

CAPÍTULO 4

EVOLUÇÃO E IMPACTO DA INTELIGÊNCIA CIENTE DO CONTEXTO: UM ESTUDO SOBRE O USO DE MAPAS COGNITIVOS FUZZY PARA A PERSONALIZAÇÃO DA APRENDIZAGEM

Data de submissão: 18/10/2024

Data de aceite: 01/11/2024

Márcio Mendonça

Universidade Tecnológica Federal do
Paraná

PPGEM-CP - Programa de Pós-
Graduação em Engenharia Mecânica PP/
CP

Cornélio Procópio - PR
<http://lattes.cnpq.br/5415046018018708>

Guilherme Cyrino Geromel

Instituto Federal de Educação, Ciência
e Tecnologia de São Paulo - IFSP

Piracicaba
Piracicaba - SP

<http://lattes.cnpq.br/7535398878830738>

Fabio Rodrigo Milanez

UniSENAI PR Campus Londrina
Londrina-PR

<http://lattes.cnpq.br/3808981195212391>

Francisco de Assis Scannavino Junior

Universidade Tecnológica Federal do
Paraná Departamento Acadêmico de
Engenharia Elétrica (DAELE)
Cornélio Procópio - PR

<http://lattes.cnpq.br/4513330681918118>

Angelo Feracin Neto

Universidade Tecnológica Federal do
Paraná

Departamento Acadêmico de Engenharia
Elétrica (DAELE)
Cornélio Procópio – PR

<http://lattes.cnpq.br/0580089660443472>

Marcos Antônio de Matos Laia

Universidade Federal de São João Del Rei
Departamento De Ciência Da Computação
– UFSJ

Minas Gerais - MG
<http://lattes.cnpq.br/7114274011978868>

Emerson Ravazzi Pires da Silva

Universidade Tecnológica Federal do
Paraná

Departamento Acadêmico de Engenharia
Elétrica (DAELE)
Cornélio Procópio – PR

<http://lattes.cnpq.br/3845751794448092>

Marcos Banheti Rabello Vallim

Universidade Tecnológica Federal do
Paraná

Departamento Acadêmico de Engenharia
Elétrica (DAELE)
Cornélio Procópio – PR

<http://lattes.cnpq.br/2326190172340055>

Vitor Blanc Milani

Universidade Tecnológica Federal do Paraná
Mestrando - PPGEM-CP - Programa de
Pós-Graduação em Engenharia Mecânica PP/CP
Cornélio Procópio - PR
<http://lattes.cnpq.br/4504374098250296>

Luiz Francisco Sanches Buzzacchero

Universidade Tecnológica Federal do Paraná
Departamento Acadêmico de
Engenharia Elétrica (DAELE)
Cornélio Procópio – PR
<http://lattes.cnpq.br/1747856636744006>

Vicente de Lima Gongora

UniSENAI PR Campus Londrina
Londrina-PR
<http://lattes.cnpq.br/6784595388183195>

Wagner Fontes Godoy

Universidade Tecnológica Federal do Paraná
Departamento Acadêmico de
Engenharia Elétrica (DAELE)
Cornélio Procópio – PR
<http://lattes.cnpq.br/7337482631688459>

Marta Rúbia Pereira dos Santos

Centro Estadual de Educação Tecnológica Paula Souza
Etec Jacinto Ferreira de Sá – Ourinhos
Ourinhos - SP
<http://lattes.cnpq.br/3003910168580444>

Andressa Haiduk

Dimension Engenharia
Ponta Grossa - PR
<http://lattes.cnpq.br/2786786167224165>

Iago Maran Machado

Egresso Engenharia Mecânica pela
Universidade Tecnológica Federal
Cornélio Procópio - PR
<http://lattes.cnpq.br/3808981195212391>

Eduardo Filgueiras Damasceno

Universidade Tecnológica Federal do Paraná
Departamento Acadêmico de Computação (DACOM)
Cornélio Procópio - PR
<http://lattes.cnpq.br/7333630388674575>

Rafael Carneiro Sacoman
UniSENAI PR Campus Londrina
Londrina-PR
<http://lattes.cnpq.br/2139273105010310>

Adriano Prado de Souza
Copel Distribuição Ltda
Londrina-PR
<https://orcid.org/0009-0000-5256-1246>

Eduardo Viana de Almeida
UniSENAI PR Campus Londrina
Londrina-PR
<http://lattes.cnpq.br/5974742627952379>

