

Sistema de Recomendação *Fuzzificado* de Objetos de Aprendizagem

Iulisloi Zacarias, Rafael Antônio Vitalli, Naidú Gasparotto de Souza, Fábio José Parreira, Sidnei Renato Silveira, Adriana Sadowski de Souza

Universidade Federal de Santa Maria (UFSM) - Centro de Educação Superior Norte (CESNORS) - Caixa Postal 54 - Frederico Westphalen - RS - Brasil

Departamento de Tecnologia da Informação

iuli.zacarias@gmail.com, rafavitalli@gmail.com, naidu.gaspar@hotmail.com, fabiojparreira.ufsm@gmail.com, sidneirenato.silveira@gmail.com, adrianasadowski@gmail.com

Resumo. *Este artigo apresenta um protótipo de sistema de recomendação de objetos de aprendizagem, desenvolvido por meio da lógica fuzzy. Este sistema de recomendação será integrado a uma arquitetura que permita a adaptação de cursos ministrados na modalidade de Educação a Distância (EaD) de acordo com o estilo cognitivo dos alunos.*

Abstract. *This paper proposes a learning objects recommender system prototype developed with fuzzy logic. This recommender system will be integrated with an architecture definition that enables the adaptation of courses offered in the form of Distance Education (DE) according to the cognitive style of the students.*

1. Introdução

Os conceitos de rede, ciberespaço e hipermídia como linguagem começaram a se consolidar com a popularização dos computadores pessoais e da internet, que se deu nos primeiros anos deste século, ocasionando um desenvolvimento notável das formas de comunicação hipermediáticas, principalmente na internet, destacando-se a sua utilização em vários campos, inclusive no educacional. A hipermídia passou a ser a linguagem do ciberespaço e da cultura em movimento constante e evolutivo, em que seus valores se reafirmam, pressupondo um mundo de operações, funções e significações diferenciadas, vividas e experimentadas pelas pessoas. Ela possui como anteparo uma série de mídias alocadas em um mesmo suporte e apresenta, através dessa união, uma personalidade diferente, repleta de interatividade, caminhos e opções para os seus adeptos ou usuários. Dessa forma, compõe-se como um "mix" de linguagens, unindo várias mídias que se complementam, sustentando-se como linguagem híbrida (Machado, 2001).

É nesse contexto que a UFSM adotou o Moodle como sendo o seu Sistema de Gerenciamento de Cursos (*Course Management System* - CMS). Por meio do Moodle é possível criar e gerenciar as disciplinas ministradas nos cursos presenciais e a distância, conforme as normatizações da UFSM. Ao iniciar o processo de construção de uma disciplina no Moodle, o primeiro ponto a ser considerado é quais objetos de aprendizagem hipermediáticos poderão ser ofertados com a finalidade de mediar pedagogicamente o conteúdo a ser ministrado. Além dessa preocupação inicial, é importante levar em consideração que cada aluno possui diferentes níveis de conhecimento e formas diferenciadas de entendimento e aprendizagem. Sendo assim, ao recomendar alguns Objetos de Aprendizagem (OAs) é importante considerar as incertezas que o aluno traz consigo acerca do conteúdo abordado. Acredita-se que os conjuntos *fuzzy* representam perfeitamente estas incertezas. De acordo com Zadeh (1965) tais conjuntos são baseados na ideia de que existem situações nas quais não está

claro se um elemento pertence ou não a um determinado conjunto.

Neste sentido, o presente trabalho propõe um sistema de recomendação que utiliza a lógica *fuzzy* em seu algoritmo de recomendação de OAs. O artigo apresenta um breve referencial teórico sobre as áreas envolvidas (objetos de aprendizagem, sistemas de recomendação e lógica *fuzzy*), situa o estado da arte e apresenta o andamento da solução implementada.

