ISSN 1981-416X
https://doi.org/10.7213/1981-416X.26.090.DS03

CC BY

Dossiê

Revista Diálogo Educacional

PUCPRESS

periodicos.pucpr.br/dialogoeducacional

# Metacognição, feedback e inteligência artificial: uma matriz didático-pedagógica para a recalibração da aprendizagem

*Metacognition, Feedback, and Artificial Intelligence: A Didactic-Pedagogical Matrix for Learning Recalibration*

*Metacognición, retroalimentación e inteligencia artificial: una matriz didáctico-pedagógica para la recalibración del aprendizaje*

Rafael Castro de Souza [a]
Natal, RN, Brasil
Instituto Federal de Educação, Ciência e Tecnologia do Rio Grande do Norte (IFRN)

Diogo Pereira Bezerra [b]
Ipanguaçu, RN, Brasil
Instituto Federal de Educação, Ciência e Tecnologia do Rio Grande do Norte (IFRN)

Carla Katarina de Monteiro Marques [c]
Natal, RN, Brasil
Instituto Federal de Educação, Ciência e Tecnologia do Rio Grande do Norte (IFRN)

Como citar: de SOUZA, R.; BEZERRA, D. P.; MARQUES, C. K. de M. Metacognição, feedback e inteligência artificial: uma matriz didático-pedagógica para a recalibração da aprendizagem. *Revista Diálogo Educacional*, Curitiba, PUCPRESS, v. 26, n. 90, p. 1372-1396, jul./set. 2026. https://doi.org/10.7213/1981-416X.26.090.DS03

[a] Doutorando em Ensino pelo Programa de Pós-Graduação em Ensino da Rede Nordeste de Ensino (RENOEN), e-mail: rafael.castro@ifrn.edu.br
[b] Doutor em Engenharia Química pela Universidade Federal do Ceará, e-mail: diogo.bezerra@ifrn.edu.br
[c] Doutor do em Engenharia de Teleinformática pela Universidade Federal do Ceará (2010) e pós-doutorado na UdeM (Department of Computer Engineering pela University Polytechnique of Montreal), e-mail: carla.marques@ifrn.edu.br

## Resumo

Este artigo propõe uma matriz didático-metacognitiva para orientar o uso de tecnologias educacionais e inteligência artificial na transformação de evidências de discrepância entre autopercepção e desempenho em feedback pedagógico, reflexão discente e recalibração da aprendizagem. O estudo é teórico-propositivo, de natureza aplicada e finalidade exploratório-descritiva, articulando metacognição, avaliação diagnóstica, aprendizagem autorregulada, feedback e mediação docente. Como prova de conceito, utiliza-se um protótipo funcional do Modelo Assistido de Calibração Metacognitiva (Metacognitive Calibration Assisted Model — MCAM), que registra, item a item, julgamento prospectivo no pré-teste, desempenho objetivo no teste e confiança retrospectiva no pós-teste. A demonstração técnico-computacional, realizada com perfis simulados em cenário controlado, verifica a viabilidade de implementação e a coerência lógico-operacional do MCAM, incluindo recodificação, normalização independente, discrepância assinada, inferência fuzzy e visualizações analíticas. A matriz organiza-se em quatro movimentos: diagnosticar, oferecer feedback, refletir e recalibrar. Os resultados da demonstração mostram que a cadeia computacional é executável e interpretável, enquanto a decisão pedagógica permanece sob responsabilidade docente. Conclui-se que o MCAM pode apoiar a organização de evidências metacognitivas para práticas formativas, desde que articulado à mediação pedagógica e às condições sociotécnicas de uso.

**Palavras-chave**: Metacognição. Feedback pedagógico. Inteligência artificial. Avaliação diagnóstica. Autorregulação da aprendizagem.

## Abstract

*This article proposes a didactic-metacognitive matrix to guide the use of educational technologies and artificial intelligence in transforming evidence of discrepancies between self-perception and performance into pedagogical feedback, student reflection, and learning recalibration. The study is theoretical-propositional, applied in nature, and exploratory-descriptive in purpose, articulating metacognition, diagnostic assessment, self-regulated learning, feedback, and teacher mediation. As a proof of concept, it uses a functional prototype of the Metacognitive Calibration Assisted Model (MCAM), which records, item by item, prospective judgment in the pre-test, objective performance in the test, and retrospective confidence in the post-test. The technical-computational demonstration, conducted with simulated profiles in a controlled scenario, verifies the feasibility of implementation and the logical-operational coherence of the MCAM, including recoding, independent normalization, signed discrepancy, fuzzy inference, and analytical visualizations. The matrix is organized into four movements: diagnose, provide feedback, reflect, and recalibrate. The demonstration results show that the computational chain is executable and interpretable, while pedagogical decision-making remains under teacher responsibility. It is concluded that the MCAM can support the organization of metacognitive evidence for formative practices when articulated with pedagogical mediation and the sociotechnical conditions of use.*

***Keywords**: Metacognition. Pedagogical feedback. Artificial intelligence. Diagnostic assessment. Self-regulated learning.*

# 1. Introdução

A avaliação da aprendizagem tem sido historicamente associada à verificação do desempenho discente por meio de notas, acertos, erros, frequência, participação e outros indicadores observáveis. Embora esses elementos sejam relevantes para o acompanhamento escolar, eles não esgotam a complexidade do aprender. Dois estudantes podem obter resultados semelhantes em uma atividade avaliativa e, ainda assim, apresentar modos distintos de interpretar o próprio desempenho: um pode reconhecer suas dificuldades, outro pode superestimar sua compreensão; um pode demonstrar domínio e baixa confiança, outro pode apresentar baixo desempenho acompanhado de elevada autoconfiança.

Essa diferença entre desempenho demonstrado e autopercepção do estudante remete diretamente ao campo da metacognição. Para Flavell (1979), a metacognição envolve o conhecimento que o sujeito possui sobre seus próprios processos cognitivos, suas experiências metacognitivas, seus objetivos e as estratégias mobilizadas diante das tarefas. Nessa perspectiva, aprender não significa apenas apropriar-se de conteúdos, mas também desenvolver condições para monitorar, avaliar e regular o próprio processo de aprendizagem. Metcalfe (2009) destaca que julgamentos metacognitivos podem participar do controle das decisões de estudo, enquanto Persky, Lee e Schlesselman (2020), ao compararem percepção de aprendizagem e ganhos objetivos de conhecimento, mostram que essas medidas não são equivalentes. A autopercepção, portanto, constitui uma evidência relevante sobre o julgamento do estudante, mas não deve substituir a medida de desempenho demonstrado.

A relação entre aquilo que o estudante acredita saber e aquilo que efetivamente demonstra saber pode ser examinada como um problema de calibração metacognitiva. Maior calibração corresponde a maior proximidade entre julgamento e evidência de desempenho; o afastamento entre essas medidas pode assumir diferentes direções e intensidades, incluindo superestimação e subestimação. O efeito Dunning-Kruger constitui uma manifestação específica desse problema, associada, em determinados contextos, à maior superestimação entre participantes de menor desempenho (Kruger; Dunning, 1999; Pennycook *et al.*, 2017). Assim, neste artigo, o efeito Dunning-Kruger não é empregado como sinônimo de toda discrepância metacognitiva nem como diagnóstico fixo do estudante. A revisão de Mahmood (2016) reforça, em outro domínio, que julgamentos subjetivos e desempenho objetivo podem divergir de modo relevante.

No contexto educacional, a precisão desses julgamentos é pedagogicamente relevante porque pode influenciar decisões sobre estudo, revisão e busca por apoio. Dunlosky e Rawson (2012) demonstraram que erros de monitoramento, especialmente a superconfiança, podem prejudicar decisões de aprendizagem e retenção. Em um caminho oposto ao da superestimação, a subestimação também merece atenção, pois um desempenho adequado acompanhado de julgamento excessivamente negativo pode demandar mediações distintas daquelas requeridas por um baixo desempenho acompanhado de elevada confiança. A avaliação diagnóstica, portanto, ganha informação adicional quando considera, de modo conjunto, o que o estudante demonstra e como julga aquilo que sabe.

A literatura sobre o efeito Dunning-Kruger no ensino e aprendizagem indica que a mensuração da discrepância entre autopercepção e desempenho tem sido realizada, frequentemente, por meio da associação entre autoavaliações, testes objetivos e procedimentos estatísticos. Contudo, permanecem lacunas no desenvolvimento de tecnologias educacionais específicas capazes de apoiar não apenas o diagnóstico dessas discrepâncias, mas também sua conversão em *feedback*, reflexão e intervenção pedagógica (Souza *et al.*, 2025). Desse modo, o desafio não se limita a identificar a má calibração metacognitiva; é necessário compreender como transformá-la em oportunidade formativa.

As tecnologias educacionais e a inteligência artificial podem contribuir nesse processo quando utilizadas para organizar evidências, identificar padrões e apoiar devolutivas mais individualizadas. Entretanto, sua inserção na avaliação da aprendizagem não deve ser compreendida como substituição do professor. Pelo contrário, modelos assistidos por tecnologia precisam ser pensados como instrumentos de mediação, subordinados à intencionalidade didática e à interpretação pedagógica docente. Essa posição é coerente com Libâneo (2017), ao compreender o ensino

como trabalho intencional articulado por objetivos, métodos, conteúdos e avaliação, e com Freire (1996), ao defender que ensinar não é transferir conhecimento, mas criar condições para sua produção.

A discussão torna-se ainda mais pertinente diante do avanço da Inteligência Artificial (IA) em contextos educacionais. O debate contemporâneo sobre metacognição e aprendizagem exige práticas pedagógicas que superem tanto a transmissão mecânica de informações quanto a avaliação puramente classificatória. Nesse cenário, a IA pode ampliar as condições de acompanhamento, análise e devolutiva, desde que articulada à formação docente, à ergonomia cognitiva, à gestão educacional e à mediação pedagógica. O problema, portanto, não é apenas técnico, mas didático: como transformar evidências sobre discrepâncias entre autopercepção e desempenho em oportunidades de reflexão, *feedback* e autorregulação?

Dessa forma, o presente trabalho tem como objetivo geral propor uma matriz didático-metacognitiva para orientar o uso de tecnologias educacionais e inteligência artificial na transformação de evidências de discrepância entre autopercepção de conhecimento e desempenho real em *feedback* pedagógico, reflexão discente e recalibração da aprendizagem. Como elemento ilustrativo, considera-se a estrutura lógico-operacional de um protótipo funcional baseado em pré-teste, teste e pós-teste, capaz de organizar evidências situadas de superestimação, subestimação e maior correspondência entre julgamento e desempenho.

## 2. Metacognição, autopercepção e calibração da aprendizagem

A metacognição ocupa lugar estratégico nas discussões contemporâneas sobre aprendizagem por permitir compreender a relação entre conhecimento, consciência e regulação. Em Flavell (1979), o conceito envolve diferentes dimensões: o conhecimento metacognitivo, as experiências metacognitivas, os objetivos ou tarefas e as ações ou estratégias mobilizadas pelo sujeito. Essa formulação permite deslocar a aprendizagem de uma leitura centrada exclusivamente no resultado para uma compreensão mais ampla, na qual o estudante também precisa interpretar o próprio percurso cognitivo.