RESUMO: Esse trabalho propõe o uso de um, mapas cognitivos *fuzzy* para compilar dados e informações da sala de aula para um sistema auxiliar de tomadas de decisões para o ritmo de ou velocidade dos conceitos de uma disciplina. Isso de forma resumida é possível devido ao uso de sistemas de *Machine Learning* e ou sistemas híbridos do contexto em sala de aula, os quais podem revolucionar o ensino ao adaptar-se às necessidades dos alunos e professores em tempo real. Este artigo propõe uma arquitetura de sistema que utiliza de variáveis e ou conceitos derivados de leitura de sensores e dispositivos IoT para coletar dados contextuais e aplicar algoritmos de aprendizado de máquina de forma paralela. Os parâmetros observados incluem o engajamento dos alunos, compreensão do conteúdo, variáveis ambientais, comportamento do professor e interações sociais. Além disso, discutimos os modelos de machine learning mais adequados para essa aplicação, como redes neurais convolucionais (CNN), algoritmos de classificação e regressão, e técnicas de *clustering*. Também abordamos o ciclo de aprendizado contínuo, desafios e considerações éticas. Após a compilação dessas variáveis uma proposta de tomadas de decisões em tempo real será apresentada para gerenciamento em tempo real do gerenciamento supracitado. E, finalmente uma conclusão e implantação das técnicas citadas serão integradas ao FCM para tomadas de decisões.

PALAVRAS-CHAVE: Mapas Cognitivos *Fuzzy*, *Machine Learning*, Personalização da Aprendizagem.

EVOLUTION AND IMPACT OF CONTEXT-AWARE INTELLIGENCE: A STUDY ON THE USE OF FUZZY COGNITIVE MAPS FOR THE PERSONALIZATION OF LEARNING

ABSTRACT: This work proposes the use of a fuzzy, cognitive maps to compile data and information from the classroom to an auxiliary decision-making system for the pace of or speed of the concepts of a discipline. This is possible due to the use of Machine Learning systems and/or hybrid systems in the classroom context, which can revolutionize teaching by adapting to the needs of students and teachers in real time. This paper proposes a system architecture

that uses variables and/or concepts derived from reading sensors and IoT devices to collect contextual data and apply machine learning algorithms in parallel. The parameters observed include student engagement, comprehension of the content, environmental variables, teacher behaviour and social interactions. In addition, we discuss the most suitable machine learning models for this application, such as convolutional neural networks (CNN), convolutional neural networks, and convolutional neural networks. And, finally, a conclusion and implementation of the techniques mentioned will be integrated into the FCM for decision-making.

KEYWORDS: Fuzzy Cognitive Maps, Machine Learning, Learning Personalization.

INTRODUÇÃO

A Inteligência Ciente do Contexto tem emergido como uma abordagem fundamental para o desenvolvimento de sistemas capazes de processar e interpretar informações contextuais fornecidas pelo usuário. Esses sistemas utilizam dados capturados em tempo real, relacionados diretamente à situação pessoal e ambiental do indivíduo—conhecido como “papel situado”—para adaptar suas respostas e ações. A aplicação de sistemas cientes de contexto traz benefícios significativos tanto para indivíduos quanto para instituições acadêmicas e industriais, com usos variados em múltiplos domínios.

No entanto, a implementação eficaz de sistemas contextuais levanta questões sobre a satisfação de restrições e a conformidade com preferências individuais. Moore, Jackson e Hu (2010) abordam esse desafio ao apresentar um algoritmo que incorpora ponderações às propriedades de contexto em uma abordagem quantitativa, permitindo a mitigação de violações de restrições e preferências expressas. Essa solução é demonstrada por meio de uma prova de conceito, indicando caminhos para pesquisas futuras.

Paralelamente, o estudo de Shafaei et al. (2018) destaca o aumento considerável de dados produzidos pelos componentes inteligentes em veículos modernos. O paradigma ciente do contexto desempenha um papel crucial no gerenciamento desses dados, oferecendo vantagens para aplicações inteligentes existentes e emergentes dentro dos carros. A previsão de contexto promete soluções confiáveis que melhoram o conforto dos ocupantes e a dinâmica do veículo, além de ser um passo importante para a condução altamente automatizada e autônoma. No entanto, a complexidade dos dados e a falta de estudos abrangentes no setor automotivo tornam desafiadora a definição de uma arquitetura funcional para a previsão de contexto.