2. Referencial Teórico

2.1 Objetos de Aprendizagem

Um objeto de aprendizagem pode ser constituído de uma única atividade ou de um módulo educacional completo, ou seja, um conjunto de estratégias e atividades, visando promover a aprendizagem em sala de aula. Segundo Wiley (2000 apud Souza et. al., 2013): “Objetos de aprendizagem são elementos de um novo tipo de instrução baseada em computador construído sobre um novo paradigma da Ciência da Computação. Pode-se usar como recurso didático um só objeto de aprendizagem, como ele pode ser agregado a outros, ou seja, objetos de aprendizagem relacionados ao mesmo conteúdo (assunto) formando um novo objeto de aprendizagem”.

Segundo Tarouco (2004 apud Souza et. al., 2013), as seguintes características são comuns aos objetos de aprendizagem:

- Reusabilidade: essa característica faz com que os objetos de aprendizagem, como módulos básicos, sejam utilizados de diferentes formas, para abordar conteúdos diferentes em contextos diferenciados;
- Portabilidade: é a capacidade que um objeto de aprendizagem tem de ser executado em diferentes plataformas de trabalho (sistemas operacionais);
- Modularidade: refere-se à forma dos objetos de aprendizagem que deve ser em módulos independentes e não sequenciais, para poderem ser usados em conjunto com outros recursos e em diferentes contextos;
- Flexibilidade: devem ser construídos em módulos com início, meio e fim, para serem flexíveis, podendo ser reutilizados sem manutenção. Isso cria mais uma vantagem que é a interoperabilidade, ou seja, a reutilização dos objetos não apenas em nível de plataforma de ensino, mas em nível mundial.

A utilização de objetos de aprendizagem vem crescendo significativamente à medida que melhora o modo como os objetos são armazenados e distribuídos na Internet.

2.2 Sistemas de Recomendação

A quantidade de informação produzida e disponibilizada na *web* pode ocasionar uma sobrecarga cognitiva sobre o usuário final. Devido a este problema várias tecnologias têm surgido para apoiar a seleção, recuperação e filtragem da informação desejada ou de interesse do usuário. Esta recuperação na maioria das vezes é realizada por uma apresentação explícita das necessidades do usuário, ou seja, uso de palavras-chave. Com o crescimento do comércio eletrônico e, também, da Educação a Distância (EaD) via internet, houve a necessidade de oferecer serviços personalizados aos usuários. Sistemas de recomendação (SRs) (Ricci et. al, 2011) surgiram como uma forma eficiente para solucionar este problema.

Os Sistemas de Recomendação (SRs) são capazes de aprender com as preferências do usuário e automaticamente sugerir produtos/serviços/itens que atendam ao seu perfil. Estes sistemas têm sido muito utilizados no comércio eletrônico com o objetivo de sugerir produtos ou fornecer informações para ajudar o usuário a decidir sobre uma determinada compra, bem como em sistemas educacionais, sugerindo materiais didáticos, cursos e objetos de aprendizagem aos alunos (Schafer et al., 2000).

Segundo Herlocker (2000), por muitos anos os cientistas têm direcionado seus esforços para aliviar o problema ocasionado com a sobrecarga de informações através de projetos que integram tecnologias que automaticamente reconhecem e categorizam as informações. Os sistemas baseados nesta técnica têm como objetivo gerar, de forma automática, descrições dos conteúdos dos itens e comparar a descrição de cada item com a descrição dos interesses dos usuários ou com o histórico de consumo e/ou utilização do mesmo, visando verificar se o item é interessante para o usuário em questão (Herlocker, 2000).

A descrição de interesses do usuário é obtida através de informações fornecidas pelo próprio usuário, através do perfil do usuário, através de uma consulta, ou aprendendo com os itens que o usuário consome (aqueles que o usuário gosta e compra). Esta técnica é chamada de filtragem baseada em conteúdo (FBC) porque o sistema realiza a filtragem baseada na análise de conteúdo do item e no perfil do usuário (Herlocker, 2000).

