA ARTIFICIAL NA PREVISÃO DA RETENÇÃO DE CONHECIMENTO

THE REMBOT METHOD FOR REMOTE TEACHING OF EDUCATIONAL ROBOTICS WITH ARTIFICIAL INTELLIGENCE SUPPORT IN PREDICTING KNOWLEDGE RETENTION

Wollace S. Picanço[1], Iury V. Bessa[2],
Renan L. P. Medeiros[3], Vicente F. Lucena Jr.[4]

DOI: 10.37702/REE2236-0158.v45p739-752.2026

RESUMO: Este artigo apresenta e avalia o método RemBot para o ensino remoto de robótica educacional, fundamentado na teoria sociocultural de Lev Vygotsky e apoiado pela Inteligência Artificial para a estimativa da retenção de conhecimento. A metodologia adotou um delineamento experimental com 30 estudantes de Engenharia, distribuídos em três grupos: tradicional, digital e RemBot. Os participantes realizaram pré-teste, provas da Semana 1 e da Semana 2, pós-teste e teste de retenção após 30 dias, com pontuações de 0 a 100. O método organiza a aprendizagem em cubos de progressão nos níveis básico, hábil e autodidata, com atividades práticas em ambiente virtual. Na amostra estudada, o grupo RemBot apresentou retenção de 95,6%, em comparação com 85,3% no grupo digital e 77,3% no grupo tradicional. Adicionalmente, uma rede neural artificial foi utilizada para estimar a retenção a partir das pontuações do pré-teste, das avaliações da Semana 1, da Semana 2 e do pós-teste. Como a previsão utiliza informações acumuladas até o pós-teste, sua aplicação está voltada ao acompanhamento da consolidação do conhecimento e à realização de ações posteriores de reforço. Os resultados sugerem o potencial de aplicação do RemBot em contextos remotos ou híbridos, devendo ser interpretados à luz do tamanho reduzido da amostra.

PALAVRAS-CHAVE: Ensino de Engenharia; Robótica Educacional; ensino remoto; Inteligência Artificial.

ABSTRACT: This article presents and evaluates the RemBot method for remote teaching of educational robotics, grounded in Lev Vygotsky's sociocultural theory and supported by artificial intelligence for estimating knowledge retention. The methodology adopted an experimental design with 30 engineering students distributed into three groups: traditional, digital, and RemBot. Participants completed a pretest, Week 1 and Week 2 tests, a posttest, and a retention test after 30 days, with scores ranging from 0 to 100. The method organizes learning into basic, skilled, and self-directed progression cubes, with practical activities carried out in a virtual environment. In the investigated sample, the RemBot group achieved a retention rate of 95.6%, compared with 85.3% in the digital group and 77.3% in the traditional group. Additionally, an artificial neural network was used to estimate retention from pretest, Week 1, Week 2, and posttest scores. Because the prediction uses information accumulated up to the posttest, its application is directed toward monitoring knowledge consolidation and supporting subsequent reinforcement actions. The results suggest potential for applying RemBot in remote or hybrid contexts and should be interpreted considering the small sample size.

KEYWORDS: Engineering Education; Educational Robotics; remote learning; Artificial Intelligence.

[1] Doutorando em Engenharia Elétrica, Programa de Pós-Graduação em Engenharia Elétrica (PPGEE), Universidade Federal do Amazonas (UFAM) wllaceps@gmail.com
[2] Doutor em Engenharia Elétrica, Pós-Graduação em Engenharia Elétrica (PPGEE), Universidade Federal do Amazonas (UFAM), iurybessa@ufam.edu.br
[3] Doutor em Engenharia Elétrica, Pós-Graduação em Engenharia Elétrica (PPGEE), Universidade Federal do Amazonas (UFAM), renanlan-dau@ufam.edu.br
[4] Doutor em Engenharia Elétrica, Pós-Graduação em Engenharia Elétrica (PPGEE), Universidade Federal do Amazonas (UFAM), vicente@ufam.edu.br; Projeto Samsung UFAM para Educação e Pesquisa (SUPER)

INTRODUÇÃO

O processo de ensino-aprendizagem tem acompanhado a evolução da sociedade ao longo do tempo, sendo constantemente influenciado por fatores culturais, tecnológicos e econômicos. No contexto da Engenharia, essa evolução torna-se ainda mais crítica, uma vez que a formação de profissionais qualificados depende da integração entre fundamentos teóricos, competências práticas e resolução de problemas reais (Lopes e Espada, 2023; De Lucena Jr. *et al.*, 2007).