No campo da educação, desafios crescentes relacionados ao engajamento dos alunos e à personalização do ensino evidenciam a necessidade de abordagens inovadoras. Soluções tradicionais frequentemente falham em se adaptar às necessidades individuais em tempo real, comprometendo a eficácia do aprendizado. Nesse cenário, a motivação e um dos objetivos está na aplicação de Mapas Cognitivos Fuzzy em sistemas de quantificação do nível de interação dos alunos em sala de aula empregando conceitos de uma ferramenta relativamente recente na área de Inteligência Artificial como uma alternativa promissora. Ao

capturar e interpretar dados contextuais em tempo real, esses sistemas podem personalizar o ambiente de aprendizagem de acordo com as necessidades específicas de cada aluno.

Este artigo explora a evolução e o impacto da Inteligência Ciente do Contexto, com foco no uso de Mapas Cognitivos Fuzzy para a personalização da aprendizagem. O objetivo principal, além da instanciação de mais uma aplicação do FCM, está em apresentar os princípios fundamentais dessa abordagem, analisamos desafios e benefícios, e apresentamos estudos de caso hipotéticos que demonstram sua aplicabilidade, entretanto sem considerar aspectos tecnológicos para implementação das variáveis circunscritas para desenvolvimento. Por meio dessa investigação, buscamos contribuir para o avanço de soluções educacionais mais adaptativas e eficazes.

Este artigo está dividido da seguinte forma: a seção 2 fundamenta os conceitos das técnicas de I.A. para desenvolvimento dessa pesquisa. A seção 3 discorre sobre o desenvolvimento desse artigo. Já a seção 4 emprega o FCM em situações diferentes para verificar as diferentes inferências. E, finalmente a seção 5 encerra e conclui o trabalho endereçando futuras pesquisas.

FUNDAMENTOS: FCM E IMPACT OF CONTEXT-AWARE INTELLIGENCE.

Os Mapas Cognitivos Fuzzy (FCMs) são uma extensão dos mapas cognitivos tradicionais introduzidos por Robert Axelrod em 1976. Axelrod, em seus trabalhos pioneiros sobre mapas mentais, propôs uma forma de representar e analisar as crenças e percepções que indivíduos ou grupos têm sobre determinados sistemas ou situações complexas.

Os mapas cognitivos de Axelrod são grafos direcionados onde os nós representam conceitos ou variáveis importantes em um sistema, e as arestas representam relações causais ou influências entre esses conceitos. Essas relações são qualitativas, indicando se a influência é positiva ou negativa, mas não quantificam a intensidade dessa influência. O objetivo era capturar e visualizar o pensamento de tomadores de decisão, permitindo uma análise estruturada de políticas e estratégias.

Evolução para Mapas Cognitivos Fuzzy. Embora os mapas cognitivos de Axelrod fossem úteis, eles tinham limitações ao lidar com a complexidade e a incerteza inerentes a muitos sistemas reais. Para superar essas limitações, Bart Kosko introduziu, em 1986, os Mapas Cognitivos Fuzzy. A principal inovação foi a incorporação da lógica Fuzzy, permitindo que as relações entre os conceitos fossem expressas em termos quantitativos e graduais, não apenas qualitativos.

Fundamentos dos Mapas Cognitivos Fuzzy

Os FCMs são estruturas que combinam elementos de redes neurais artificiais e lógica Fuzzy para modelar sistemas complexos. Seus principais componentes e características são:

- **Nós (Conceitos):** Representam estados, variáveis ou características do sistema em estudo. Cada nó possui um valor que reflete seu nível de atividade ou estado em um dado momento.
- **Arestas Ponderadas:** As conexões entre os nós são associadas a pesos que expressam o grau e o tipo de influência de um conceito sobre outro. Esses pesos podem variar em um intervalo contínuo, geralmente entre -1 e 1, onde valores positivos indicam influência estimuladora e valores negativos, influência inibitória.
- **Lógica Fuzzy:** Permite lidar com a incerteza e a imprecisão presentes nos sistemas reais. Em vez de utilizar lógica binária, a lógica fuzzy reconhece que os valores podem pertencer a conjuntos com graus de pertinência variáveis (Zadeh, 1965).
- **Dinâmica do Sistema:** Os FCMs podem ser atualizados iterativamente, permitindo a simulação da evolução do sistema ao longo do tempo. A atualização dos valores dos nós é realizada através de funções de ativação que agregam as influências, por meio de relações de causa e efeito recebidas. Após a evolução dinâmica do FCM, ele normalmente converge para um ciclo-limite D'onofrio et al (2024), em outras palavras um valor muito próximo ao valor final a cada passo, como será mostrado nos resultados.