2.3 Lógica Fuzzy

A teoria de conjunto *fuzzy* (Zadeh, 1965) é considerada o principal pilar da teoria da lógica *fuzzy*, ela difere da tradicional, principalmente, ao que se refere a descontinuidades. Na *fuzzy* não há uma distinção abrupta entre elementos pertencentes e não pertencentes a um conjunto, o que leva à admissão da possibilidade de pertinência parcial, logo um elemento pode pertencer a um dado conjunto, com determinado grau de pertinência.

Seja um conjunto *fuzzy* F em um universo de discurso U , a função de pertinência de F é definida como: $\mu_F: U \rightarrow [0, 1]$. O valor 0 (zero) indica a não pertinência e o valor 1 (um) a pertinência plena. Este mesmo conjunto é representado por pares ordenados de μ_F e u . Sendo u um elemento qualquer e, μ_F o seu grau de pertinência, neste sentido, tem-se: $F = \{\mu_F(u)/u\}, u \in U$.

Entre os conjuntos *fuzzy* é possível realizar operações. Sendo A e B conjuntos *fuzzy* de U , a operação de união, equivalente operador *max*, é representada por: $\mu_{A \cup B}(u) = \max\{\mu_A(u), \mu_B(u)\} \forall u \in U$. Por sua vez, a operação de interseção, equivalente ao operador *min*, é definida por: $\mu_{A \cap B}(u) = \min\{\mu_A(u), \mu_B(u)\} \forall u \in U$.

O produto cartesiano é similar à operação de interseção, tendo-se A_1, A_2, \dots, A_n como conjuntos *fuzzy* em U_1, U_2, \dots, U_n respectivamente. O produto cartesiano, destes, resulta em um conjunto *fuzzy* no espaço denotado por $U_1 \times U_2 \times \dots \times U_n$, cuja função de pertinência é: $\mu_{A_1 \times A_2 \times \dots \times A_n}(u_1, u_2, \dots, u_n) = \min\{\mu_{A_1}(u_1), \mu_{A_2}(u_2), \dots, \mu_{A_n}(u_n)\}$.

Por definição, o produto cartesiano *fuzzy* é uma relação *fuzzy*. Uma relação *fuzzy* n -ária é definido por: $R_{A_1 \times A_2 \times \dots \times A_n} = \{\mu_R(a_1, a_2, \dots, a_n) / (a_1, a_2, \dots, a_n)\} / (a_1, a_2, \dots, a_n), a_i \in A_i, i=1, \dots, n$. A composição entre relações, conforme proposta de Zadeh (1965), é a operação denominada *max-min*. Logo, a composição entre as relações R e S , em $U_1 \times U_2$ e $U_2 \times U_3$ respectivamente, é denotada por $R \circ S$, cuja função de pertinência, é fornecida por: $\mu_{R \circ S}(x_1, x_3) = \max_{x_2 \in U_2} [\min(\mu_R(x_1, x_2), \mu_S(x_2, x_3))]$.

3. Estado da Arte

Existem diversos sistemas de recomendação de objetos de aprendizagem apresentados na literatura. Entretanto, não foram encontrados sistemas que apliquem a lógica *fuzzy*. Existem sistemas implementados por meio de sistemas multiagentes, tais como os propostos por Muniz (Muniz et.al., 2012) e Silva (Silva et. al., 2011). Outros sistemas, tais como os propostos por Cazella (Cazella et. al., 2009) e Zaina (Zaina et. al, 2012) utilizam algoritmos de recomendação com técnicas de filtragem colaborativa ou de filtragem baseada em conteúdo.

Muniz (Muniz et. al. 2012) propõe uma abordagem de recomendação baseada em agentes, recomendando OAs que utilizam o padrão T-SCORM. O padrão T-SCORM é uma extensão do padrão SCORM (*Shareable Content Object Reference Model*), visando a apresentação de OAs em televisões digitais interativas. O sistema multiagente (SMA) conta com quatro agentes: estudante, conteúdo, interface e DF. O agente estudante monitora as atividades dos alunos e envia, para o agente de conteúdo, informações sobre o perfil do estudante (informadas, explicitamente, pelos alunos) - estático, além de capturar informações dinâmicas sobre a utilização do sistema. O agente de conteúdo é o responsável por buscar os OAs no repositório e selecionar/recomendar os mais indicados para o estudante, utilizando a técnica da filtragem baseada em conteúdo, considerando os atributos dos OAs e o perfil dos estudantes. O agente de interface exibe os OAs e o agente DF armazena os serviços que cada agente oferece na arquitetura. Os agentes foram desenvolvidos utilizando o JADE (*Java Agent Development Framework*).