A pandemia de Covid-19 intensificou esse desafio ao interromper atividades presenciais e impulsionar a adoção do Ensino Remoto Emergencial (ERE). Embora essa modalidade tenha permitido a continuidade das atividades acadêmicas, sua implementação ocorreu, em muitos casos, sem planejamento metodológico adequado, especialmente em disciplinas que dependem de práticas laboratoriais e interação direta com equipamentos, como a robótica educacional (Daher, 2024; Townsend, 2024).

Nesse cenário, tornou-se necessário desenvolver metodologias capazes de articular mediação pedagógica, atividades práticas simuladas e acompanhamento sistemático da aprendizagem. A teoria sociocultural de Lev Vygotsky oferece uma base pertinente para essa finalidade, pois compreende a aprendizagem como um processo mediado socialmente, no qual o estudante avança com o apoio de sujeitos mais experientes e de recursos didáticos adequados (Vygotsky, 1978; Wertsch e Sohmer, 1995).

Entre os conceitos centrais dessa abordagem, destaca-se a Zona de Desenvolvimento Proximal, entendida como a distância entre aquilo que o estudante realiza de forma autônoma e aquilo que consegue realizar com auxílio de um mediador. Essa perspectiva permite estruturar o ensino de forma progressiva, considerando diferentes níveis de autonomia e complexidade das tarefas (Vygotsky, 1978; Karpov, 1995).

Além da fundamentação pedagógica, o uso de tecnologias digitais, ambientes virtuais, simulações e recursos de Inteligência Artificial tem ampliado as possibilidades de Ensino em Engenharia. Simuladores robóticos e plataformas computacionais podem apoiar a realização de práticas remotas, enquanto modelos preditivos podem auxiliar o professor na análise do desempenho discente e na estimativa da retenção do conhecimento após o processo formativo (Hu *et al.*, 2024; Wang e Cheng, 2024).

Diante desse contexto, este artigo apresenta e avalia o método RemBot, uma proposta para o ensino remoto de robótica educacional baseada na teoria

sociocultural de Vygotsky, organizada em cubos de progressão e apoiada por recursos tecnológicos. O estudo compara três abordagens de ensino – tradicional, digital e RemBot – e utiliza um modelo de rede neural artificial para estimar a retenção do conhecimento a partir do desempenho dos estudantes ao longo das avaliações.

REFERENCIAL TEÓRICO

A formação em Engenharia tem sido impactada por mudanças tecnológicas e demandas do mercado, exigindo o desenvolvimento de competências técnicas e habilidades como pensamento crítico, autonomia e resolução de problemas (Brasil, 2019). Nesse contexto, metodologias ativas têm sido adotadas para aumentar o engajamento discente e superar limitações do modelo tradicional (Seabra *et al*., 2023).

Entre as abordagens pedagógicas, destaca-se a teoria sociocultural de Lev Vygotsky, que compreende a aprendizagem como um processo mediado socialmente, no qual o desenvolvimento ocorre por meio da interação entre o indivíduo e o meio (Vygotsky, 1978). A Zona de Desenvolvimento Proximal orienta esse processo, ao definir a progressão entre o desempenho independente e aquele assistido, fundamentando estratégias de ensino baseadas em suporte gradual (Karpov, 1995).

Paralelamente, o uso de tecnologias digitais tem ampliado as possibilidades de Ensino em Engenharia, especialmente em contextos remotos. Simulações e ambientes virtuais permitem a realização de práticas com menor dependência de infraestrutura física, sendo particularmente relevantes em áreas como a robótica educacional (Hu *et al*., 2024).

Além disso, a Inteligência Artificial tem sido incorporada como ferramenta de apoio à análise do desempenho discente. Modelos de aprendizado de máquina possibilitam identificar padrões, prever resultados e apoiar decisões pedagógicas (Wang e Cheng, 2024). Nesse contexto, a integração entre mediação pedagógica, tecnologias digitais e Inteligência Artificial configura-se como uma estratégia promissora para o Ensino em Engenharia, fundamentando a proposta do método RemBot.

No ensino de robótica, ambientes virtuais de simulação podem ampliar as possibilidades de realização de atividades práticas e permitir a experimentação de conceitos relacionados à movimentação e à operação de sistemas robóticos em

contextos educacionais. Nesse sentido, plataformas de simulação de manipuladores têm sido utilizadas como recurso complementar ao ensino, possibilitando a visualização e a execução de tarefas robóticas em ambientes virtuais (Hu *et al*., 2024).