O conhecimento metacognitivo envolve crenças e julgamentos que o sujeito constrói sobre si mesmo, sobre as tarefas e sobre as estratégias disponíveis para enfrentá-las. Um estudante pode acreditar que domina determinado conteúdo, que determinada tarefa é simples ou que uma estratégia de estudo é suficiente, mesmo quando seu desempenho posterior não confirma essa percepção. Da mesma forma, pode considerar-se incapaz diante de uma tarefa, ainda que possua conhecimentos suficientes para realizá-la. Nesse sentido, a autopercepção constitui uma dimensão relevante da aprendizagem, mas não pode ser tomada isoladamente como evidência de competência.

Os julgamentos produzidos pelo estudante sobre o próprio conhecimento não se confundem com o conhecimento demonstrado. Metcalfe (2009) discute esses julgamentos como parte do monitoramento metacognitivo que pode orientar o controle do estudo. Persky, Lee e Schlesselman (2020) observaram baixa correspondência entre percepção de aprendizagem e ganhos objetivos de conhecimento, enquanto Finn e Tauber (2015) mostram que a confiança pode ser influenciada por pistas subjetivas que nem sempre sinalizam conhecimento efetivo. Essa distinção sustenta a necessidade de confrontar medidas subjetivas e objetivas em vez de utilizar uma delas como substituta da outra.

Na literatura de metamemória, *judgments of learning* (JOLs) são julgamentos prospectivos formulados durante ou após uma experiência de estudo para estimar desempenho futuro, especialmente a probabilidade de recordar uma informação (Koriat, 1997; Metcalfe, 2009). O pré-teste do MCAM é conceitualmente próximo desse campo por ser prospectivo e realizado item a item, mas não é tratado como um JOL clássico: sua pergunta focaliza a capacidade ou o domínio percebido diante da tarefa antes da resposta objetiva. O pós-teste, por sua vez, é retrospectivo e se aproxima de um julgamento de confiança sobre uma resposta já emitida. Essa distinção evita equivalência indevida entre medidas metacognitivas que possuem temporalidade e objeto de julgamento diferentes.

Nesse confronto, calibração não significa ausência absoluta de erro, mas o grau de correspondência entre o julgamento emitido e a evidência de desempenho no contexto de uma tarefa. A discrepância pode ser positiva, negativa ou próxima de zero e pode variar em magnitude. Essa caracterização permite tratar superestimação, subestimação e maior correspondência como estados relacionais situados, dependentes do conteúdo, da tarefa, do instrumento e do momento avaliativo, e não como traços permanentes do estudante.

Estudos sobre o efeito Dunning-Kruger constituem uma vertente específica dessa discussão. Kruger e Dunning (1999) observaram que participantes de menor desempenho podiam apresentar maior dificuldade para reconhecer a inadequação das próprias respostas. Pennycook *et al.* (2017) também encontraram padrões de superestimação associados ao desempenho em tarefas de raciocínio, ao mesmo tempo em que seus resultados evidenciam a variação dos julgamentos entre grupos de desempenho. Por essa razão, a calibração metacognitiva é adotada aqui como fenômeno mais amplo. O MCAM não pressupõe previamente a ocorrência do efeito Dunning-Kruger, mas representa relações de maior ou menor correspondência, direção e intensidade da discrepância.

Desse ponto de vista, a discrepância metacognitiva não deve ser reduzida a um marcador de deficiência individual. Ela deve ser compreendida como indício pedagógico, situado em uma relação entre tarefa, estudante, contexto, mediação e *feedback*. Um estudante pode apresentar superestimação em determinado conteúdo e calibração adequada em outro; pode subestimar seu desempenho em situações avaliativas de maior pressão; ou pode modificar sua autopercepção após receber devolutivas qualificadas. Por isso, a calibração deve ser entendida como processo dinâmico, e não como característica fixa do sujeito.

## 3. Feedback metacognitivo e mediação docente

A avaliação diagnóstica permite levantar informações sobre conhecimentos prévios, dificuldades, lacunas e necessidades de intervenção. Entretanto, quando limitada à mensuração de desempenho, ela pode indicar que o estudante teve baixo rendimento sem revelar se ele reconhece ou não essa dificuldade. Esse ponto é decisivo para a prática pedagógica. Um estudante que erra e sabe que errou demanda um tipo de intervenção; um estudante que erra e acredita ter domínio pleno do conteúdo demanda outro tipo de mediação.

Esomonu e Eleje (2020) discutem a avaliação diagnóstica como procedimento capaz de identificar dificuldades e orientar ações pedagógicas. Contudo, em uma perspectiva metacognitiva, o diagnóstico precisa incorporar também a autopercepção discente. Isso permite observar a relação entre o resultado obtido e o julgamento produzido pelo estudante sobre sua própria aprendizagem. Assim, a avaliação deixa de ser apenas verificação de desempenho e passa a produzir evidências sobre o modo como o estudante interpreta seu percurso formativo.

O *feedback* metacognitivo surge como etapa essencial dessa relação. Identificar discrepâncias entre autopercepção e desempenho não basta. Se o diagnóstico não for transformado em devolutiva compreensível e pedagogicamente orientada, corre o risco de permanecer como dado técnico. O *feedback* metacognitivo deve explicitar ao estudante a distância entre aquilo que ele acreditava saber, aquilo que demonstrou saber e aquilo que precisa reorganizar em suas estratégias de estudo.

Nesse sentido, o *feedback* não deve operar apenas como correção de erro. Ele deve funcionar como mediação para que o estudante compreenda seus critérios de julgamento, reconheça lacunas, revise estratégias e desenvolva maior consciência sobre seu processo de aprendizagem. Essa compreensão aproxima-se de Libâneo (2017), ao situar a avaliação no interior de uma prática pedagógica intencional, e de Luckesi (2011, p. 13–15), ao compreendê-la como fonte de informações que subsidiam decisões e o reencaminhamento da ação pedagógica.

A relação entre monitoramento, *feedback* e revisão do julgamento também se articula à aprendizagem autorregulada. A síntese de Panadero (2017) mostra que modelos de autorregulação integram processos de monitoramento, controle, avaliação e reflexão em ciclos recursivos. Nessa perspectiva, o *feedback* pode oferecer critérios externos para que o estudante confronte seu julgamento com evidências, mas não garante, por si só, a

recalibração. A revisão do julgamento depende da atividade do próprio estudante, das características da tarefa e das condições de mediação pedagógica. A contribuição das tecnologias educacionais e da inteligência artificial, nesse cenário, consiste em apoiar a organização de evidências e a identificação de padrões que podem subsidiar a ação docente. Todavia, o sentido pedagógico do *feedback* permanece dependente da mediação humana. Um sistema pode indicar que há discrepância entre autopercepção e desempenho; cabe ao professor interpretar esse dado, contextualizar a situação, considerar a trajetória do estudante e decidir quais intervenções são mais adequadas.

## 4. Tecnologias educacionais, inteligência artificial e condições sociotécnicas

As tecnologias digitais, a *learning analytics* e a IA ampliam as possibilidades de produzir, organizar e interpretar evidências educacionais, mas seu valor depende da articulação com modelos pedagógicos explícitos. Banihashem *et al.* (2025), em revisão sistemática de 93 estudos, mostram que resultados de *learning analytics* se tornam mais úteis para a avaliação formativa quando conectados a processos que esclarecem onde o estudante está, onde precisa chegar e como pode avançar. Em paralelo, a meta-revisão de Bond *et al.* (2024) indica que a pesquisa sobre IA no ensino superior requer atenção simultânea a rigor metodológico, ética e contexto de aplicação.

A formação docente constitui uma condição central dessa integração. Børte *et al.* (2023), ao sintetizarem estudos sobre uso de tecnologias em avaliação formativa, identificam três pré-requisitos: definição clara da finalidade formativa, alinhamento entre ferramenta digital e prática pedagógica e letramento em dados para interpretar informações e convertê-las em ações de melhoria da aprendizagem. Para o MCAM, essa evidência reforça que indicadores de calibração só adquirem sentido educacional quando o professor compreende o que representam e decide como utilizá-los.

A dimensão cognitiva também precisa ser considerada. Skulmowski e Xu (2022) mostram que ambientes digitais podem introduzir carga cognitiva extrínseca, mas ressaltam que os efeitos dos elementos tecnológicos devem ser analisados em relação aos objetivos de aprendizagem e aos benefícios pedagógicos que podem produzir. No MCAM, isso implica apresentar resultados de modo legível e economicamente informativo, evitando que a quantidade de indicadores, siglas ou visualizações se converta em sobrecarga para estudantes e docentes.

A adoção institucional de tecnologias analíticas envolve ainda governança, processos e diferentes atores. Márquez *et al.* (2024), em revisão sistemática sobre *learning analytics* no ensino superior, identificam fatores distribuídos por dimensões institucionais, pedagógicas, técnicas e éticas. Assim, a incorporação do MCAM não deve ser pensada apenas como instalação de um *software*, mas como integração de evidências a rotinas de acompanhamento, critérios de interpretação, proteção de dados e decisões pedagógicas.

Dessa forma, uma matriz didático-metacognitiva apoiada por recursos computacionais precisa considerar pelo menos quatro condições sociotécnicas: formação docente e letramento em dados; ergonomia cognitiva e clareza das representações; organização institucional dos dados e processos; e mediação pedagógica capaz de transformar indicadores em *feedback* formativo. A literatura revisada por pares converge para uma leitura onde a tecnologia pode ampliar a capacidade de diagnóstico e acompanhamento, mas sua contribuição depende da forma como os resultados são interpretados, contextualizados e incorporados à prática (Børte *et al.*, 2023; Márquez *et al.*, 2024; Bond *et al.*, 2024; Banihashem *et al.*, 2025).

## 5. Percurso metodológico

O estudo é teórico-propositivo, de natureza aplicada e finalidade exploratório-descritiva, acompanhado de uma demonstração técnico-computacional do *Metacognitive Calibration Assisted Model* (MCAM) com perfis simulados construídos para teste controlado. A etapa computacional foi concebida como teste de viabilidade de implementação

e de coerência lógico-operacional entre instrumento, codificação, normalização, cálculo da discrepância, inferência *fuzzy*, persistência e visualização. Com isso, o protótipo funciona como prova de conceito da cadeia analítica proposta. A avaliação empírica do modelo em contextos educacionais reais integra etapa subsequente do programa de pesquisa e encontra-se em andamento; neste artigo, o foco recai sobre a especificação conceitual e a viabilidade técnico-computacional.

O protótipo foi implementado em Java, com interface *Swing*, arquitetura cliente-servidor baseada em TCP e persistência relacional. O professor cadastra uma unidade avaliativa composta por três momentos vinculados ao mesmo conteúdo: (i) julgamento prospectivo de domínio/capacidade (pré-teste); (ii) questão objetiva de desempenho (teste); e (iii) julgamento retrospectivo de confiança (pós-teste). Na *interface* destinada ao estudante, as respostas são coletadas item a item e devolvidas ao servidor para armazenamento e agregação. Essa granularidade permite confrontar separadamente o pré-teste × teste e pós-teste × teste, sem assumir que os dois julgamentos metacognitivos sejam medidas conceitualmente idênticas. A especificação matemática é apresentada no Apêndice A, enquanto a arquitetura de execução e as interfaces correspondentes são apresentadas no Apêndice B.