Silva (Silva et. al., 2011) apresenta um ambiente multiagente de aprendizagem, o MobiLE – ambiente multiagente de aprendizagem móvel para apoiar a recomendação sensível ao contexto de objetos de aprendizagem. Esta arquitetura também foi desenvolvida utilizando-se o JADE e o perfil do aluno possui informações estáticas e dinâmicas, como no trabalho anterior. O diferencial desta arquitetura é que a recomendação utiliza as técnicas de filtragem baseada em conteúdo (atributos dos OAs comparados ao perfil do estudante) e de filtragem colaborativa (comparação de estudantes com preferências semelhantes). A arquitetura conta com três agentes: agente estudante, agente recomendador e agente de interface. O ambiente móvel foi construído utilizando-se o *framework* de desenvolvimento de aplicações MLE (*Mobile Learning Engine*).

Uma abordagem de recomendação baseada em filtragem colaborativa e competências é proposta por Cazella (Cazella et. al., 2009). A recomendação de OAs é realizada por meio dos gostos dos alunos por determinados objetos de aprendizagem, bem como pelas competências que devem ser desenvolvidas, estabelecidas pelos professores. A filtragem colaborativa baseia-se na avaliação que é dada pelos alunos aos OAs e a similaridade entre os alunos é calculada por meio do coeficiente de *Pearson*. Após a definição da predição, o sistema verifica se as competências que devem ser adquiridas pelo aluno, estabelecidas pelo professor, estão de acordo com os OAs potencialmente recomendados. A abordagem de recomendação foi validada por meio de um protótipo desenvolvido em Java.

Zaina (Zaina et. al., 2012) apresenta uma abordagem de recomendação de OAs denominada *e-LORS* (*e-Learning Object Recommendation System*) baseada no relacionamento entre as dimensões que incorporam as preferências de aprendizagem de um aluno e os metadados que descrevem os OAs. O sistema de recomendação utiliza a filtragem baseada em conteúdo, confrontando-se as informações do tema de estudo, o

perfil de aprendizagem do aluno e as possíveis restrições tecnológicas que caracterizam o ambiente eletrônico em que o aluno interage.

Diferentemente dos sistemas apresentados, este trabalho propõe a recomendação empregando a lógica *fuzzy*, tendo-se em vista a possibilidade de considerar as incertezas que os alunos possuem com relação ao conteúdos (OAs) a serem recomendados.

4. Sistema Fuzzificado Implementado

O Sistema Fuzzificado de Recomendação de Objetos de Aprendizagem (OAs) consiste em três módulos: o cadastro/alteração de questões, cadastro/alteração de OAs e o Sistema de Recomendação *Fuzzificado* de OAs (SRF). Neste artigo será detalhado o SRF, conforme apresentado na Figura 1. Para desenvolver o sistema foi utilizada a linguagem de programação *Java*, juntamente com o Sistema Gerenciador de Banco de Dados *SQL Server*.