De forma complementar, recursos de Inteligência Artificial podem contribuir para o acompanhamento educacional por meio da análise de dados de desempenho dos estudantes. A utilização dessas tecnologias permite incorporar mecanismos computacionais de apoio à avaliação e ao acompanhamento da aprendizagem, ampliando as possibilidades de integração entre práticas educacionais digitais e a análise do desempenho discente (Wang e Cheng, 2024).

METODOLOGIA

Caracterização da pesquisa

A presente pesquisa caracteriza-se como aplicada, do tipo intervenção pedagógica, com delineamento experimental e abordagem quantitativa. O estudo tem como objetivo analisar a aplicação do método RemBot no ensino remoto de robótica educacional, considerando a evolução da aprendizagem, a retenção do conhecimento e a capacidade de previsão por meio de Inteligência Artificial.

Apresentação do método RemBot

O método RemBot é fundamentado na teoria sociocultural de Lev Vygotsky e organiza o processo de aprendizagem em três níveis progressivos: Cubo de Progressão Básico (CPB), Cubo de Progressão Hábil (CPH) e Cubo de Progressão Autodidata (CPA).

O CPB corresponde à identificação dos conhecimentos prévios e à execução de atividades introdutórias. O CPH envolve atividades de média complexidade, realizadas com mediação docente. O CPA representa a etapa de autonomia, na qual o estudante executa tarefas de forma independente, com vistas à consolidação do conhecimento.

Tabela 1 – Estrutura conceitual do método RemBot

Cubo de Progressão	Período de desenvolvimento de habilidades
1° CPB	1° Período – Compreensão: O estudante apresenta conhecimentos prévios, cabendo ao professor analisar o nível de habilidades e estruturar as tarefas em pré-requisitos. Nessa fase, erros e acertos geram informações para o processo de mediação. 2º Período – Consolidação: Resolução de tarefas de baixa complexidade.
2° CPH	1° Período – Compreensão: O estudante já adaptou suas habilidades e realiza tarefas de média complexidade, ainda necessitando de supervisão docente. 2º Período – Consolidação: Resolução de tarefas de média complexidade.
3° CPA	1° Período – Compreensão: O estudante atua de forma autônoma, executando tarefas independentemente. Cabe ao professor propor desafios. 2º Período – Consolidação: O estudante mantém autonomia na execução das atividades.

Fonte: elaborada pelos autores.

Planejamento pedagógico do método RemBot

O planejamento do método RemBot foi estruturado de forma progressiva, associando cada cubo de progressão a conteúdos e atividades específicas de robótica educacional. No CPB, abordam-se os fundamentos e a identificação de componentes. No CPH, são trabalhados conceitos relacionados à programação e aos sistemas de coordenadas. No CPA, são desenvolvidas atividades de programação e de operação autônoma em ambiente simulado. A organização curricular detalhada é apresentada na Tabela 2.

Tabela 2 – Organização curricular do método RemBot aplicada à robótica educacional

Cubo de Progressão	Estágio do estudante	Período	Estrutura curricular	Exemplo
1º CPB	O estudante apresenta conhecimentos prévios, cabendo ao professor analisar suas habilidades e estruturar as tarefas em pré-requisitos. Nessa etapa, erros e acertos orientam a mediação pedagógica.	Compreensão	Pré-requisito de conteúdo	Introdução à Robótica educacional
		Compreensão	Conteúdo	Componentes técnicos de um robô
		Consolidação	Atividade	Identificação dos componentes do robô.
2º CPH	O estudante já adaptou suas habilidades e executa tarefas de média complexidade, ainda necessitando de supervisão docente.	Compreensão	Pré-requisito de conteúdo	Álgebra linear aplicada à programação robótica.
		Compreensão	Conteúdo	Sistemas de coordenadas para robótica.
		Consolidação	Atividade	Planejamento e execução de movimentos articulares utilizando sistemas de coordenadas, relacionando os valores das juntas ao posicionamento do manipulador.
3º CPA	O estudante atua de forma autônoma, realizando tarefas de forma independente, cabendo ao professor propor desafios.	Compreensão	Pré-requisito de conteúdo	Fundamentos de programação e movimentação de sistemas robóticos.
		Compreensão	Conteúdo	Programação sequencial de movimentos e definição de trajetórias robóticas.
		Consolidação	Atividade	Desenvolvimento autônomo de uma sequência programada de movimentos articulares, integrando sistemas de coordenadas, posicionamento e execução ordenada de tarefas no ambiente virtual.

Fonte: elaborada pelos autores.