As alternativas A–D dos julgamentos prospectivo e retrospectivo são recodificadas como 0, 1, 2 e 3 para fins de análise. Seja $P_i$ o código atribuído ao julgamento no item i, n o número de itens, R a pontuação objetiva obtida e R_max a pontuação máxima possível no teste. As medidas são normalizadas independentemente para o intervalo [0,1], evitando que a comparação dependa da escala bruta escolhida para o teste. Para o pré-teste e o pós-teste, as mesmas equações são aplicadas separadamente.

$$P = \Sigma_i\, p_i, \quad \text{com } p_i \in \{0,1,2,3\}$$

$$P_N = P / (3n) \qquad R_N = R / R_max$$

$$d = P_N - R_N \qquad m = |d|$$

O sinal de d expressa direção: d > 0 indica superestimação, d < 0 indica subestimação e valores próximos de zero indicam maior correspondência entre julgamento e desempenho. A magnitude matemática é m = |d|. Nesta etapa, o artigo trabalha com a discrepância como variável contínua e não fixa uma faixa universal de "calibração aceitável"; qualquer tolerância aplicada em contexto educacional deve ser examinada em função do instrumento, da tarefa e do contexto. A especificação completa das variáveis, inclusive P_N(pre), P_N(pós), d_pre e d_pós, consta do Apêndice A.

Essa separação entre direção e magnitude também aparece na literatura de acurácia metacognitiva: Persky, Lee e Schlesselman (2020) tratam o viés como a diferença entre predição e desempenho e o viés absoluto como o módulo dessa diferença, distinguindo, respectivamente, direção e magnitude do erro de julgamento.

Além da discrepância assinada, o MCAM utiliza inferência *fuzzy* para representar linguisticamente a magnitude. As entradas normalizadas são *KnowledgeReal* = R_N e *SelfPerception* = P_N; a saída *Discrepancy* utiliza os termos *Low*, *Moderate* e *High*. A base contém nove regras que atribuem baixa discrepância às combinações alinhadas (*Low*/*Low*, *Medium*/*Medium* e *High*/*High*), discrepância moderada às combinações adjacentes e alta discrepância aos extremos opostos. O sistema de inferência utiliza AND = MIN, ACT = MIN e ACCU = MAX, com defuzzificação pelo centro de gravidade (COG) e valor padrão igual a zero. Como a matriz de regras é simétrica, a saída *fuzzy* representa magnitude; a direção continua sendo dada pelo sinal de d. Vértices das funções, regras e equações do mecanismo de inferência são apresentados no Apêndice A.

As saídas do protótipo incluem visualização por dispersão normalizada, funções de pertinência e resultado defuzzificado. O *software* também mantém um módulo auxiliar de análise ROC para explorar a sensibilidade de limiares definidos pelo professor: para cada corte c entre 0,01 e C, o sistema calcula previsões binárias, matriz de confusão, TPR e FPR. Sua função, na demonstração, é examinar como alterações do limiar modificam as taxas de verdadeiros e falsos positivos quando comparadas a uma classe de referência atribuída externamente; a escolha do limite permanece sob parametrização do professor, e o sistema apresenta comparativamente a sensibilidade dos resultados ao longo dos cortes simulados. A dispersão normalizada é apresentada na Figura 1, enquanto o Apêndice B reúne exemplos de execução da inferência *fuzzy* e do módulo auxiliar ROC.

A demonstração principal utiliza dez perfis sintéticos definidos deterministicamente em um cenário de dez itens. O total recodificado de julgamento varia de 0 a 30 pontos e o desempenho objetivo da demonstração varia de 0 a 40 pontos. Os perfis foram construídos intencionalmente para cobrir padrões de maior correspondência, superestimação e subestimação em diferentes magnitudes e, assim, submeter a cadeia computacional a casos contrastantes, controláveis e rastreáveis. A tabela completa de parâmetros é apresentada no Apêndice A.

# 6. Resultados e discussão: matriz didático-metacognitiva para recalibração da aprendizagem

Como resultado teórico-propositivo, apresenta-se uma matriz didático-metacognitiva organizada em quatro movimentos: diagnosticar, oferecer *feedback*, refletir e recalibrar. A matriz parte do pressuposto de que a avaliação da aprendizagem deve considerar não apenas o desempenho objetivo, mas também a forma como o estudante percebe, interpreta e regula o próprio conhecimento. O protótipo fornece uma demonstração computacional de como parte dessas evidências pode ser organizada; a transformação dos resultados em ação pedagógica permanece dependente da mediação docente.

## 6.1 Diagnosticar: identificar a relação entre a autopercepção e o desempenho

O primeiro movimento da matriz consiste em diagnosticar a relação entre julgamento e desempenho. Nessa etapa, o objetivo não é apenas identificar se o estudante acertou ou errou, mas examinar se o julgamento produzido sobre o próprio conhecimento se aproxima ou se afasta da evidência objetiva disponível. O diagnóstico é, portanto, relacional e situado: descreve uma combinação observada em determinada tarefa e momento, e não uma característica permanente do estudante.

No protótipo, os três momentos fornecem medidas distintas e complementares. O pré-teste registra um julgamento prospectivo de capacidade ou domínio antes da questão; o teste registra o desempenho objetivo no mesmo item; e o pós-teste registra um julgamento retrospectivo de confiança após a resposta. As comparações pré-teste × teste e pós-teste × teste podem, assim, ser examinadas separadamente, evitando tratar os dois julgamentos como se fossem a mesma medida repetida.

A relação entre as medidas pode assumir três direções gerais. Há superestimação quando P_N > R_N, subestimação quando P_N < R_N e maior correspondência quando as medidas se aproximam. Essas categorias descrevem a relação observada e não constituem rótulos fixos. A intensidade do afastamento também importa: duas situações de superestimação podem ter magnitudes muito diferentes e, portanto, exigir leituras pedagógicas distintas.

A Figura 1 apresenta a visualização normalizada dos dez perfis simulados descritos na metodologia. O eixo horizontal representa o julgamento prospectivo normalizado (P_N) e o eixo vertical o desempenho objetivo normalizado (R_N). A linha de identidade y = x representa correspondência exata entre as medidas. Como cada ponto representa um caso simulado, pontos abaixo da linha indicam superestimação (P_N > R_N), pontos acima indicam subestimação (P_N < R_N) e pontos sobre ou próximos da linha indicam maior correspondência.

A distância em relação à linha de identidade pode ser interpretada em conjunto com a discrepância assinada d = P_N − R_N. O sinal informa direção e |d| informa a magnitude matemática; a inferência *fuzzy* acrescenta uma representação linguística da magnitude por regras transparentes e parâmetros explicitados. A demonstração não estabelece faixa rígida de calibração nem transforma a posição do ponto em diagnóstico definitivo. O Apêndice A permite reconstruir o cálculo desde a resposta item a item até a saída defuzzificada, e o Apêndice B mostra exemplos de execução do módulo *fuzzy* e do módulo auxiliar ROC.

Figura 1 – Dispersão normalizada produzida pelo protótipo para dez perfis simulados. As margens negativas dos eixos são apenas gráficas; P_N e R_N permanecem definidos no intervalo [0,1].

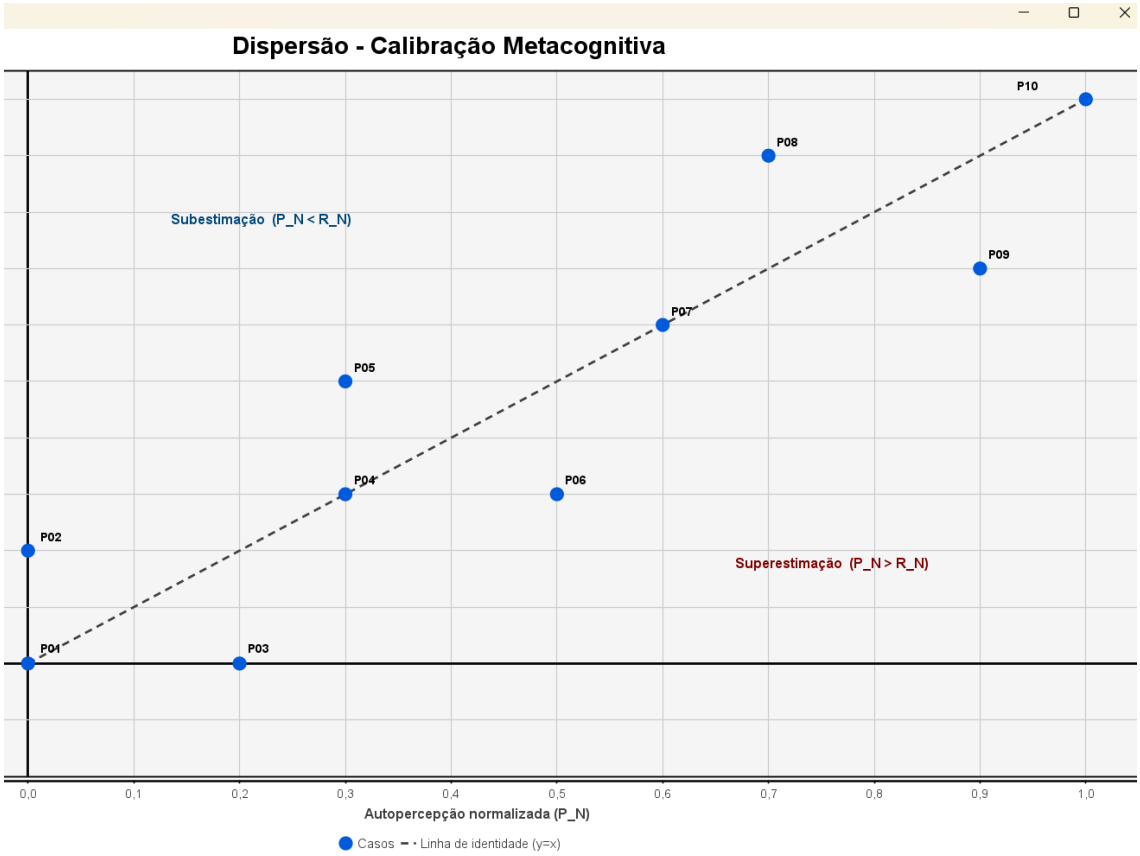


Fonte: Autoria Própria.

## 6.2 Feedback: transformar o diagnóstico em devolutiva pedagógica

O segundo movimento consiste em transformar o diagnóstico em *feedback* metacognitivo. A identificação da discrepância só ganha sentido educacional quando devolvida ao estudante de forma compreensível, contextualizada e orientada à aprendizagem. Um *feedback* metacognitivo não se limita a dizer se a resposta está certa ou errada; ele explicita a relação entre o julgamento do estudante e seu desempenho demonstrado.

No caso da superestimação, o *feedback* pode ajudar o estudante a reconhecer que sua confiança não correspondeu ao resultado obtido. Isso não deve ser feito de modo punitivo, mas como oportunidade para revisar critérios de autoavaliação, estratégias de estudo e compreensão do conteúdo. No caso da subestimação, o *feedback* pode apoiar o reconhecimento de estratégias bem-sucedidas e fortalecer a confiança acadêmica. No caso de maior correspondência entre julgamento e desempenho, pode reforçar práticas de monitoramento que favoreceram maior ajuste entre percepção e desempenho.