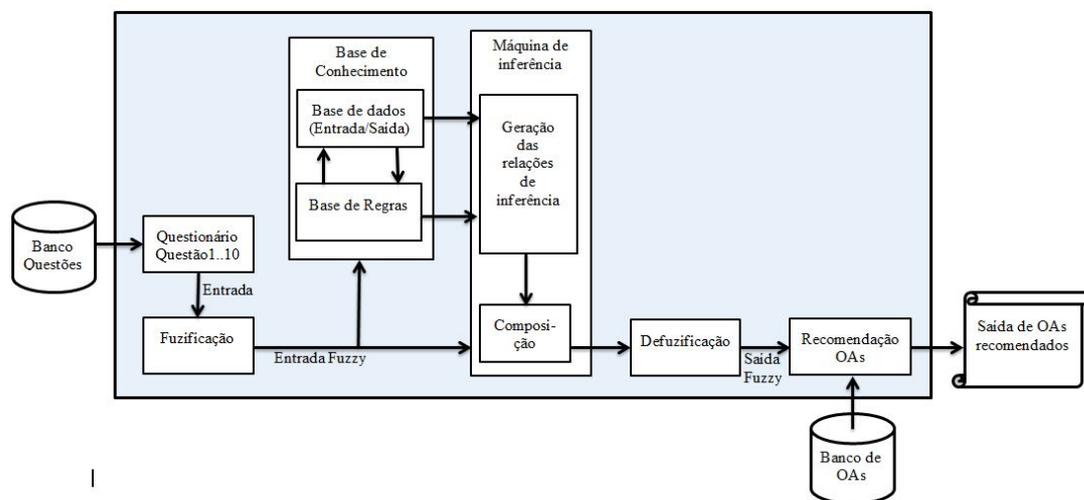


Figura 1: SRF: Sistema de Recomendação *Fuzzificado* de OAs

Inicialmente, é apresentado um questionário ao aluno, contendo dez questões sorteadas aleatoriamente. Cada questão possui cinco alternativas, que podem ser marcadas com “V” (verdadeiro) “F” (falso), valendo dois pontos cada.

A equação para calcular os acertos é definida como: $Q1, \dots, Q10 = 2 * \sum_{i=1}^N \text{alternativasCorretas}(i)$, onde N é o total de alternativas da questão. Ao final, o questionário produz um conjunto de dados *crisp* (ou valores numéricos não *fuzzy*) da avaliação contendo as *notasQuestões*($Q1, \dots, Q10$)= $[Q1, \dots, Q10]$.

O *fuzzificador* de dados consiste em converter os dados de entrada em valores *fuzzy*, por meio do mapeamento de números reais em conjunto *fuzzy*. Neste processo a metodologia de *fuzzificação* adotada é o conjunto singular. Um *fuzzificador* singular mapeia um ponto real $u^* \in U \rightarrow [0, 10]$ em um conjunto difuso singular F' em U , que possui valor de pertinência 1 em u^* e 0 em todos os outros pontos em U (Wang, 1997), conforme segue: $\mu_{F'}(u) = 1$ se $u = u^*$, 0 se $u \neq u^*$. O *fuzzificador* produz um conjunto de pares ordenados contendo as *notasQuestões*($Q1, \dots, Q10$), e seus respectivos graus de pertinência $\mu_{Q1}, \dots, \mu_{Q10}$.

A base de conhecimento é composta por uma base de dados e uma base de regras. A base de dados é formada pelas variáveis de entrada (*Conhecimento*) e saída (*Recomendação*). Graficamente, o *Conhecimento* e a *Recomendação* são representados na figura 2.

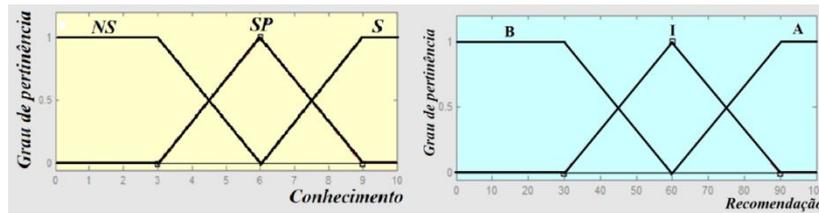


Figura 2: Conhecimento do aluno e Recomendação de OAs

Os conjuntos *fuzzy* da variável de entrada *conhecimento* são: NS (*Não satisfaz*)-conhecimento inferior a 4, indica que o conhecimento do aluno, referente ao conteúdo previamente estabelecido, está muito abaixo do esperado; SP (*Satisfaz parcialmente*) conhecimento em torno de 5 e 7. Neste caso, o aluno está com um pouco de dificuldade em seu aprendizado; S (*Satisfaz*) conhecimento superior a 8. O aluno já possui conhecimentos necessários para conseguir êxito no aprendizado do conteúdo.