Recursos tecnológicos utilizados

A Figura 1 apresenta a arquitetura tecnológica utilizada para viabilizar o compartilhamento e a execução remota das atividades práticas no método RemBot, estabelecendo o fluxo de interação entre o professor, os estudantes e o ambiente de simulação. Como recurso de apoio às atividades práticas, foi utilizado o GearsBot, um ambiente virtual de simulação empregado para representar e executar situações de aprendizagem relacionadas aos fundamentos da robótica. A Figura 2 apresenta a interface do ambiente GearsBot utilizada pelos estudantes durante as atividades práticas, permitindo a visualização e a execução dos movimentos robóticos propostos ao longo das etapas de aprendizagem.

No contexto desta pesquisa, o GearsBot foi empregado como recurso didático de simulação, e não como substituto de plataformas industriais proprietárias ou de células robóticas reais. Sua utilização esteve associada à compreensão progressiva de componentes robóticos, sistemas de coordenadas, movimentos articulares e programação de movimentos, em consonância com a progressão pedagógica estabelecida pelos Cubos de Progressão. Dessa forma, o escopo educacional da formação está relacionado aos conceitos, procedimentos e competências de robótica abordados nas atividades, enquanto o ambiente virtual constitui o meio tecnológico utilizado para possibilitar experimentação, visualização e prática em contexto remoto.

Figura 1 – Arquitetura de compartilhamento e execução do simulador



Fonte: elaborada pelos autores.

Figura 2 – Ambiente virtual GearsBot utilizado como recurso didático nas atividades de fundamentos de robótica educacional

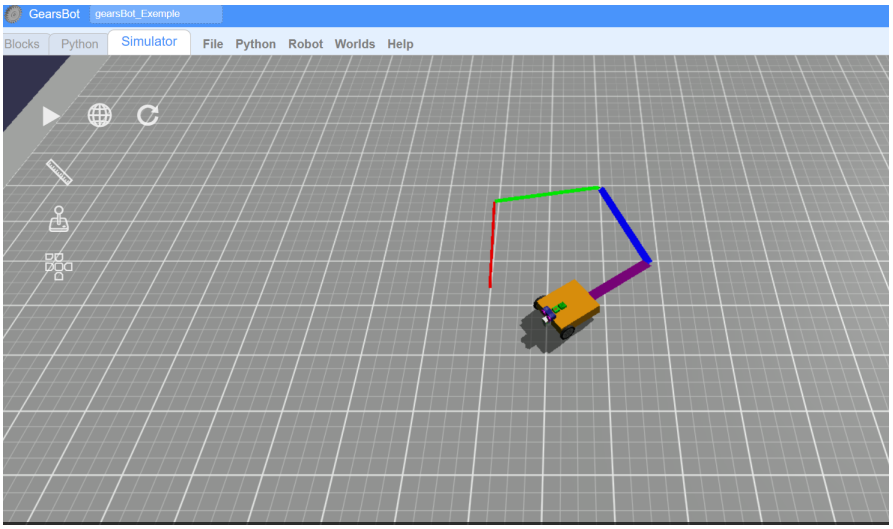

Fonte: elaborada pelos autores.

Aplicação experimental do método

A aplicação experimental foi realizada com 30 estudantes de graduação em Engenharia, distribuídos em três grupos de 10 participantes: Grupo A, submetido ao método tradicional presencial; Grupo B, submetido ao método digital convencional; e Grupo C, submetido ao método RemBot.

Considerando a dimensão da amostra, o delineamento experimental foi utilizado para analisar o comportamento do desempenho e da retenção de conhecimento no conjunto de participantes investigado, permitindo a comparação entre as três abordagens educacionais dentro desse contexto experimental.

Em razão do número reduzido de estudantes por grupo, os resultados são interpretados como evidências referentes à amostra analisada, não sendo utilizados isoladamente para estabelecer generalizações sobre a população de estudantes de Engenharia.

Além da limitação relacionada ao tamanho amostral, a interpretação dos resultados considera a possível influência de variáveis de confusão inerentes ao contexto educacional. Aspectos como nível de engajamento dos estudantes, familiaridade prévia com recursos computacionais, tempo individual dedicado ao estudo e o próprio efeito de novidade decorrente da utilização de uma metodologia distinta podem influenciar o desempenho observado.

Dessa forma, as diferenças identificadas entre os grupos não são interpretadas como efeito causal exclusivo do método RemBot, mas como resultados associados às condições experimentais investigadas. Essa precaução metodológica permite analisar os ganhos de aprendizagem e retenção observados na amostra sem atribuir exclusivamente à intervenção pedagógica fatores que também podem estar relacionados às características individuais dos participantes e ao contexto de aplicação.