Na implementação demonstrada, o núcleo computacional organiza medidas, executa a inferência *fuzzy* e produz visualizações que subsidiam a formulação docente do *feedback*. No âmbito da matriz, recursos de inteligência artificial podem ampliar esse apoio mediante sugestões iniciais de devolutiva e organização das evidências; contudo, a formulação final da devolutiva deve permanecer sob responsabilidade docente, considerando o contexto da turma, a natureza do conteúdo, as condições do estudante e os objetivos formativos da avaliação.

## 6.3 Refletir: converter a devolutiva em atividade metacognitiva

O terceiro movimento da matriz é a reflexão. O *feedback* só se torna metacognitivo quando provoca o estudante a pensar sobre seus próprios critérios de julgamento e estratégias de aprendizagem. Sem essa etapa, a tecnologia corre o risco de apenas apresentar indicadores, sem promover mudança na consciência do estudante sobre seu processo de aprender.

A reflexão pode ser orientada por perguntas como: "O que eu acreditava saber antes da atividade?", "O que meu desempenho mostrou?", "Onde minha percepção se aproximou ou se afastou do resultado?", "Que estratégia utilizei?", "Que estratégia preciso modificar?", "Que evidências indicam que compreendi ou não compreendi o conteúdo?". Tais perguntas estimulam o estudante a reconstruir a relação entre percepção, desempenho e ação.

Na matriz, recursos de inteligência artificial podem apoiar a elaboração de perguntas reflexivas, a organização de trilhas de estudo e a síntese de registros de acompanhamento a partir das evidências produzidas pelo núcleo analítico. Essa camada é concebida como apoio à atividade reflexiva, preservando a participação ativa do estudante e a mediação pedagógica. O protótipo apresentado fornece o núcleo analítico que organiza as medidas, calcula a discrepância, executa a inferência *fuzzy* e produz visualizações para subsidiar esse movimento.

## 6.4 Recalibrar: ajustar progressivamente a percepção e o desempenho

O quarto movimento é a recalibração da aprendizagem. Recalibrar significa favorecer, ao longo de ciclos sucessivos, uma relação progressivamente mais informada entre aquilo que o estudante julga saber e aquilo que consegue demonstrar. Trata-se de uma finalidade pedagógica da matriz, e não de um efeito automático produzido pelo *software* ou por uma única devolutiva.

A comparação entre pré-teste, teste e pós-teste permite observar, no mesmo ciclo avaliativo, diferenças entre o julgamento prospectivo, o desempenho objetivo e a confiança retrospectiva. Quando essa estrutura é repetida ao longo do tempo, ela oferece uma base para acompanhar mudanças nos julgamentos e no desempenho. Estudos empíricos subsequentes poderão, assim, examinar de forma longitudinal a relação entre *feedback*, reflexão e recalibração, utilizando indicadores produzidos pela própria cadeia do MCAM.

A recalibração articula-se à autorregulação porque julgamentos metacognitivos podem participar de decisões sobre estudo, revisão, busca por ajuda e mudança de estratégia (Metcalfe, 2009; Panadero, 2017). Nesse sentido, a matriz não assume que a aproximação entre percepção e desempenho ocorrerá espontaneamente; ela organiza condições para que discrepâncias se tornem objeto de análise pedagógica e possam subsidiar novos ciclos de monitoramento e decisão.

## 6.5 Condições sociotécnicas e síntese da matriz proposta

A aplicação da matriz proposta exige condições sociotécnicas que ultrapassam a existência do protótipo. A primeira é a formação docente associada ao letramento em dados. Børte *et al.* (2023) mostram que o uso de tecnologias em avaliação formativa depende de professores capazes de interpretar as informações produzidas e traduzi-las em decisões voltadas à aprendizagem. No MCAM, isso significa compreender o sentido pedagógico de P_N, R_N, d e das saídas *fuzzy*, e não apenas operar a interface.

A segunda condição refere-se à ergonomia cognitiva. Skulmowski e Xu (2022) propõem que o desenho de ambientes digitais equilibre a carga cognitiva com os resultados de aprendizagem pretendidos. Por isso, as saídas do MCAM devem priorizar legibilidade, hierarquia visual e informação acionável: a formalização matemática pode permanecer disponível para auditoria, enquanto o uso pedagógico cotidiano deve oferecer representações suficientemente simples para apoiar a interpretação.

A terceira condição diz respeito à transformação dos dados em evidências formativas. Banihashem *et al.* (2025) mostram que *learning analytics* ganha valor pedagógico quando seus resultados são alinhados a processos de avaliação formativa e ajudam a compreender a situação atual do estudante, os objetivos de aprendizagem e os caminhos de avanço. Essa lógica é compatível com o MCAM ao posicionar a discrepância como evidência para diagnóstico e *feedback*, e não como classificação final.

A quarta condição é a organização institucional para adoção e governança. Márquez *et al.* (2024) identificam fatores de adoção de *learning analytics* distribuídos entre atores, processos pedagógicos e institucionais, limitações técnicas e considerações éticas. A sustentação do MCAM, portanto, requer rotinas de acompanhamento, critérios de acesso aos dados, responsabilidades definidas e espaços para que os resultados sejam discutidos pedagogicamente.

Essas condições reforçam que a inteligência artificial não deve ser pensada como solução isolada. A meta-revisão de Bond *et al.* (2024) destaca a necessidade de maior atenção a ética, contexto, colaboração e rigor metodológico na pesquisa educacional com IA. No MCAM, isso se traduz em uma arquitetura de apoio: o componente analítico organiza evidências e amplia a capacidade de leitura, enquanto a interpretação e a decisão pedagógica permanecem situadas na relação entre professor, estudante e contexto. A matriz didático-metacognitiva proposta pode ser sintetizada em quatro movimentos articulados, conforme o Quadro 1.

**Quadro 1** – Matriz didático-metacognitiva para *feedback* e recalibração.

| Movimento | Finalidade Pedagógica | Evidências Utilizadas | Apoio tecnológico possível | Papel Docente |
|---|---|---|---|---|
| **Diagnosticar** | Identificar a relação entre autopercepção e desempenho | Pré-teste, teste, pós-teste, autoavaliação e desempenho | Organização dos dados, visualizações e identificação de padrões | Interpretar o perfil do estudante e contextualizar os resultados |
| **Oferecer *Feedback*** | Transformar o diagnóstico em devolutiva formativa. | Discrepância entre percepção e desempenho | Sugestão de devolutivas, relatórios e alertas | Produzir *feedback* contextualizado, ético e pedagógico |
| **Refletir** | Estimular consciência metacognitiva | Respostas reflexivas, justificativas e estratégias relatadas | Perguntas orientadoras e trilhas de estudo | Mediar a análise crítica do estudante sobre seu processo |
| **Recalibrar** | Favorecer ajuste progressivo entre julgamento e desempenho ao longo de ciclos | Comparação longitudinal entre ciclos, desempenho e novos julgamentos | Acompanhamento longitudinal e comparação entre momentos | Planejar intervenções e acompanhar mudanças no julgamento metacognitivo |

Fonte: Autoria Própria.

A matriz busca deslocar a avaliação de uma lógica predominantemente classificatória para uma lógica formativa. Sua contribuição não está em automatizar o julgamento docente, mas em organizar evidências que possam qualificar a mediação pedagógica. O estudante deixa de ser avaliado apenas pelo resultado e passa a ser acompanhado também em relação ao modo como interpreta sua própria aprendizagem. Nesse sentido, o diagnóstico metacognitivo torna-se ponto de partida para *feedback*, reflexão e recalibração.

## 7. Considerações Finais

Este artigo propôs uma matriz didático-metacognitiva para orientar o uso de tecnologias educacionais e inteligência artificial na transformação de evidências de discrepância entre autopercepção de conhecimento e desempenho real em *feedback* pedagógico, reflexão discente e recalibração da aprendizagem. A proposta parte do

entendimento de que a avaliação educacional não deve limitar-se à mensuração do desempenho objetivo, pois a forma como o estudante julga e interpreta o próprio conhecimento acrescenta informação relevante à leitura diagnóstica.

A matriz apresentada organiza-se em quatro movimentos: diagnosticar, oferecer *feedback*, refletir e recalibrar. Diagnosticar significa examinar a relação entre julgamento e desempenho; oferecer *feedback* significa transformar essa evidência em devolutiva pedagógica; refletir significa favorecer a análise dos critérios e estratégias utilizados; e recalibrar significa buscar, ao longo de novos ciclos, julgamentos progressivamente mais informados pela experiência e pelas evidências disponíveis.

Como contribuição, o estudo desloca o uso da tecnologia de uma função meramente classificatória para uma função pedagógica mediadora. Modelos assistidos por tecnologia podem apoiar professores na organização de evidências, na visualização de padrões e na identificação de perfis de calibração metacognitiva. Entretanto, tais modelos não substituem o julgamento docente, nem devem ser usados para rotular estudantes. Sua finalidade deve ser apoiar decisões pedagógicas, *feedbacks* formativos e estratégias de acompanhamento individualizado.

O estudo também evidencia que o uso educacional da IA exige condições sociotécnicas. A formação docente, a ergonomia cognitiva, a organização dos dados e a gestão institucional são dimensões fundamentais para que a tecnologia possa contribuir de modo efetivo com a aprendizagem. Sem essas condições, há risco de reduzir a avaliação a indicadores automatizados. Com elas, abre-se a possibilidade de construir práticas avaliativas mais diagnósticas, reflexivas e orientadas à autorregulação.

Conclui-se que recursos de inteligência artificial podem contribuir para a aprendizagem quando subordinados à intencionalidade pedagógica e à mediação docente. No protótipo demonstrado, a inferência *fuzzy* constitui o componente computacional de inteligência artificial empregado para integrar as medidas normalizadas em uma representação interpretável da magnitude da discrepância. Essa informação é concebida como subsídio à mediação docente, responsável por transformar evidências em *feedback* e orientar ciclos de reflexão e recalibração. A contribuição do MCAM consiste em tornar examinável a relação entre julgamento e desempenho e disponibilizá-la de forma rastreável para apoiar decisões formativas e processos de autorregulação.

## Referências

BANIHASHEM, Seyyed Kazem *et al. Optimizing formative assessment with learning analytics. Review of Educational Research, OnlineFirst*, 2025.

BOND, Melissa *et al. A meta systematic review of artificial intelligence in higher education: a call for increased ethics, collaboration, and rigour. International Journal of Educational Technology in Higher Education*, v. 21, art. 4, 2024.

BØRTE, Kristin *et al. Prerequisites for teachers' technology use in formative assessment practices: a systematic review. Educational Research Review*, v. 41, art. 100568, 2023.

DUNLOSKY, John; RAWSON, Katherine *A. Overconfidence produces underachievement: inaccurate self evaluations undermine students' learning and retention. Learning and Instruction*, v. 22, n. 4, p. 271-280, 2012.

ESOMONU, N. P. M.; ELEJE, L. I. *Effect of diagnostic testing on students' achievement in secondary school quantitative economics. World Journal of Education*, v. 10, n. 3, p. 178-187, 2020.

FINN, Bridgid; TAUBER, Sarah K. *When confidence is not a signal of knowing: how students' experiences and beliefs about processing fluency can lead to miscalibrated confidence. Educational Psychology Review*, v. 27, n. 4, p. 567-586, 2015.

FLAVELL, John H. *Metacognition and cognitive monitoring: a new area of cognitive-developmental inquiry. American Psychologist*, v. 34, n. 10, p. 906-911, 1979.

FREIRE, Paulo. Pedagogia da autonomia: saberes necessários à prática educativa. São Paulo: Paz e Terra, 1996.