Aplicações e Importância dos FCMs

Os Mapas Cognitivos Fuzzy têm sido amplamente utilizados em diversas áreas devido à sua capacidade de modelar sistemas complexos e dinâmicos:

- **Tomada de Decisão:** Auxiliam na análise de cenários e na avaliação de políticas ou estratégias em ambientes incertos (PAPAGEORGIOU, E.; STYLIOS, C.; GROUMPOS, P. A, 2006)
- **Engenharia e Controle:** Utilizados no design de sistemas de controle que exigem a consideração de múltiplas variáveis interconectadas (MENDONÇA et al., 2013)
- **Ciências Sociais e Comportamentais:** Modelam interações sociais, comportamentos coletivos e fenômenos psicológicos.
- **Medicina e Biologia:** Aplicados na modelagem de processos biológicos complexos e na interpretação de dados clínicos.

De modo resumido: os Mapas Cognitivos Fuzzy representam uma evolução significativa dos mapas cognitivos iniciais de Axelrod, oferecendo uma ferramenta mais robusta para modelar e analisar sistemas complexos com interações não lineares e incertezas. Ao integrar conceitos de lógica Fuzzy, os FCMs permitem uma representação mais precisa das influências entre conceitos, facilitando a compreensão e a previsão do comportamento sistêmico em diversas disciplinas.

INTELIGÊNCIA CIENTE DO CONTEXTO

A Inteligência Ciente do Contexto é um campo emergente da Inteligência Artificial que se concentra em sistemas capazes de compreender e reagir inteligentemente ao contexto em que ações ou decisões ocorrem. Diferentemente dos sistemas tradicionais que se baseiam apenas em dados brutos, essa abordagem incorpora informações adicionais — como localização, horário, preferências do usuário, condições ambientais e estado emocional — para fornecer respostas e ações mais personalizadas e relevantes.

Os principais componentes do sistema proposto incluem:

Sensores e Dispositivos IoT: A coleta de dados é realizada por meio de dispositivos da Internet das Coisas (IoT), que capturam informações sobre o ambiente, os alunos e o professor. Entre esses dispositivos estão câmeras para monitoramento visual e atenção dos alunos; microfones para captar áudio, como o tom de voz do professor e níveis de ruído; dispositivos vestíveis (smartwatches) para registrar dados biométricos dos alunos, como frequência cardíaca e nível de atividade; e sensores de movimento, termômetros e sensores de qualidade do ar para medir variáveis ambientais que podem afetar o conforto e a concentração.

Plataforma de Processamento de Dados: Os dados coletados são enviados para uma plataforma que os organiza, filtra e processa em tempo real ou próximo disso. O uso de sistemas de processamento de eventos permite estruturar os dados contextuais de forma útil para os algoritmos de machine learning.

Módulos de Machine Learning: Essenciais para a análise e adaptação dos dados em tempo real, os modelos de machine learning podem ser treinados para funções como classificação (detectar estados de atenção ou distração dos alunos), detecção de anomalias (identificar quedas bruscas no engajamento ou comportamentos inesperados) e previsão (antecipar o nível de entendimento dos alunos com base em comportamentos anteriores).

Feedback e Interface com o Professor: O sistema oferece feedback imediato e personalizado ao professor, utilizando interfaces simples e intuitivas, como painéis com gráficos de engajamento dos alunos ou alertas que sugerem ajustes no ritmo da aula.

Parâmetros observados pelo sistema incluem:

- **Engajamento dos Alunos:** Monitorado através de câmeras que rastreiam o comportamento visual, identificando quantos alunos estão atentos ou distraídos. Movimentações indicativas de inquietação e participação ativa, como levantar a mão ou interagir com dispositivos, também são usadas como métricas de engajamento.
- **Nível de Compreensão:** Avaliado pelo tempo que os alunos levam para responder perguntas ou concluir atividades, cruzando esses dados com a precisão das respostas. A análise de microexpressões faciais ajuda a detectar emoções

como confusão ou frustração, indicando o nível de entendimento.

- Parâmetros Ambientais: Fatores como qualidade do ar, temperatura e nível de ruído são monitorados para garantir um ambiente propício ao aprendizado. Sugestões podem ser feitas para ajustar essas variáveis e aumentar o conforto e a concentração.
- Comportamento do Professor: O tom de voz e o ritmo de apresentação do conteúdo pelo professor são monitorados. Se necessário, o sistema sugere ajustes para garantir clareza e manter o engajamento dos alunos.
- Interações Sociais: As interações em grupo entre os alunos são acompanhadas para ajustar dinâmicas de colaboração, identificando se certos alunos estão sendo marginalizados ou não participam adequadamente.