Todos os grupos realizaram a mesma sequência de avaliações, composta por pré-teste, prova da Semana 1, prova da Semana 2, pós-teste e teste de retenção aplicado após 30 dias. As avaliações foram constituídas por questões de múltipla escolha, utilizadas para mensurar o desempenho dos estudantes nos diferentes momentos do processo formativo.

Em cada etapa, a pontuação obtida foi convertida para uma escala de 0 a 100 pontos. O pré-teste foi utilizado para identificar o nível inicial de conhecimento dos participantes; as provas da Semana 1 e da Semana 2 permitiram acompanhar a evolução do desempenho durante o processo de aprendizagem; o pós-teste avaliou o desempenho ao término da intervenção pedagógica; e o teste de retenção, realizado após 30 dias, permitiu verificar a permanência do conhecimento após o período de aprendizagem.

A aplicação do método RemBot ocorreu em três momentos pedagógicos conforme a Tabela 2. Inicialmente, foi aplicado o CPB, com foco na identificação dos conhecimentos prévios e na execução de atividades introdutórias. Em seguida, foram aplicadas as etapas CPH e CPA.

Modelo neural de previsão da retenção

Para estimar a retenção de conhecimento, foi utilizada uma Rede Neural Artificial do tipo *feedforward*, configurada como um modelo de regressão. A rede recebeu quatro variáveis de entrada correspondentes às pontuações obtidas no pré-teste, Semana 1, Semana 2 e pós-teste, sendo a variável de saída correspondente à pontuação estimada para o teste de retenção.

A arquitetura foi composta por uma camada de entrada com quatro neurônios, duas camadas ocultas contendo, respectivamente, 16 e 8 neurônios, e uma camada de saída com um neurônio, resultando na configuração 4–16–8–1. As camadas ocultas utilizaram a função de ativação ReLU, enquanto a camada de saída foi linear, adequada à previsão de uma variável contínua.

O treinamento foi realizado utilizando o erro quadrático médio (MSE), como função de perda, e o otimizador Adam, com taxa de aprendizagem inicial de 0,01. Foi definido um limite máximo de 5.000 épocas, associado a um mecanismo de *early stopping* com paciência de 50 épocas e variação mínima de melhoria de 10^{-5}. Durante o treinamento, o erro obtido no conjunto de validação foi monitorado e, quando não foi observada melhoria dentro do intervalo estabelecido, o treinamento foi interrompido e os pesos correspondentes ao menor erro de validação foram restaurados.

Os dados foram separados em 80% para treinamento e 20% para validação, utilizando semente aleatória 42 para permitir a reprodutibilidade do procedimento. A separação foi realizada antes da normalização dos dados. A média e o desvio-padrão das quatro variáveis de entrada foram calculados exclusivamente a partir do conjunto de treinamento e posteriormente aplicados ao conjunto de validação, evitando a utilização de informações estatísticas provenientes da validação durante o ajuste do modelo.

O modelo foi treinado previamente com uma base histórica composta por 350 registros históricos, contendo as pontuações de pré-teste, Semana 1, Semana 2, pós-teste e retenção. No processo de treinamento, as pontuações do pré-teste, Semana 1, Semana 2 e pós-teste foram utilizadas como variáveis de entrada, enquanto a pontuação de retenção correspondeu à variável-alvo do modelo. Posteriormente, a rede treinada foi aplicada à amostra experimental composta pelos 30 participantes.

Dessa forma, os dados dos participantes do experimento não foram utilizados para o ajuste dos pesos da rede, mantendo separadas as etapas de treinamento e de aplicação experimental do modelo.

O desempenho preditivo foi analisado pela comparação entre os valores estimados e os valores reais de retenção. Na presente análise, os resultados do modelo são utilizados como apoio à avaliação da retenção de conhecimento no conjunto investigado, sendo interpretados conjuntamente com as limitações metodológicas e amostrais do estudo.

RESULTADOS E DISCUSSÃO

A análise dos resultados foi realizada por meio da comparação entre três abordagens de ensino: tradicional, digital e RemBot, considerando desempenho acadêmico e retenção de conhecimento.

Observa-se que todos os grupos apresentaram evolução entre o pré-teste e o pós-teste, indicando aprendizagem ao longo do processo. No entanto, diferenças significativas foram identificadas na retenção do conhecimento.

O grupo tradicional apresentou média de 39,8 pontos no pré-teste, 67,0 no pós-teste e 51,8 no teste de retenção, resultando em taxa de retenção de 77,3%. O grupo digital apresentou médias de 41,5, 70,6 e 60,2 pontos, respectivamente, com retenção de 85,3%.