KORIAT, Asher. *Monitoring one's own knowledge during study: a cue-utilization approach to judgments of learning. Journal of Experimental Psychology: General*, v. 126, n. 4, p. 349-370, 1997.

KRUGER, Justin; DUNNING, David. *Unskilled and unaware of it: how difficulties in recognizing one's own incompetence lead to inflated self-assessments. Journal of Personality and Social Psychology*, v. 77, n. 6, p. 1121-1134, 1999.

LIBÂNEO, José Carlos. Didática. São Paulo: Cortez, 2017.

LUCKESI, Cipriano Carlos. Avaliação da aprendizagem: componente do ato pedagógico. São Paulo: Cortez, 2011.

MAHMOOD, Khalid. *Do people overestimate their information literacy skills? A systematic review of empirical evidence on the Dunning-Kruger effect. Communications in Information Literacy*, v. 10, n. 2, p. 199-213, 2016.

MÁRQUEZ, Lucía *et al. Adoption of learning analytics in higher education institutions: a systematic literature review. British Journal of Educational Technology*, v. 55, n. 2, p. 439-459, 2024.

METCALFE, Janet. *Metacognitive judgments and control of study. Current Directions in Psychological Science*, v. 18, n. 3, p. 159-163, 2009.

PANADERO, Ernesto. *A review of self-regulated learning: six models and four directions for research. Frontiers in Psychology*, v. 8, art. 422, 2017.

PENNYCOOK, Gordon; ROSS, Robert M.; KOEHLER, Derek J.; FUGELSANG, Jonathan A. *Dunning-Kruger effects in reasoning: theoretical implications of the failure to recognize incompetence. Psychonomic Bulletin & Review*, v. 24, p. 1774-1784, 2017.

PERSKY, Adam M.; LEE, Edward; SCHLESSELMAN, Lauren S. *Perception of learning versus performance as outcome measures of educational research. American Journal of Pharmaceutical Education*, v. 84, n. 7, art. 7782, 2020.

SKULMOWSKI, Alexander; XU, Kate Man. *Understanding cognitive load in digital and online learning: a new perspective on extraneous cognitive load. Educational Psychology Review*, v. 34, p. 171-196, 2022.

SOUZA, Rafael Castro de *et al.* Efeito Dunning-Kruger no processo de ensino e aprendizagem: uma revisão sistemática da literatura. Boletim de Conjuntura (BOCA), Boa Vista, v. 22, n. 64, 2025.

---

**Editor Responsável/Editor-in-Chief:** Alboni Marisa Dudeque Pianovski Vieira

**Recebido/Received:** 10.05.2026 / 05.10.2026

**Aprovado/Approved:** 15.08.2026 / 08.15.2026

# APÊNDICE A – ESPECIFICAÇÃO COMPUTACIONAL DO MCAM

## A.1 Siglas e símbolos: como ler as equações

A Tabela A1 reúne a notação empregada no processamento do MCAM e distingue as medidas normalizadas, a discrepância assinada, sua magnitude matemática e a saída fuzzy. Essa identificação também procura evitar que grandezas com funções distintas, como a discrepância assinada d, sua magnitude matemática |d| e a saída *fuzzy* F, sejam interpretadas como equivalentes.

**Tabela A1** – Siglas, símbolos e respectivas funções no processamento do MCAM.

| Sigla/símbolo | Significado | Leitura no MCAM |
|---|---|---|
| MCAM | *Metacognitive Calibration Assisted Model* | Modelo computacional de apoio à calibração metacognitiva. |
| Pré-teste / Teste / Pós-teste | prospectivo / desempenho objetivo / retrospectivo | Pré-teste: julgamento antes; Teste: desempenho objetivo; Pós-teste: confiança após o item. |
| n; p_i | número de itens; código do julgamento no item i | p_i: A=0, B=1, C=2, D=3; n: quantidade de itens. |
| P_PRE; P_PÓS; P | somas dos julgamentos | Soma dos códigos no pré-teste ou no pós-teste. |
| P_N | percepção normalizada | P/(3n), portanto varia de 0 a 1. |
| R; R_max; R_N | pontuação obtida; máximo objetivo; desempenho normalizado | R_N=R/R_max, também no intervalo 0–1. |
| d; \|d\| | discrepância assinada; magnitude matemática | d=P_N−R_N: sinal=direção; \|d\|=distância sem direção. |
| μ; μ_max | pertinência *fuzzy*; maior pertinência | Valores de 0 a 1 que expressam pertinência aos conjuntos linguísticos. |
| α_j | força da regra j | Menor pertinência das condições que ativam uma regra. |
| F | saída *fuzzy* defuzzificada | Valor numérico obtido por COG; representa magnitude fuzzy, não direção. |
| MIN / MAX; COG | operadores; *Center of Gravity* | MIN combina/ativa; MAX agrega; COG produz F. |
| TP / FP / TN / FN | matriz de confusão | Verdadeiro/falso positivo e verdadeiro/falso negativo em cada corte. |

| Sigla/símbolo | Significado | Leitura no MCAM |
|---|---|---|
| TPR / FPR | taxas de verdadeiros e falsos positivos | Coordenadas y e x, respectivamente, de cada ponto ROC. |
| C; ε | corte máximo; tolerância numérica | C limita os cortes; $\varepsilon=10^{-9}$ evita erro de comparação numérica. |
| IA | Inteligência artificial | No protótipo, a inferência *fuzzy* é o componente de IA efetivamente empregado na análise. |
| JOL / JOLs | *Judgment(s) of Learning* | Julgamento prospectivo de aprendizagem na literatura de metamemória; o pré-teste é próximo desse campo, mas não é tratado como JOL clássico. |
| TCP / DAO | *Transmission Control Protocol* / *Data Access Object* | TCP realiza a comunicação cliente-servidor; DAO é a camada que persiste e recupera os dados. |
| ROC | *Receiver Operating Characteristic* | Análise de sensibilidade dos limiares por meio das taxas TPR e FPR. |

Fonte: Autoria Própria.

## A.2 Da resposta bruta à escala comum de 0 a 1

Considerando $n$ o número total de questões, as pontuações acumuladas de autopercepção no pré-teste e no pós-teste são obtidas pelo somatório dos valores recodificados em cada item:

$$P_{\mathrm{PRE}} = \sum_{i=1}^{n} p_{\mathrm{PRE},i} \qquad P_{\mathrm{POS}} = \sum_{i=1}^{n} p_{\mathrm{POS},i}$$

Nessas expressões, $i$ representa o índice da questão, $n$ corresponde ao número total de questões e $p_{\mathrm{PRE},i}$ e $p_{\mathrm{POS},i}$ representam, respectivamente, os valores recodificados das respostas do estudante no Pré-teste e no Pós-teste para a questão $i$, adotando-se A = 0, B = 1, C = 2 e D = 3. A pontuação objetiva total do Teste é calculada de modo análogo:

$$R = \sum_{i=1}^{n} r_i$$

em que $r_i = 4$ para resposta correta e $r_i = 0$ para resposta incorreta. Como as escalas de autopercepção e de desempenho possuem amplitudes distintas, a comparação é realizada após normalização independente:

$$P_{N,\mathrm{PRE}} = \frac{P_{\mathrm{PRE}}}{3n} \qquad R_N = \frac{R}{R_{\max}}$$
$$P_{N,\mathrm{POS}} = \frac{P_{\mathrm{POS}}}{3n}$$

A discrepância metacognitiva é então calculada pela diferença entre a autopercepção normalizada e o desempenho objetivo normalizado:

$$d_{\mathrm{PRE}} = P_{N,\mathrm{PRE}} - R_N \qquad d_{\mathrm{POS}} = P_{N,\mathrm{POS}} - R_N$$

## A.3 Discrepância: direção e magnitude

Após a normalização, a percepção e o desempenho encontram-se no mesmo intervalo [0,1]. A discrepância é calculada pela diferença entre a percepção normalizada e o desempenho normalizado:

$$d = P_N - R_N$$

Nessa expressão, d é uma medida assinada. Quando d > 0, a percepção é superior ao desempenho demonstrado, caracterizando superestimação. Quando d < 0, a percepção é inferior ao desempenho, caracterizando subestimação. Valores iguais ou próximos de zero representam maior correspondência entre julgamento e desempenho. Assim, o sinal de d informa a direção do afastamento entre as duas medidas, e não apenas o seu tamanho. Para representar somente a distância entre as duas medidas, independentemente da direção, utiliza-se o módulo:

$$m = |d|$$

O valor m elimina o sinal e conserva apenas a magnitude matemática da discrepância. Portanto, duas situações com d = +0,30 e d = −0,30 possuem a mesma distância matemática (m = 0,30), embora tenham sentidos opostos: a primeira corresponde à superestimação e a segunda à subestimação. Essa distinção é importante porque direção e magnitude fornecem informações complementares para a interpretação da calibração metacognitiva.

## A.4 Inferência *fuzzy* da magnitude da discrepância

O sistema *fuzzy* recebe como entradas as duas medidas previamente normalizadas:

$$\mathrm{KnowledgeReal} = R_N;\ \mathrm{SelfPerception} = P_N$$

Cada entrada é representada pelos termos linguísticos *Low*, *Medium* e *High*. A variável de saída, denominada *Discrepancy*, utiliza os termos *Low*, *Moderate* e *High*. As funções de pertinência estabelecem, para cada valor entre 0 e 1, o grau μ com que esse valor pertence a cada conjunto *fuzzy*. Um mesmo valor pode, portanto, apresentar simultaneamente diferentes graus de pertinência em conjuntos vizinhos, o que permite representar transições graduais em vez de estabelecer fronteiras exclusivamente rígidas.

A inferência *fuzzy* depende da definição das funções de pertinência associadas às variáveis de entrada e de saída. A Tabela A2 apresenta os pontos que delimitam essas funções na configuração utilizada pelo protótipo.