Os modelos de machine learning propostos incluem:

- Redes Neurais Convolucionais (CNN): Utilizadas para reconhecimento de imagens e vídeos, auxiliando no rastreamento do comportamento visual dos alunos e na detecção de estados de atenção ou distração.
- Modelos de Classificação: Algoritmos como Máquinas de Vetores de Suporte (SVM) ou Árvores de Decisão categorizam estados emocionais com base em expressões faciais ou sons captados em tempo real.
- Modelos de Regressão: Preveem o desempenho dos alunos com base em dados históricos e em tempo real, sugerindo ajustes no ritmo da aula e no conteúdo.
- Algoritmos de Clusterização: Técnicas como o K-means identificam grupos de alunos com diferentes níveis de compreensão, permitindo estratégias de ensino personalizadas.

O ciclo de aprendizado contínuo é mantido através da coleta de feedback de alunos e professores após cada aula, ajustando os modelos de machine learning e melhorando a precisão das previsões. Relatórios automáticos sobre o desempenho dos alunos são gerados, com sugestões de melhorias para as próximas aulas.

A implementação do sistema envolve linguagens de programação como Python e R, e frameworks de machine learning como TensorFlow, PyTorch e Scikit-learn. Para a coleta de dados, plataformas IoT são integradas com dispositivos de sensoriamento para monitorar o ambiente da sala de aula.

Desafios e considerações éticas incluem:

- Privacidade: Garantir a privacidade de alunos e professores é fundamental, tanto em relação aos dados coletados quanto ao seu uso.
- Consentimento: O consentimento informado de todos os envolvidos deve ser obtido, assegurando que estão cientes da coleta de dados e de seus propósitos.
- Viés em Modelos de Machine Learning: Os modelos devem ser treinados para

evitar vieses que possam prejudicar certos grupos de alunos ou favorecer outros, garantindo justiça e equidade no ensino.

DESENVOLVIMENTO

Essa seção discorre sobre o desenvolvimento do FCM e das variáveis circunscritas de maior relevância para se obter uma noção, ainda que inicial do Nível de interação dos alunos.

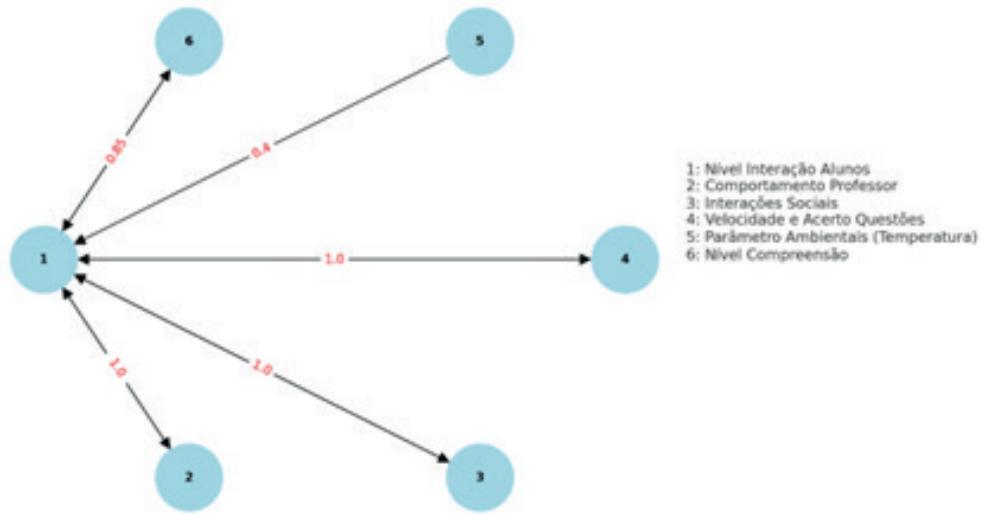


Figura 1– FCM do Nível de Interação

O diagrama apresentado na figura é um Mapa Cognitivo Fuzzy, que representa uma rede de interações entre diferentes conceitos ou fatores. Cada nó no mapa numerado corresponde a um conceito específico relacionado ao comportamento de alunos, professores e o ambiente de ensino, enquanto as setas e os valores numéricos representam a influência e a intensidade dessas interações.

O Mapa Cognitivo Fuzzy (FCM) ilustra uma rede de seis conceitos principais que interagem entre si, com influências modeladas através de pesos fuzzy variando de -1 a 1. Esses pesos indicam o impacto positivo ou negativo de um conceito sobre outro no contexto educacional descrito.