Já o grupo RemBot apresentou, na amostra investigada, médias de 42,1 pontos no pré-teste, 85,4 pontos no pós-teste e 81,6 pontos no teste de retenção, correspondendo a uma taxa de retenção de 95,6%, valor superior aos observados nos grupos digital e tradicional dentro das condições deste experimento.

A Figura 3 apresenta a comparação das curvas médias de aprendizagem dos três grupos, evidenciando maior crescimento do desempenho no grupo RemBot ao longo das etapas avaliativas e menor redução entre o pós-teste e o teste de retenção.

Em termos quantitativos, o ganho de aprendizagem observado entre o pré-teste e o pós-teste foi de 43,3 pontos no grupo RemBot, enquanto os grupos digital e tradicional apresentaram ganhos de 29,1 e 27,2 pontos, respectivamente. Esses resultados evidenciam diferenças de desempenho entre os grupos na amostra analisada, devendo ser interpretados considerando o tamanho reduzido dos grupos experimentais.

Figura 3 – Curva de aprendizagem

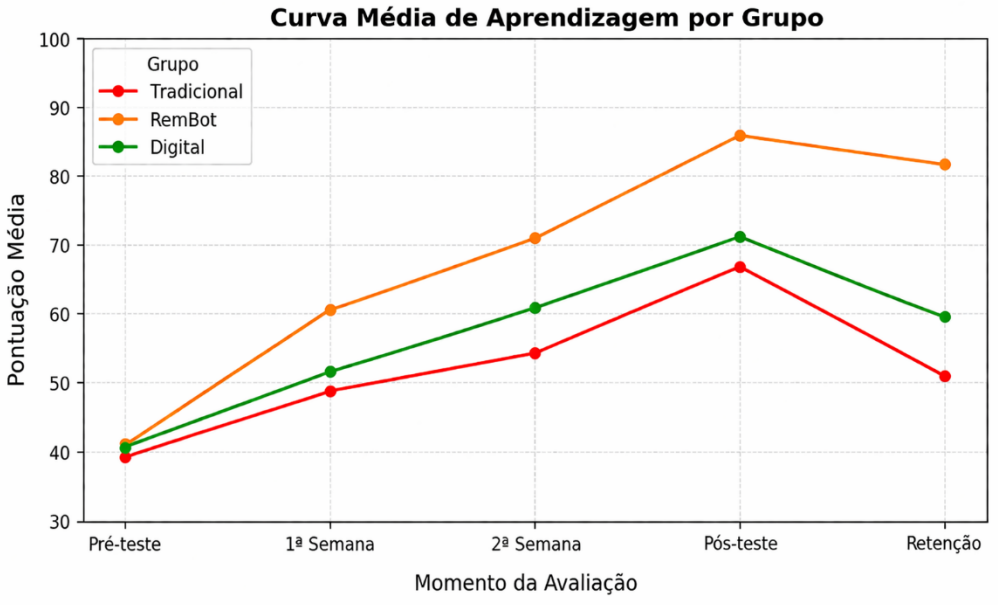

Fonte: elaborada pelos autores.

Para verificar a significância estatística das diferenças entre os grupos, foi inicialmente aplicado o teste de normalidade de Shapiro-Wilk, que indicou ausência de normalidade nos dados ($p < 0,05$). Dessa forma, foi utilizado o teste não paramétrico de Kruskal-Wallis (Kruskal e Wallis, 1952) para comparação global entre os três grupos. Posteriormente, o teste de Mann-Whitney (Mann e Whitney, 1947) foi aplicado em comparações pareadas, evidenciando diferença estatisticamente significativa entre o grupo RemBot e os demais métodos analisados ($p < 0,05$).

A Figura 4 apresenta a relação entre os valores reais de retenção e os valores estimados pelo modelo para os participantes analisados, permitindo visualizar a proximidade entre as previsões produzidas pela rede neural e os resultados observados.