**Tabela A2** – Parametrização das funções de pertinência utilizadas no sistema *fuzzy* do MCAM.

| Variável | Termo | Pontos da função de pertinência (x; μ) |
|---|---|---|
| *KnowledgeReal* | *Low* | (0,1) (0,1;1) (0,2;1) (0,3;0) |
| *KnowledgeReal* | *Medium* | (0,2;0) (0,3;1) (0,4;1) (0,5;1) (0,6;1) (0,7;0) |
| *KnowledgeReal* | *High* | (0,6;0) (0,7;1) (0,8;1) (0,9;1) (1;1) |
| *SelfPerception* | *Low* | (0,1) (0,1;1) (0,2;1) (0,3;0) |
| *SelfPerception* | *Medium* | (0,2;0) (0,3;1) (0,4;1) (0,5;0) |
| *SelfPerception* | *High* | (0,4;0) (0,5;1) (0,6;1) (0,7;1) (0,8;1) (0,9;1) (1;1) |
| *Discrepancy* | *Low* | (0,1) (0,1;1) (0,2;1) (0,3;0) |
| *Discrepancy* | *Moderate* | (0,2;0) (0,3;1) (0,4;1) (0,5;0) |
| *Discrepancy* | *High* | (0,4;0) (0,5;1) (0,6;1) (0,7;1) (0,8;1) (0,9;1) (1;1) |

**Fonte: Autoria Própria.**

Os pontos apresentados na Tabela A2 definem como os valores normalizados são distribuídos entre os termos linguísticos. Nas entradas, desempenho e autopercepção são representados pelos termos *Low*, *Medium* e *High*; na saída, a discrepância é representada por *Low*, *Moderate* e *High*. A sobreposição

parcial entre as funções permite que um mesmo valor participe, em graus diferentes, de conjuntos vizinhos, preservando o caráter gradual da inferência *fuzzy*. A saída *fuzzy* representa a magnitude da discrepância, enquanto sua direção, como superestimação ou subestimação, permanece determinada pelo sinal da discrepância assinada. Para cada regra j, sua força de ativação é calculada por:

$$\alpha_j = \text{MIN}[\ \mu_Aj(R_N),\ \mu_Bj(P_N)\ ]$$

Nessa expressão, μ_Aj(R_N) e μ_Bj(P_N) são os graus de pertinência das duas entradas aos conjuntos especificados pela regra j. O operador MIN seleciona o menor desses valores. Desse modo, a intensidade com que uma regra participa do resultado é limitada pela condição que apresenta menor grau de pertinência. Após a ativação das regras, suas contribuições são reunidas em uma única função de saída:

$$\mu_D(z) = \text{MAX_j}\ \{\ \text{MIN}[\ \alpha_j,\ \mu_Cj(z)\ ]\ \}$$

Aqui, μ_Cj(z) representa a função de pertinência do consequente da regra j. O operador MIN limita essa função à força de ativação α_j, enquanto o operador MAX reúne as contribuições das regras em uma única distribuição *fuzzy*. O resultado dessa etapa ainda não é um número isolado, mas uma função agregada de pertinência da discrepância. Por fim, essa distribuição é convertida em um valor numérico por meio do método *Center of Gravity* (COG):

$$F = [\int z \cdot \mu_D(z)\ dz] \,/\, [\int \mu_D(z)\ dz]$$

Nessa expressão, F corresponde ao valor defuzzificado e μ_D(z) representa o grau de pertinência da saída agregada. O método COG determina o centro de gravidade dessa distribuição, produzindo um valor numérico para a discrepância *fuzzy*. Esse valor pode então ser interpretado em conjunto com os graus de pertinência aos termos *Low*, *Moderate* e *High*, sem substituir a informação direcional fornecida por d. A configuração empregada pelo protótipo é:

$$\text{AND} = \text{MIN};\ \text{ACT} = \text{MIN};\ \text{ACCU} = \text{MAX};\ \text{METHOD} = \text{COG};\ \text{DEFAULT} = 0$$

Esses parâmetros tornam explícita a sequência de inferência utilizada: o mínimo é empregado na conjunção e na ativação das regras, o máximo na agregação das saídas e o centro de gravidade na defuzzificação. O valor padrão zero é utilizado quando não há contribuição capaz de produzir uma saída diferente desse valor. Essa especificação permite relacionar diretamente a formulação matemática ao procedimento executado pelo sistema.

## A.5 Curva ROC como análise de sensibilidade dos cortes

O módulo ROC é utilizado no MCAM como recurso auxiliar para examinar a sensibilidade da classificação a diferentes valores de corte. O professor estabelece um limite máximo C, e o programa percorre sucessivamente os cortes 0,01, 0,02, 0,03 e assim por diante, até C. Em cada corte, a discrepância assinada é convertida em uma decisão binária de superestimação e c representa o corte examinado e:

$$d + \varepsilon \geq c;\ \varepsilon = 1 \times 10^{-9}$$

é uma pequena tolerância computacional utilizada para reduzir problemas de comparação decorrentes da representação de números em ponto flutuante. O ε, portanto, não constitui um limiar pedagógico nem metacognitivo; sua função é exclusivamente numérica. A classificação produzida em cada corte é comparada à classe de referência utilizada no exercício controlado. Dessa comparação resultam os valores de verdadeiro positivo (TP), falso positivo (FP), verdadeiro negativo (TN) e falso negativo (FN). A partir deles são calculadas a taxa de verdadeiros positivos e a taxa de falsos positivos:

$$TPR = TP / (TP + FN);\ FPR = FP / (FP + TN)$$

A TPR representa a proporção de positivos de referência corretamente identificados, enquanto a FPR representa a proporção de negativos de referência classificados como positivos.

# APÊNDICE B – ARQUITETURA, INTERFACES E VISUALIZAÇÕES DO PROTÓTIPO

A Figura B1 apresenta a arquitetura de comunicação do protótipo. A aplicação do professor atua como servidor TCP e recebe as conexões dos módulos utilizados pelos estudantes. Para cada conexão aceita, é criada uma instância da classe correspondente ao momento avaliativo, executada em uma *thread* própria. Desse modo, os estudantes podem prosseguir independentemente após a conexão, enquanto as respostas são encaminhadas à camada de persistência. A implementação utiliza uma *thread* por conexão, sem emprego de um *ThreadPool* formal.

**Figura B1** – Arquitetura cliente-servidor TCP e atendimento concorrente por *threads*.

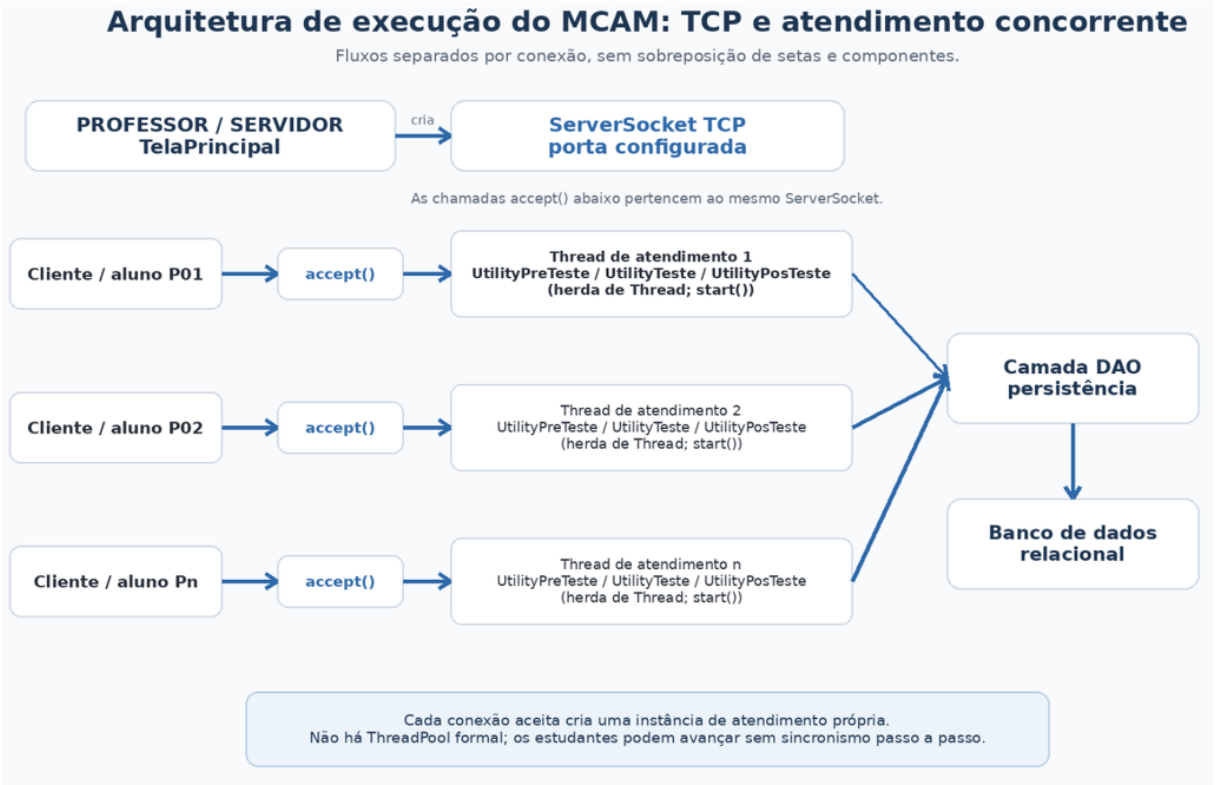


Fonte. Autoria Própria.

A Figura B2 apresenta o módulo utilizado pelo professor para configurar a execução da atividade. A interface reúne o endereço IP e a porta do servidor, o número previsto de estudantes, as questões selecionadas e a identificação do teste, além dos comandos que iniciam o pré-teste, o teste e o pós-teste. Esses parâmetros estabelecem as condições necessárias para a comunicação com os módulos dos estudantes e para o registro das respostas.

**Figura B2** – Interface do módulo do professor para configuração e execução da atividade.

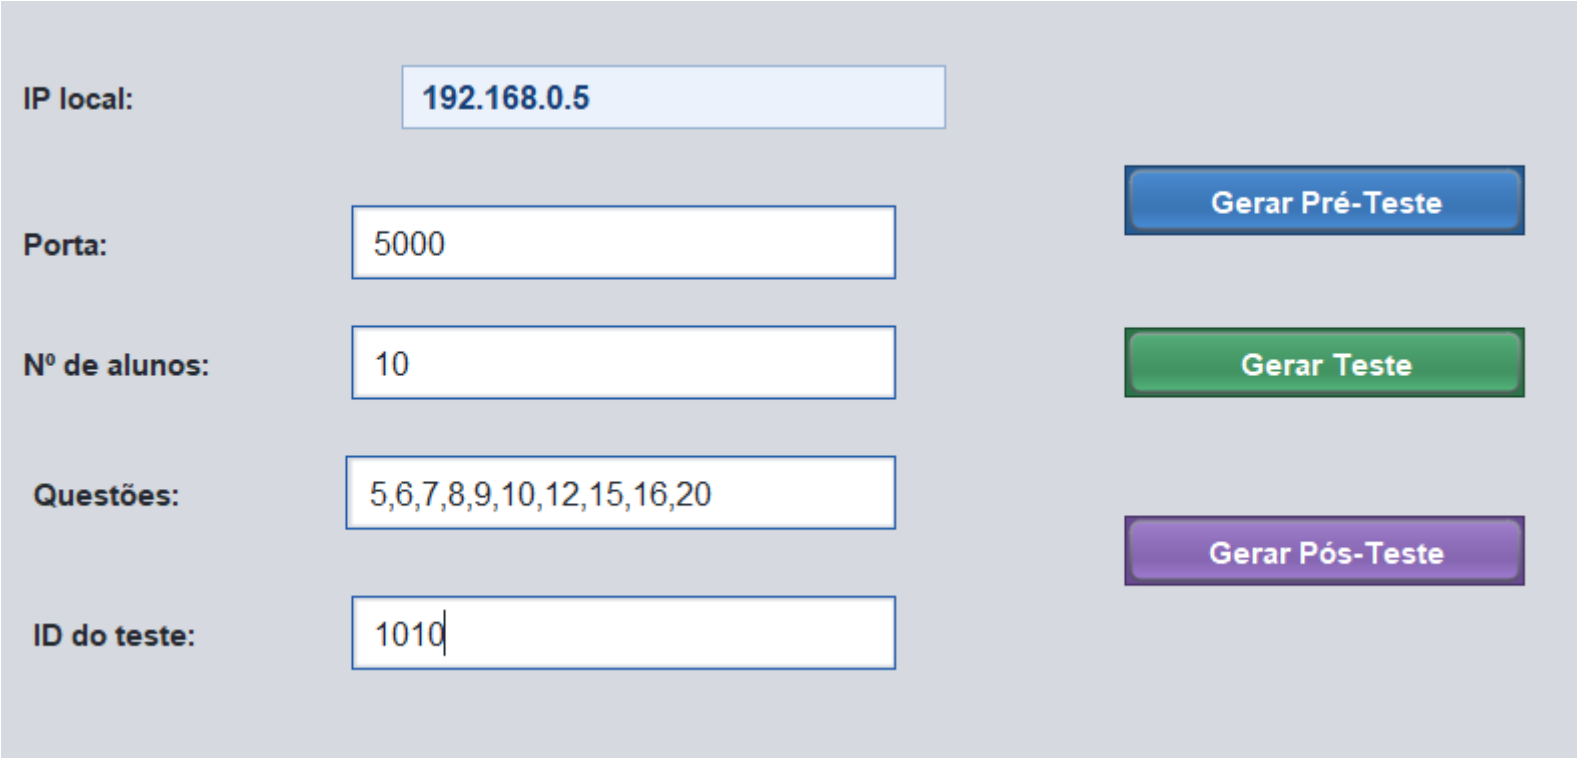


Fonte: Autoria Própria.