O Nível de Interação dos Alunos é o centro da rede, representando o grau em que os alunos interagem entre si. Ele influencia diretamente outros fatores, como o comportamento do professor, as interações sociais e o desempenho nas questões.

O Comportamento do Professor é influenciado negativamente pelo nível de interação dos alunos, com um peso de -1.0. Isso sugere que, quando a interação entre

os alunos aumenta, o comportamento do professor pode ser afetado de forma negativa, possivelmente devido a uma perda de controle ou desorganização da aula.

As Interações Sociais também são influenciadas negativamente pela interação dos alunos, com um peso de -1.0. Isso pode indicar que um aumento na interação dos alunos, possivelmente em contextos de distração, prejudica as interações sociais organizadas e produtivas.

A Velocidade e Acerto nas Questões representa o desempenho dos alunos em termos de rapidez e precisão na resolução de questões. A interação dos alunos afeta positivamente este conceito com um peso de 1.0, sugerindo que, quando os alunos interagem mais, há um aumento no desempenho nas atividades acadêmicas.

Os Parâmetros Ambientais (Temperatura) referem-se a fatores como a temperatura que afetam o ambiente de aprendizado. Esse fator tem uma influência moderada no nível de interação dos alunos, com peso de 0.4, indicando que ambientes mais confortáveis podem encorajar maior interação entre os estudantes.

O Nível de Compreensão reflete o quanto os alunos entendem o conteúdo e é positivamente influenciado pela interação entre eles, com um peso de 0.85. Isso sugere que, quanto mais os alunos interagem entre si, maior é a sua compreensão do material abordado.

As setas no FCM mostram a direção da influência de um conceito para outro, e os valores associados indicam a intensidade dessa influência. Valores positivos indicam uma influência benéfica, enquanto valores negativos sugerem uma influência prejudicial.

Esse modelo pode ser utilizado como uma ferramenta para simulação e análise de como mudanças em certos fatores podem impactar o comportamento geral do sistema educacional, auxiliando na tomada de decisões sobre intervenções no ambiente de sala de aula e estratégias pedagógicas. Por exemplo, modificar os parâmetros ambientais pode ser uma intervenção viável para melhorar a interação dos alunos e o nível de compreensão, conforme sugerido pelas relações identificadas no FCM.

De um modo geral: O Mapa Cognitivo Fuzzy demonstra a complexidade do ambiente educacional, onde diversos fatores estão interconectados e influenciam os resultados de aprendizado. Com base nas relações e pesos observados, intervenções focadas em aumentar a interação dos alunos de maneira controlada podem melhorar a compreensão e o desempenho acadêmico, desde que o comportamento do professor e o equilíbrio nas interações sociais sejam mantidos.

O Mapa Cognitivo Fuzzy (FCM) ilustra uma rede de seis conceitos principais que interagem entre si, com influências modeladas através de pesos fuzzy variando de -1 a 1. Esses pesos indicam o impacto positivo ou negativo de um conceito sobre outro no contexto educacional descrito.

O Nível de Interação dos Alunos é o centro da rede, representando o grau em que os alunos interagem entre si. Ele influencia diretamente outros fatores, como o comportamento

do professor, as interações sociais e o desempenho nas questões.

O Comportamento do Professor é influenciado negativamente pelo nível de interação dos alunos, com um peso de -1.0. Isso sugere que, quando a interação entre os alunos aumenta, o comportamento do professor pode ser afetado de forma negativa, possivelmente devido a uma perda de controle ou desorganização da aula.

As Interações Sociais também são influenciadas negativamente pela interação dos alunos, com um peso de -1.0. Isso pode indicar que um aumento na interação dos alunos, possivelmente em contextos de distração, prejudica as interações sociais organizadas e produtivas.

A Velocidade e Acerto nas Questões representa o desempenho dos alunos em termos de rapidez e precisão na resolução de questões. A interação dos alunos afeta positivamente este conceito com um peso de 1.0, sugerindo que, quando os alunos interagem mais, há um aumento no desempenho nas atividades acadêmicas.

Os Parâmetros Ambientais (Temperatura) referem-se a fatores como a temperatura que afetam o ambiente de aprendizado. Esse fator tem uma influência moderada no nível de interação dos alunos, com peso de 0.4, indicando que ambientes mais confortáveis podem encorajar maior interação entre os estudantes.