Figura 4 – Relação entre os valores reais e estimados de retenção pelo modelo

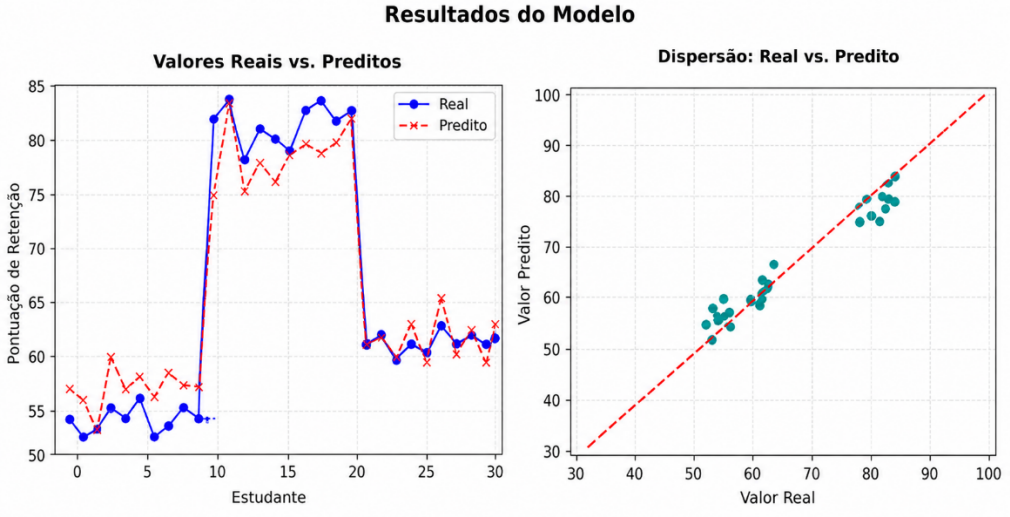

Fonte: elaborada pelos autores.

A comparação entre os valores reais e estimados permite analisar visualmente o comportamento preditivo do modelo na amostra experimental. Considerando as limitações associadas ao tamanho da amostra e ao procedimento de validação adotado, os resultados da previsão são interpretados como evidências referentes ao conjunto analisado, sem extrapolação direta de desempenho para outras populações estudantis.

Os resultados indicam que a Inteligência Artificial pode atuar como ferramenta complementar ao acompanhamento pedagógico, utilizando o desempenho acumulado até o pós-teste para estimar a retenção de conhecimento esperada após o período de 30 dias. Nesse contexto, a previsão não representa um

diagnóstico precoce realizado durante a disciplina, mas um recurso de apoio à análise da consolidação da aprendizagem e ao planejamento de ações posteriores de acompanhamento ou reforço educacional.

Do ponto de vista educacional, os resultados observados estão alinhados à proposta de organização progressiva do ensino fundamentada na teoria sociocultural de Vygotsky. Na amostra investigada, o grupo RemBot apresentou maiores valores de desempenho e retenção em comparação aos grupos tradicional e digital. Entretanto, considerando o tamanho reduzido da amostra, esses achados devem ser interpretados como evidências referentes às condições experimentais avaliadas, sem estabelecer generalização de superioridade do método para outras populações ou contextos educacionais.

CONCLUSÕES

Os resultados obtidos indicam que, na amostra experimental investigada, o grupo submetido ao método RemBot apresentou maiores valores de ganho de aprendizagem e retenção de conhecimento em comparação aos grupos tradicional presencial e digital convencional.

O desempenho médio do grupo RemBot passou de 42,1 pontos no pré-teste para 85,4 pontos no pós-teste e alcançou média de 81,6 pontos no teste de retenção realizado após 30 dias, correspondendo a uma taxa de retenção de 95,6%.

Esses resultados descrevem o comportamento observado nas condições do experimento e, considerando o número reduzido de participantes, não devem ser interpretados isoladamente como evidência de superioridade do método para outras populações ou contextos educacionais.

A organização do RemBot em Cubo de Progressão Básico, Cubo de Progressão Hábil e Cubo de Progressão Autodidata possibilitou estruturar as atividades de forma gradual, partindo da identificação dos conhecimentos prévios e de atividades introdutórias para tarefas que demandaram maior participação e autonomia do estudante.

Nesse contexto, os resultados observados são compatíveis com a proposta pedagógica fundamentada na teoria sociocultural de Vygotsky, na qual a mediação e a progressão das atividades acompanham o desenvolvimento das habilidades do estudante. O uso de atividades práticas em ambiente virtual atuou como recurso de apoio à execução desse processo em contexto remoto.

Além da análise do desempenho educacional, foi empregado um modelo de rede neural artificial para estimar a retenção de conhecimento a partir das pontuações obtidas no pré-teste, Semana 1, Semana 2 e pós-teste. O modelo foi utilizado como ferramenta complementar de análise do desempenho acadêmico, permitindo estimar a retenção esperada após o período de 30 dias.

Considerando que essa previsão utiliza informações acumuladas até o pós-teste, sua aplicação, na configuração avaliada neste estudo, está direcionada ao acompanhamento da consolidação do conhecimento e à identificação de estudantes que possam demandar ações posteriores de reforço ou acompanhamento educacional.