A Figura B3 apresenta a interface utilizada pelo estudante para estabelecer conexão com a aplicação do professor. O endereço IP e a porta identificam o servidor da atividade, enquanto o campo de identificação permite associar as respostas ao participante durante a execução. Após a conexão, o estudante recebe os itens correspondentes ao momento avaliativo iniciado pelo professor.

**Figura B3** – Interface do módulo do estudante para conexão ao servidor.

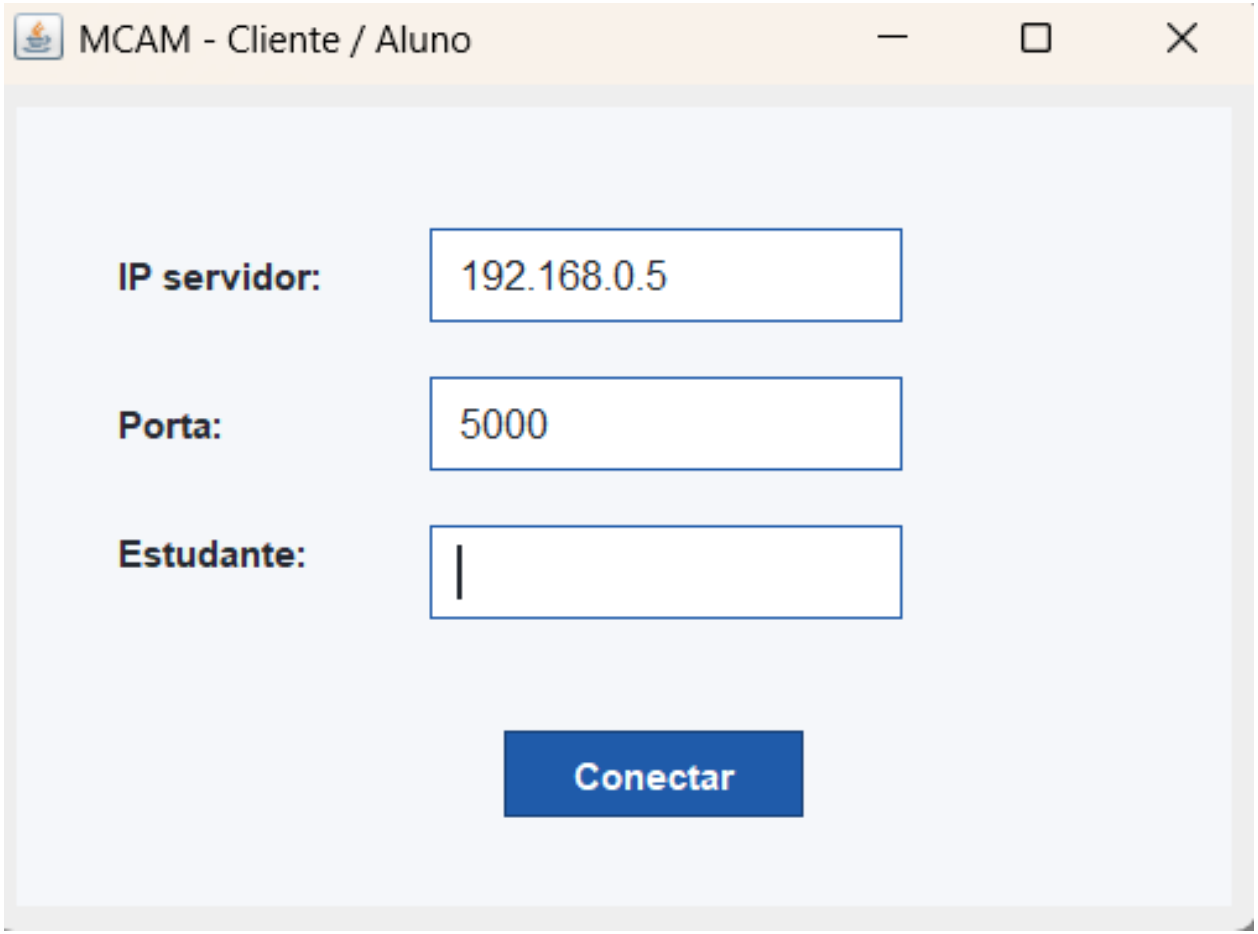


Fonte: Autoria Própria.

A Figura B4 evidencia a estrutura integrada da unidade avaliativa utilizada pelo MCAM. Para um mesmo conteúdo, o professor cadastra o Pré-teste, destinado ao julgamento prospectivo de capacidade, a questão objetiva do Teste e o Pós-teste, destinado ao julgamento retrospectivo de confiança. A vinculação dos três momentos permite relacionar posteriormente os julgamentos do estudante ao desempenho demonstrado no mesmo conjunto de itens.

**Figura B4** – Interface de edição da unidade avaliativa composta por pré-teste, teste e pós-teste.

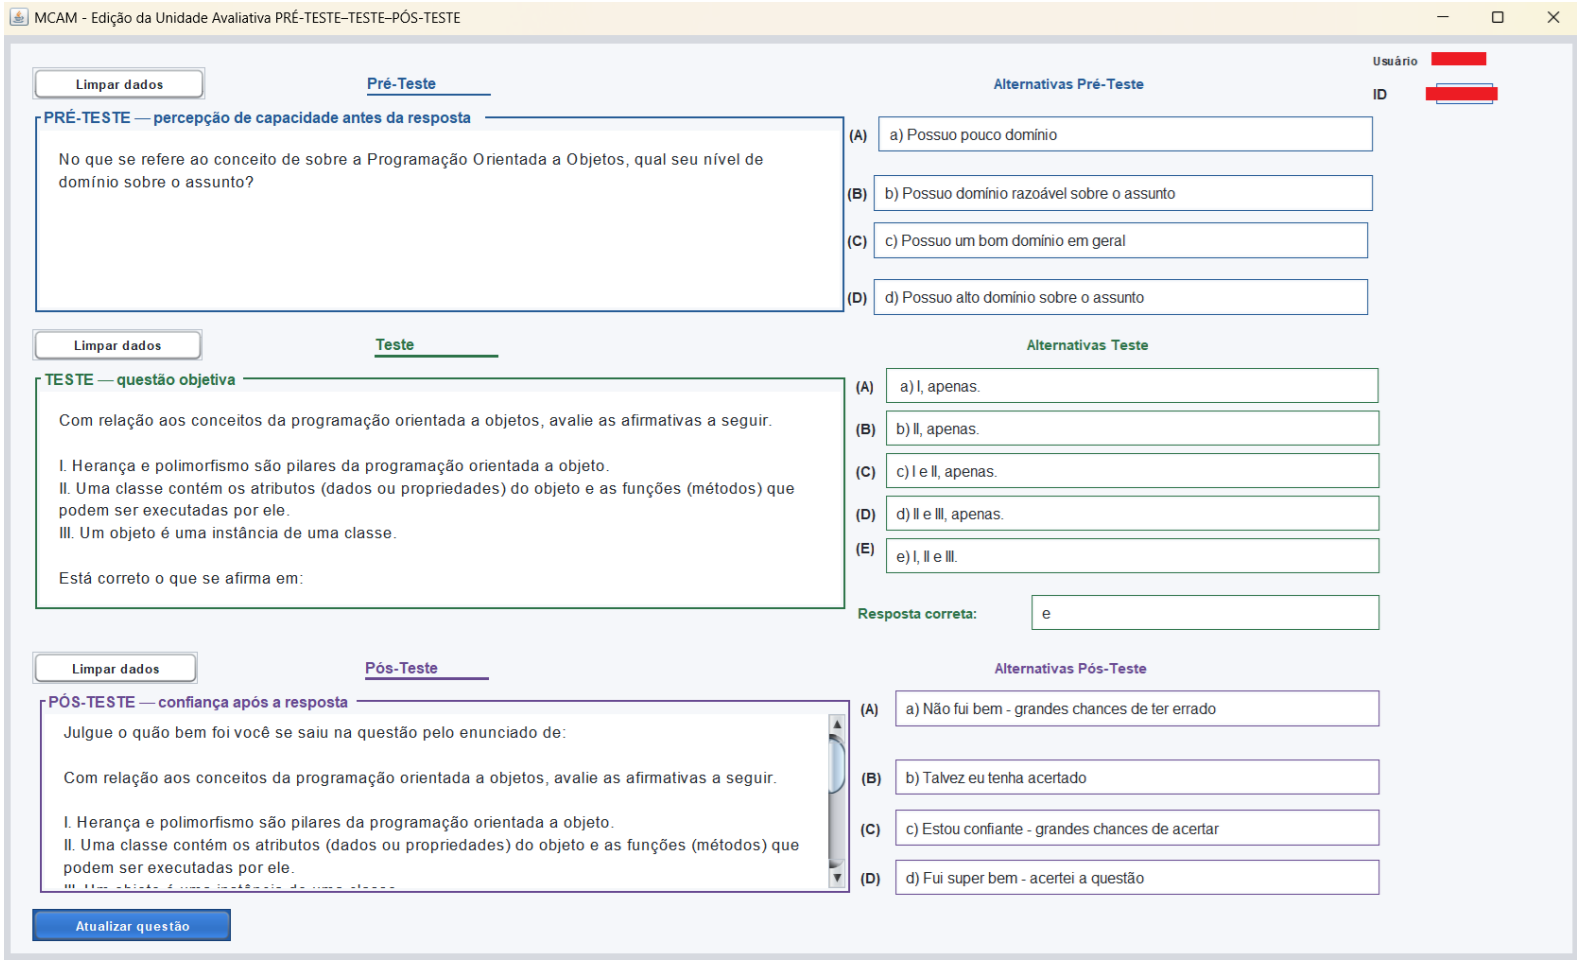


Fonte: Autoria Própria.

A Figura B5 apresenta a saída produzida pelo módulo fuzzy para um dos casos controlados da demonstração. As curvas representam os graus de pertinência aos termos *Low*, *Moderate* e *High*, e o ponto destacado indica o resultado obtido após a defuzzificação pelo método COG. No exemplo, o valor F≈0,61 apresenta maior pertinência ao conjunto *High*. Essa saída representa a magnitude *fuzzy* da discrepância; sua direção permanece determinada pelo sinal de d.