O Nível de Compreensão reflete o quanto os alunos entendem o conteúdo e é positivamente influenciado pela interação entre eles, com um peso de 0.85. Isso sugere que, quanto mais os alunos interagem entre si, maior é a sua compreensão do material abordado.

As setas no FCM mostram a direção da influência de um conceito para outro, e os valores associados indicam a intensidade dessa influência. Valores positivos indicam uma influência benéfica, enquanto valores negativos sugerem uma influência prejudicial. Esse modelo pode ser utilizado como uma ferramenta para simulação e análise de como mudanças em certos fatores podem impactar o comportamento geral do sistema educacional, auxiliando na tomada de decisões sobre intervenções no ambiente de sala de aula e estratégias pedagógicas. Por exemplo, modificar os parâmetros ambientais pode ser uma intervenção viável para melhorar a interação dos alunos e o nível de compreensão, conforme sugerido pelas relações identificadas no FCM.

Ressalta-se que: o mapa cognitivo fuzzy demonstra a complexidade do ambiente educacional, onde diversos fatores estão interconectados e influenciam os resultados de aprendizado. Com base nas relações e pesos observados, intervenções focadas em aumentar a interação dos alunos de maneira controlada podem melhorar a compreensão e o desempenho acadêmico, desde que o comportamento do professor e o equilíbrio nas interações sociais sejam mantidos.

RESULTADOS

Em conformidade com o modelo cognitivo desenvolvido a figura 2 mostra os resultados

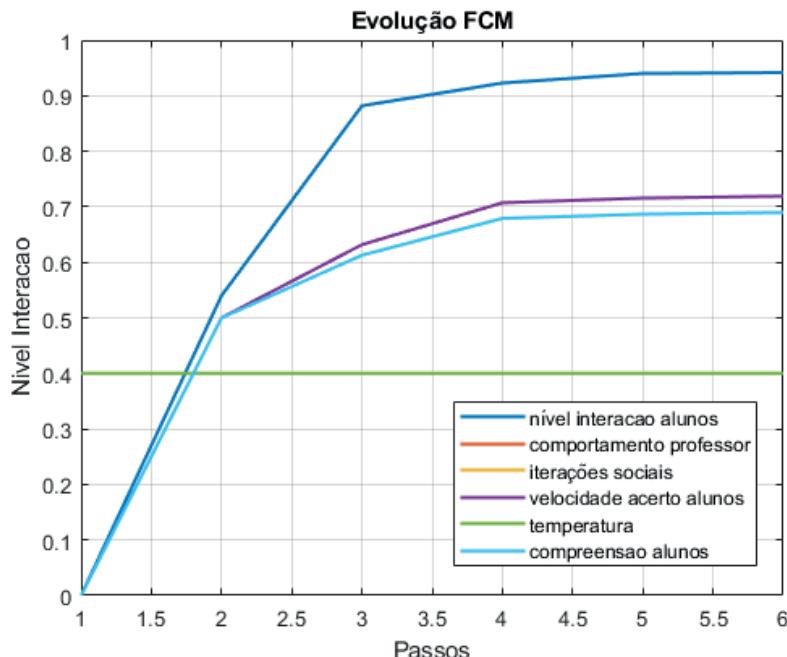


Figura 1– Nível de Interação dos alunos

A figura mostra a evolução de diversas variáveis ao longo de 6 passos, com destaque para o nível de interação dos alunos, que é representado pela linha azul. Aqui está uma análise detalhada focando no nível de interação dos alunos:

Nível de interação dos alunos:

- A curva azul, representando o **nível de interação dos alunos**, começa muito baixa no primeiro passo, próxima de 0, valor inicial atribuído ao conceito. A partir do segundo passo, ocorre um crescimento acentuado até aproximadamente 0.9, o que sugere um aumento rápido da interação entre os alunos.

No terceiro passo, o crescimento começa a desacelerar, e a partir do quarto passo, o nível de interação se estabiliza, variando muito pouco até o passo 6, com o valor permanecendo em torno de 0.9.

Comparação com outras variáveis:

- **Comportamento do professor** (linha laranja) é constante durante todo o período, o que indica que essa variável não muda significativamente ao longo do tempo, mantendo-se próxima de 0.5.