Para a variável de saída, *Recomendação*, os conjuntos *fuzzy* são: B (*Básico*) ao serem recomendados OAs *básicos*, significa que o aluno está com o conhecimento bem deficitário, precisando suprir a maioria dos conceitos exigidos na disciplina; I (*Intermediária*): para essa recomendação, o aluno está quase conseguindo acompanhar os conteúdos ministrados em sua integralidade, sendo necessário apenas um pequeno reforço; A (*Avançado*): esta recomendação tem a finalidade de manter a aprendizagem interessante, para aluno que já adquiriu, de alguma forma, os conceitos que serão ministrados na disciplina, neste caso, são recomendados OAs que representam certo desafio ao conhecimento do aluno.

A base de regras tem por finalidade associar as variáveis linguísticas de entrada com as de saída (Campos e Saito, 2004). Sendo assim, ela define as estratégias de resposta do sistema, por meio de uma coleção de afirmações condicionais, que tem a forma “*Se<antecedente>então<consequente>*” (Zadeh, 1988).

Conforme a proposta deste trabalho, o questionário utilizado para quantificar o conhecimento do aluno possui dez questões, por isso as afirmações condicionais possuem como *antecedentes* a variável *Conhecimento*_{Q1,...,Q10}, cuja cardinalidade é três (NS, SP, S). Para a saída, que é o *consequente* da regra, foi definida a variável *Recomendação*, cuja cardinalidade também é três (B, I e A). Sendo assim, as regras propostas, para recomendar os OAs, são formadas por dez antecedentes e um consequente, neste contexto, elas podem ser escritas com conjunções (conectivo *e*) no antecedente:

$R_1 = SE(Q1 \text{ é } NS) \text{ e } (Q2 \text{ é } NS) \text{ e } (Q3 \text{ é } NS) \text{ e } (Q4 \text{ é } NS) \text{ e } (Q5 \text{ é } NS) \text{ e } (Q6 \text{ é } NS) \text{ e } (Q7 \text{ é } NS) \text{ e } (Q8 \text{ é } NS) \text{ e } (Q9 \text{ é } NS) \text{ e } (Q10 \text{ é } NS) \text{ ENTÃO } \textit{Recomendação} \text{ é } B$

$R_n = SE(Q1 \text{ é } S \text{ e } Q2 \text{ é } S \text{ e } Q3 \text{ é } S \text{ e } Q4 \text{ é } S \text{ e } Q5 \text{ é } S \text{ e } Q6 \text{ é } S \text{ e } Q7 \text{ é } S \text{ e } Q8 \text{ é } S \text{ e } Q9 \text{ é } S \text{ e } Q10 \text{ é } S) \text{ então } \textit{Recomendação} \text{ é } A$

Sendo que R_1 a R_n são as regras *fuzzy* inseridas pelos especialistas. O total de regras a serem inferidas pelo SRF, representado pelo valor de n , é calculado de acordo com a equação: $n = \textit{Cardinalidade}Q1 * \dots * \textit{Cardinalidade}Q10$. Logo o total de regras é: $n = 3 * 3 * 3 * 3 * 3 * 3 * 3 * 3 * 3 * 3 = 59.049 \textit{ regras}$.