Em conjunto, os resultados sugerem que a integração entre a organização pedagógica proposta pelo método RemBot, as atividades práticas simuladas e a análise preditiva por Inteligência Artificial apresentam potencial para apoiar o ensino de robótica educacional em contextos remotos ou híbridos.

Entretanto, a interpretação dos achados deve considerar o tamanho reduzido da amostra experimental, composta por 30 estudantes distribuídos em três grupos de 10 participantes, bem como a possível influência de características individuais e das condições específicas de aplicação.

Como trabalhos futuros, recomenda-se ampliar o número de participantes, realizar novas aplicações do método em diferentes turmas e contextos educacionais e avaliar sua utilização em outras disciplinas de Engenharia, permitindo verificar a consistência dos resultados em amostras mais amplas e diversificadas.

REFERÊNCIAS

BRASIL. Ministério da Educação. Conselho Nacional de Educação. Câmara de Educação Superior. **Resolução nº 2, de 24 de abril de 2019**. Institui as Diretrizes Curriculares Nacionais do Curso de Graduação em Engenharia. *Diário Oficial da União*: seção 1, Brasília, DF, 2019.

DAHER, W. Schools' challenges in distance learning during emergency. **Education Sciences**, v. 14, n. 4, 2024.

DE LUCENA JR., V. F. *et al.* A Germany-Brazil experience report on teaching software engineering for electrical engineering undergraduate students. **Software Engineering Education Conference, Proceedings**, p. 69–76, 2006.

DE LUCENA JR., V. F. *et al.* Teaching software engineering for embedded systems: an experience report from the Manaus research and development pole. **Frontiers in Education Conference**, p. S4C3–S4C8, 2007.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep learning**. Cambridge: MIT Press, 2016.

HU, J. *et al.* Unity 3D-Based Six-Degree-of-Freedom Robotic Arm Virtual Simulation Teaching Platform. In: INTERNATIONAL CONFERENCE ON ROBOTICS, ARTIFICIAL INTELLIGENCE, AND INTELLIGENT CONTROL, 3., 2024. **Proceedings [...]**. p. 265–270, 2024.

KARPOV, Y. V. L. S. Vygotsky as the founder of a new approach to instruction. **School Psychology International**, v. 16, n. 2, p. 131–142, 1995.

KRUSKAL, W. H.; WALLIS, W. A. Use of ranks in one-criterion variance analysis. **Journal of the American Statistical Association**, v. 47, n. 260, p. 583–621, 1952.

LOPES, B. D.; ESPADA, S. D. A. **General didactics: an experience lived and built with higher education students**. USA, 2023.

MANN, H. B.; WHITNEY, D. R. On a test of whether one of two random variables is stochastically larger than the other. **Annals of Mathematical Statistics**, v. 18, n. 1, p. 50–60, 1947.

NAVEZ, E. L. M. *et al.* Virtual and augmented reality environment for remote training of wheelchairs users: social, mobile, and wearable technologies applied to rehabilitation. In: IEEE INTERNATIONAL CONFERENCE ON E-HEALTH NETWORKING, APPLICATIONS AND SERVICES, 18., 2016. **Proceedings [...]**. 2016.

RUSSELL, S.; NORVIG, P. **Artificial intelligence: a modern approach**. 4. ed. Hoboken: Pearson, 2021.

SANJARI, A.; MANOUCHEHRI, A. Interactive learning: unpacking the influence of computer simulations on students' mathematical modeling processes. **Education Sciences**, v. 14, n. 4, 2024.

SEABRA, A. D. *et al.* Metodologias ativas como instrumento de formação acadêmica e científica no ensino em ciências do movimento. **Educação e Pesquisa**, v. 49, 2023.

TOWNSEND, T. The challenge to change: leading schools beyond COVID-19. **Education Sciences**, v. 14, n. 10, 2024.

VYGOTSKY, L. S. **Mind in society: the development of higher psychological processes**. Cambridge: Harvard University Press, 1978.

VYGOTSKY, L. S. **Thought and language**. Cambridge: MIT Press, 1986.

WANG, K.; CHENG, M. Teaching feedback system based on ViT expression recognition in distance education. In: INTERNATIONAL CONFERENCE ON EDUCATIONAL AND INFORMATION TECHNOLOGY, 13., 2024. **Proceedings [...]**. p. 93–97, 2024.

WERTSCH, J. V.; SOHMER, R. Vygotsky on learning and development. **Human Development**, v. 38, n. 6, p. 332–337, 1995.