- **Interações sociais** (linha roxa) e **velocidade de acerto dos alunos** (linha magenta) têm uma trajetória de crescimento suave e constante. Elas alcançam um patamar ao redor de 0.6 a partir do passo 4, mas permanecem abaixo do nível de interação dos alunos.
- **Temperatura** (linha verde) não apresenta variação, mantendo-se estática ao redor de 0.4, sugerindo que essa variável não exerce influência relevante (se mantendo em um valor fixo) no contexto da interação dos alunos.
- **Compreensão dos alunos** (linha amarela) também permanece constante, não influenciando diretamente o nível de interação ou outros fatores no modelo.

O **nível de interação dos alunos** apresenta um aumento significativo nos primeiros passos, atingindo rapidamente um nível elevado (0.9), onde se estabiliza. Esse comportamento sugere que, com a dinâmica apresentada no gráfico, a interação dos alunos responde rapidamente a algum estímulo inicial e depois se estabiliza em um patamar alto, indicando uma interação forte e constante entre os alunos após o impulso inicial.

Este comportamento pode ser interpretado como uma forte resposta dos alunos a intervenções ou mudanças no ambiente que promovem interação, mas que, depois de um certo ponto, o nível de interação atinge um equilíbrio. A análise sugere a importância de um bom estímulo inicial para alcançar níveis elevados de interação entre os alunos.

CONCLUSÃO:

A Inteligência Ciente do Contexto possui um potencial promissor em diversos setores, como saúde, transporte, automação e, especialmente, educação. Promete sistemas mais personalizados e eficientes, oferecendo abordagens inovadoras para a personalização do ensino. Esta pesquisa destaca como o uso de dados em tempo real pode impactar positivamente o ambiente educacional, melhorando a interação entre alunos e conteúdo, e promovendo um aprendizado mais eficaz.

Sugere-se que trabalhos futuros investiguem a integração de tecnologias contextualmente cientes, inseridas apenas no modelo cognitivo, para auxiliar na velocidade de transmissão do conteúdo, ajustando-se ao nível de interação e compreensão dos alunos. Estudos podem explorar o desenvolvimento de sistemas adaptativos que modifiquem dinamicamente o ritmo e a metodologia de ensino com base nas respostas dos estudantes. Além disso, é relevante avaliar o impacto dessas tecnologias em diferentes ambientes educacionais e faixas etárias, bem como sua eficácia em promover engajamento e melhorar os resultados de aprendizagem. A exploração de análises preditivas para antecipar dificuldades dos alunos e implementar intervenções proativas também representa um caminho promissor para futuras pesquisas.

REFERÊNCIAS

D'ONOFRIO, S.; MÜLLER, S. M.; PAPAGEORGIOU, E. I.; PORTMANN, E. Fuzzy reasoning in cognitive cities: an exploratory work on fuzzy analogical reasoning using fuzzy cognitive maps. In: **IEEE INTERNATIONAL CONFERENCE ON FUZZY SYSTEMS**, 2018, Rio de Janeiro. *Proceedings*. Piscataway: IEEE, 2018. p. 1-8 DOI:10.1109/FUZZ-IEEE.2018.8491474.

MENDONÇA, Márcio; ANGELICO, Bruno; ARRUDA, L. V. R.; NEVES, Flavio. A dynamic fuzzy cognitive map applied to chemical process supervision. **Engineering Applications of Artificial Intelligence**, v. 26, n. 4, p. 1199-1210, 2013. DOI: 10.1016/j.engappai.2012.11.007.

MOORE, P.; JACKSON, M.; HU, B. Constraint Satisfaction in Intelligent Context-Aware Systems. In: **INTERNATIONAL CONFERENCE ON COMPLEX, INTELLIGENT AND SOFTWARE INTENSIVE SYSTEMS**, 2010, Cracóvia, Polônia. Anais [*International Conference on Complex*]. Cracóvia: IEEE, 2010. p. 75-80. DOI: 10.1109/CISIS.2010.25.

PAPAGEORGIOU, E.; STYLIOS, C.; GROUMPOS, P. A combined fuzzy cognitive map and decision trees model for medical decision making. In: **ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY**, 28., 2006, New York, NY, USA. *Proceedings...* Piscataway, NJ: IEEE, 2006. p. 6117-6120. DOI: 10.1109/EMBS.2006.260354.

SHAFAEI, S.; MÜLLER, F.; SALZMANN, T.; FARZANEH, M. H.; KUGELE, S.; KNOLL, A. Context Prediction Architectures in Next Generation of Intelligent Cars. In: **INTERNATIONAL CONFERENCE ON INTELLIGENT TRANSPORTATION SYSTEMS (ITSC)**, 21., 2018, Maui, HI, USA. IEEE, 2018. p. 2923-2930. DOI: 10.1109/ITSC.2018.8569617.