**Figura B5** – Saída *fuzzy* para um caso controlado de alta discrepância.

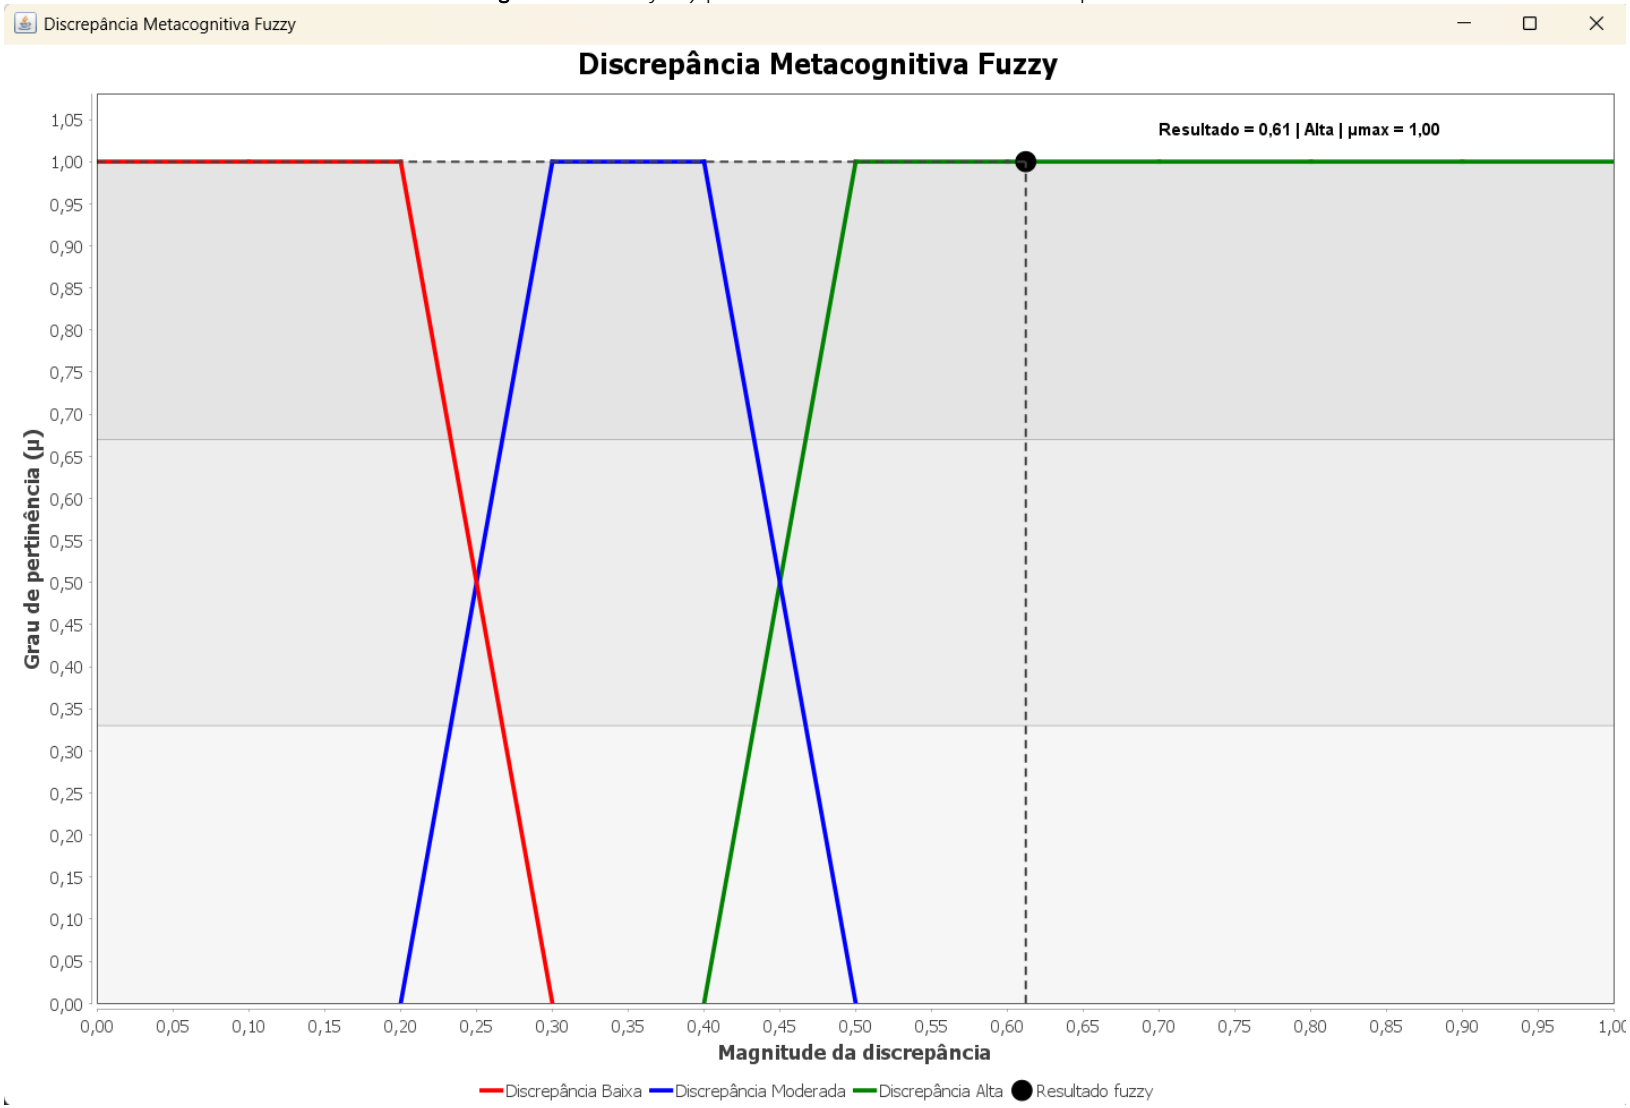


Fonte: Autoria Própria.

A Figura B6 apresenta a variação das taxas TPR e FPR para os cortes simulados entre 0,01 e 0,20. Cada par (FPR,TPR) corresponde ao comportamento da classificação em determinado limiar. Quando diferentes cortes produzem as mesmas coordenadas, seus rótulos são apenas deslocados para preservar a legibilidade do gráfico. A linha y=x funciona como referência visual, permitindo comparar a sensibilidade da classificação às alterações do corte sem atribuir ao sistema a escolha automática de um limiar ótimo.

**Figura B6** – Curva ROC para análise de sensibilidade dos cortes normalizados.

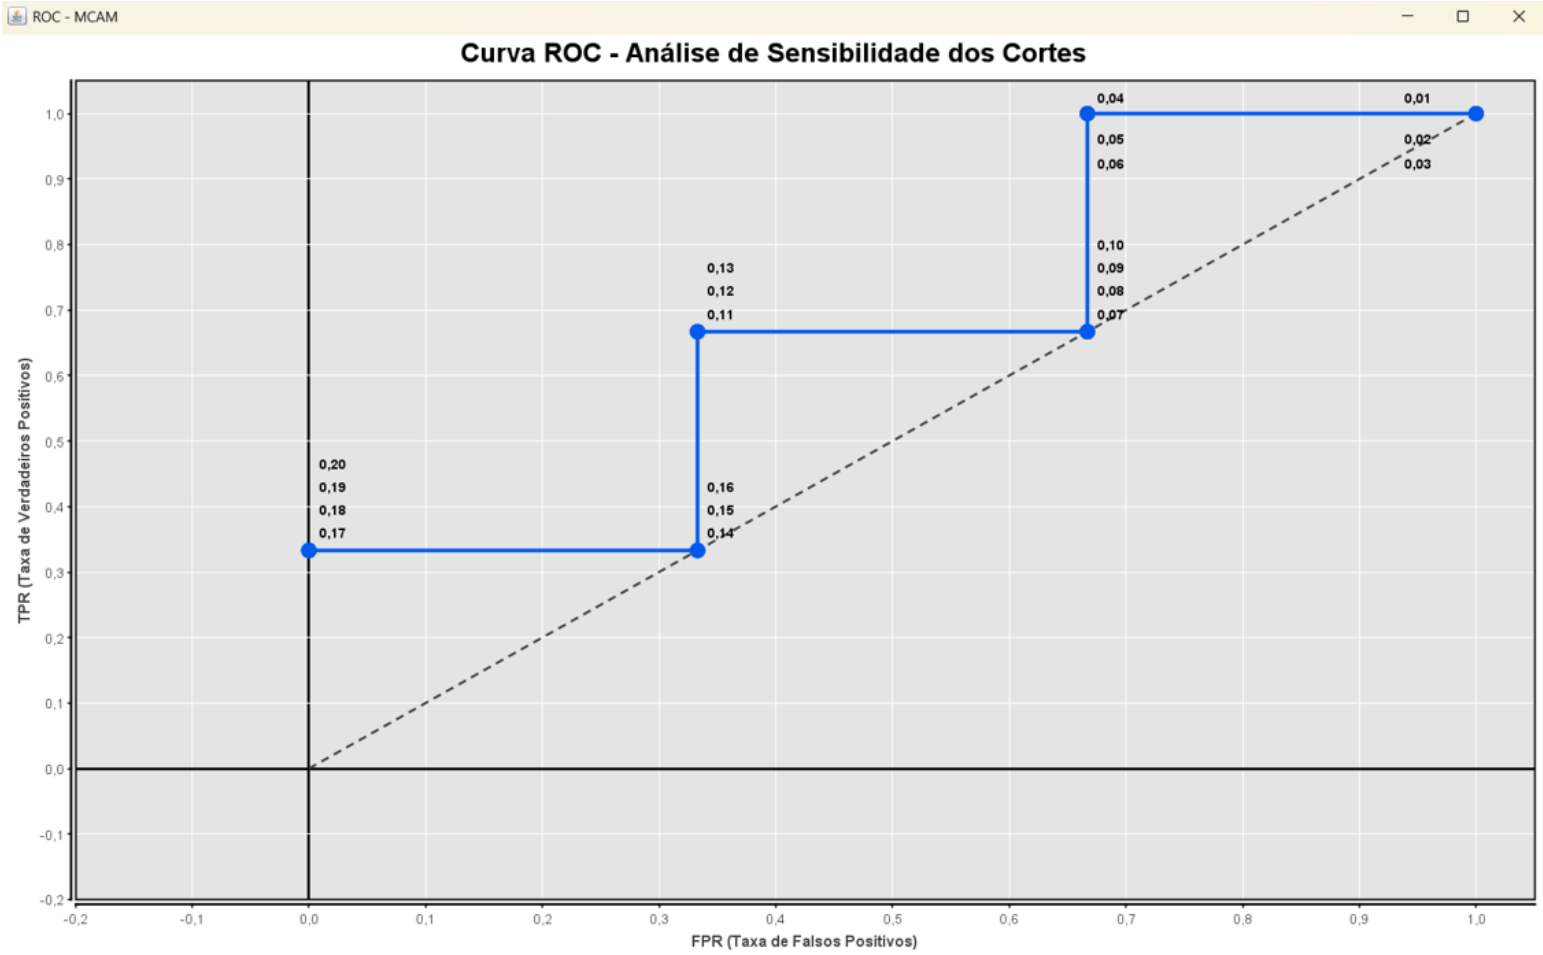


Fonte: Autoria Própria.