A máquina de inferência, adotada neste trabalho, é baseada na inferência max-min, proposta por Mamdani (1974). A seguir é definido um caso especial de inferência, que é utilizado no SRF, para recomendação de conteúdos. Neste sentido a máquina de inferência proposta possui duas tarefas bem distintas: agregação e composição. Na agregação deve-se calcular a importância de cada regra, por meio do coeficiente de disparo, para selecionar as mais pertinentes à situação corrente. Já na composição calcula-se a influência de cada regra selecionada, nas variáveis de saída. Neste contexto, conforme descrito nos passos abaixo, para cada regra, tem-se:

- Passo 1: Localiza-se a compatibilidade das entradas ($q1, q2...q10$), por meio do grau de pertinência ($\mu_{NS}(q_n), \mu_{SF}(q_n)$ ou $\mu_S(q_n)$), conforme apresentado, graficamente, na figura 2.
- Passo 2: Calcula-se a medida do coeficiente de disparo, de cada regra, por meio da conjunção dos antecedentes:

$$\alpha_{00001} = \min\{\mu_{NS}(q1), \mu_{NS}(q2), \mu_{NS}(q3), \mu_{NS}(q4), \mu_{NS}(q5), \mu_{NS}(q6), \mu_{NS}(q7), \mu_{NS}(q8), \mu_{NS}(q9), \mu_{NS}(q10)\}$$

$$\alpha_{59049} = \min\{\mu_S(q1), \mu_S(q2), \mu_S(q3), \mu_S(q4), \mu_S(q5), \mu_S(q6), \mu_S(q7), \mu_S(q8), \mu_S(q9), \mu_S(q10)\}$$

- Passo 3: Ao selecionar todas as regras, cujo $\alpha > 0$, no resultado de cada uma é aplicado: $R'_j = \min(\alpha_j, R_j), j = 1 \dots N$, onde N é o total de regras selecionadas.
- Passo 4: Na agregação dos resultados, R'_j , de cada regra, $R_1, R_2 \dots R_n$, aplica-se: $R(r) = \bigcup_{j=1}^N R'_{j(r)} = \max[R'_{j(r)}, j = 1 \dots N], \forall r \in \text{Recomendação}$. Ao final do passo 4, R é um conjunto *fuzzy* com seus respectivos elementos e graus de pertinência, por exemplo: $R = \{0/0, 20/0, 40/0.2, 60/0.8, 100/0\}$.

A *defuzzificação* consiste em converter os valores *fuzzy* de saída em valores numéricos. Para realizar a conversão, utilizou-se o critério do método do centro de área, conforme apresentado: $\text{valorDefuzzificado} = \frac{\sum_{i=1}^n \mu_F(u_i) * u_i}{\sum_{i=1}^n \mu_F(u_i)}$, onde n é o número elementos. Considerando a aplicação desta equação, na saída R, tem-se a saída *defuzzificada* como sendo igual a:

$$\text{valorDefuzzificado} = \frac{0 * 0 + 0 * 20 + 40 * 0.2 + 60 * 0.8 + 80 * 0.2 + 100 * 0}{0 + 0 + 0.2 + 0.8 + 0.2 + 0} = 60$$

A recomendação de OAs é concretizada aplicando-se o *valorDefuzzificado* à variável de saída *Recomendação*, que três conjuntos fuzzy: B, I e A. De acordo com a figura 3, tem-se $\mu_I(60) = 1$, portanto, este aluno está com grau de pertinência igual a 1, no conjunto *fuzzy* intermediário. Logo, os OAs estão em um nível de dificuldade considerado intermediário. Neste nível, o aluno está quase conseguindo acompanhar os conteúdos ministrados em sua integralidade, sendo necessário apenas um pequeno reforço no aprendizado.

5. Considerações Finais

O presente trabalho estabelece um método computacional capaz de interpretar as competências dos professores, no tangente à recomendação de OAs, em determinado conteúdo. Este método resultou no Sistema de Recomendação *Fuzzificado*, que é capaz de imitar parte do raciocínio humano, e tem como cerne a lógica *fuzzy*. Ao fazer uso da lógica *fuzzy*, que quantifica as incertezas humanas, o sistema demonstrou ser uma importante ferramenta para a recomendação de OAs, pois direciona os alunos em seus estudos, considerando as incertezas sobre o melhor material a ser estudado, levando em consideração as dificuldades de cada estudante. Durante a etapa de testes, foram realizadas pesquisas com 20 alunos, cujas informações foram geradas aleatoriamente. Destes, somente em 5 casos o sistema não se comportou adequadamente, conforme os especialistas, foi quando o *valorDefuzzificado* é maior que 70 e menor que 75. Para estes valores o SRF recomenda OAs cujo nível de dificuldade é intermediário. Já os especialistas concordam que este estudante tem condições de estudar em conteúdos avançados. Para resolver tal impasse faz-se necessário implementar testes com uma quantidade maior de conjuntos *fuzzy*, tanto de entrada quanto de saída, para representar melhor as incertezas do conhecimento do aluno. O sistema proposto apresenta-se como

uma arquitetura promissora para a recomendação de OAs, pois foram alcançados 75% de sucesso. Como trabalhos futuros, pretende-se integrar o SRF à arquitetura de adaptação apresentada em Souza et. al. (2013). Além disso, pretende-se aplicar metodologias para pré-selecionar as regras que irão compor a base de regras, diminuindo assim, a quantidade de regras a serem analisadas.

Referências

- Campos, M. M. de; Saito, K (2004). “Sistemas Inteligentes em Controle e Automação de Processos”. Rio de Janeiro: Ciência Moderna.
- Cazella, S. C.; Reategui, E. B.; Machado, M.; Barbosa, J. L. V. (2009). “Recomendação de Objetos de Aprendizagem empregando Filtragem Colaborativa e Competências”. Anais do XX Simpósio Brasileiro de Informática na Educação.
- Herlocker, J. L. (2000). “Understanding and Improving Automated Collaborative Filtering Systems”. University of Minnesota, Minnesota.
- Machado, A. (2001). “O quarto iconoclasmo (e outros ensaios hereges)”. Rio de Janeiro: Contracapa.
- Mamdani, E. H. (1974). “Application of Fuzzy Algorithms for Control of Simple Dynamic Plant”. IEEE (Control and Science), v.121(12), p.1585-1588.
- Muniz, R. C.; Mendes Neto, F. M.; Burlamaqui, A. M. F.; Souza, R. C. (2012). “Uma Abordagem Baseada em Agentes para Recomendação de Objetos de Aprendizagem utilizando o padrão T-SCORM para TVDi”. Revista Novas Tecnologias na Educação. V. 10, n. 3, dezembro.
- Ricci, F.; Rokach, L.; Shapira, B.; Kantor, P. B. (2011). “Recommender Systems Handbook”. Springer.
- Schafer, J. B.; Konstan, J.; Riedl, J. (2000). “Recommender Systems”. In: Conference on Electronic Commerce, Minneapolis. Proceedings.
- Silva, L. C. N.; Mendes Neto, F. M.; Jácome Júnior, L. (2011). “MobiLE: um ambiente multiagente de aprendizagem móvel para apoiar a recomendação sensível ao contexto de objetos de aprendizagem”. Anais do XX Simpósio Brasileiro de Informática na Educação.
- Souza, N. G.; Silveira, S. R.; Bigolin, N. M.; Parreira, F. J.; Cunha; G. B. (2013). “Arquitetura para Adaptação de Cursos na Modalidade de Educação a Distância empregando Objetos de Aprendizagem”. Anais do EATI – Encontro Anual de Tecnologia da Informação. UFSM/CAFW.
- Wang, L. (1997). “A Course in Fuzzy Systems and Control”. New Jersey: Prentice-Hall International, Inc.
- Zadeh, L. A. (1965). “Fuzzy sets”. Information and Control, v. 8, n. 3, p. 338–353.
- Zadeh, L. A. (1988). “Fuzzy logic”. Computer 21(4): 83–93.
- Zaina, L. A. M.; Bressan, G.; Cardieri, M. A. C. A.; Rodrigues Júnior, J. F. (2012). “e- LORS: uma abordagem para recomendação de objetos de aprendizagem”. Revista Brasileira de Informática na Educação. V. 20, n. 1.