

## Uso de Lógica Fuzzy na Seleção de Estratégias de Aprendizagem

Luis Henrique S. Rodrigues<sup>1</sup>, Luciana Assis<sup>1</sup>, Alessandro Vivas<sup>1</sup>,  
Cristiano Pitangui<sup>1</sup>, Samuel Falci<sup>1</sup>

<sup>1</sup>Programa de Pós-Graduação em Educação (PPGED)  
Universidade Federal dos Vales do Jequitinhonha e Mucuri (UFVJM)

luishenrique@minasvale.com.br

{lupassis, alessandro.vivas, pitangui.cristiano, samuelhfalci}@gmail.com

**Abstract.** *The evolution of distance education was by the popularization of information and communication technologies, the most important aspect in a Adaptive and Intelligent System for Education, is its ability to adapt to the characteristics of each student. This paper presents a proposal for automatic detection and correction of learning styles (EA) using an algorithm based on fuzzy logic. This approach offers excellent results for minimizing learning problems.*

**Resumo.** *Com o crescimento da Educação à Distância (EAD), impulsionado pela popularização das tecnologias da informação e comunicação, o aspecto mais importante em um Sistema Adaptativo e Inteligente para Educação (SAIE), é a sua capacidade de adaptação às particularidades de cada estudante. Este trabalho apresenta uma proposta para detecção e correção automática de estilos de aprendizagem (EA) com o uso de um algoritmo baseado em Lógica Fuzzy. Esta abordagem apresenta ótimos resultados na busca por minimizar problemas de aprendizagem.*

### 1. Introdução

Na área educacional a evolução das Tecnologias da Informação e Comunicação (TICs) impulsionaram o desenvolvimento de ferramentas poderosas que possibilitam o fácil acesso a conteúdos e informações, contribuindo para a expansão da Educação a Distância (EAD).

A EAD surgiu em 1728 quando Calleb Philips anunciou uma modalidade de ensino através do uso de correspondências. A EAD evoluiu e utilizou diferentes tipos de tecnologias, isto é, rádio, televisão, teleconferência e por último a Internet [Moore et al. 2011].

Atualmente, cursos de diversas áreas são ofertados na Internet através de um modelo de ensino denominado *E-learning*, que possibilita a auto-aprendizagem. Estes sistemas tem com objetivo fornecer uma plataforma de fácil utilização para que o aprendiz consiga atingir seus objetivos de acordo com as particularidades do aprendiz e do conteúdo lecionado.

Sistemas de EAD tradicionalmente utilizam Ambientes Virtuais de Aprendizagem (AVA). Segundo [de Oliveira et al. 2001, dos Santos 2002], um AVA pode ser conceituado como o espaço das relações com o saber, o qual é o objeto maior do processo de

aprendizagem. Esses ambientes estabelecem comunicação de seres humanos utilizando ferramentas digitais tais como: blogs, sites, fóruns, comunidades virtuais entre outros.

Quando um Ambiente Virtual de Aprendizagem (AVA) utiliza técnicas de Inteligência Artificial é denominado de Sistemas de Tutoria Inteligentes (STI). STI devem se adaptar às necessidades do aprendiz fornecendo Objetos de Aprendizagem (OA) de acordo com seu Estilo de Aprendizagem (EA).

Diante disto, a proposta central deste trabalho é a utilização de Lógica Fuzzy na definição de um modelo probabilístico na Combinação de Estilos de Aprendizagem (CEA), de maneira dinâmica, buscando a melhor política para aplicação de conteúdos em uma plataforma de Ensino à Distância.

A aplicação deste trabalho utilizou como base um Sistema Adaptativo e Inteligente para Educação proposto por [Dorça 2012]. Para realização dos testes foram utilizadas técnicas de simulação computacional, o que permitiu a constatação da eficiência do algoritmo na detecção das preferências do aluno.

## **2. Referencial Teórico**

### **2.1. Estilos de Aprendizagem**

Aprender é um processo exclusivo a cada ser humano que depende de vários aspectos físicos, psíquicos e sociais. [SANCHO and Hernández 2006, Cavellucci 2005] relatam que cada aluno tem o seu jeito individual e particular de adquirir conhecimento. [Allport 1937] completa que cada pessoa percebe, processa, armazena e recupera as informações de uma forma peculiar, que é denominado Estilos de Aprendizagem.

A partir do modelo de [Kolb 1984] e nos tipos psicológicos de Myers-Briggs (MBTI), [Felder and Silverman 1988] propuseram um novo modelo que atualmente é um dos mais utilizados quando a pesquisa está relacionada a Estilos de Aprendizagem [Graf 2009]. [Carvalho et al. 2014] relata que este modelo é amplamente utilizado em pesquisas que envolvem Estilos de Aprendizagem por representar com bastante eficácia estudantes reais em um modelo computacional facilmente entendível pelos STI's.

Este modelo sofreu revisão em 2002 e, a partir de então, ficou organizado em quatro dimensões que definem a preferência de aprendizagem: Percepção, Entrada, Processamento e Organização.

A dimensão Percepção descreve a forma com que as pessoas percebem o que está no ambiente. Nesta dimensão os indivíduos podem ser definidos como Sensoriais ou Intuitivos. Os sensoriais são pessoas mais racionais que preferem fatos e dados para formação de conhecimento, preferem a experimentação, descritos por [Felder and Silverman 1988] como detalhistas. Os intuitivos são mais rápidos menos atentos a detalhes e são fortemente teóricos.

A dimensão Entrada descreve a forma mais prática de assimilação do conteúdo. Nesta dimensão as pessoas são caracterizadas como Visual ou Verbal. Os visuais preferem figuras, gráficos, desenhos, mapas mentais entre outros. Os verbais preferem a informação falada ou explicação onde o que é dito ou escrito é absorvido e processado pelo receptor [Senra 2009].

A dimensão Processamento descreve a forma como as informações percebidas

são convertidas em conhecimento. Neste caso, os indivíduos podem ser definidos como Ativos ou Reflexivos. O ativo prefere aplicar para assimilar, geralmente gosta de fazer na prática o que está sendo percebido. O reflexivo pensa, de forma individual e não se preocupa com aplicação.

A dimensão Organização refere-se a forma como a organização do conteúdo é melhor assimilada, podendo ser o indivíduo ser Sequencial ou Global. O primeiro opta por uma sequência lógica e planejada do que deve ser aprendido. O segundo prefere que o conteúdo seja exposto na íntegra e os conceitos vão surgindo da assimilação destes conceitos [Senra 2009].

Segundo [Felder and Silverman 1988] cada pessoa apresenta um estilo referente a cada dimensão com determinado grau de pertinência, ou seja, em uma determinada dimensão, o indivíduo pode possuir um percentual de ambas características. Por exemplo, ele pode ser 10% sensorial e 90% intuitivo, na dimensão Percepção.

Assim, pensando neste grau de pertinência, este trabalho consiste no uso do modelo de Felder e Silverman para classificação dos Estilos de Aprendizagem e na aplicação de Lógica *Fuzzy* para detectar estes estilos. A Lógica *Fuzzy* é uma ferramenta que se adapta bem nestas situações onde não há uma definição única ou binária de determinadas características. Assim, o sistema proposto simula a apresentação de conteúdo aos estudantes utilizando diferentes Combinações de Estilos de Aprendizagem (CEA) e, então, com a adaptação do sistema, o conteúdo será apresentado de acordo com o Estilo de Aprendizagem real do estudante. A seção 2.2 apresenta detalhes do sistema proposto por [Dorça 2012] que simula esta adaptação de um sistema real ao Estilo de Aprendizagem do estudante.

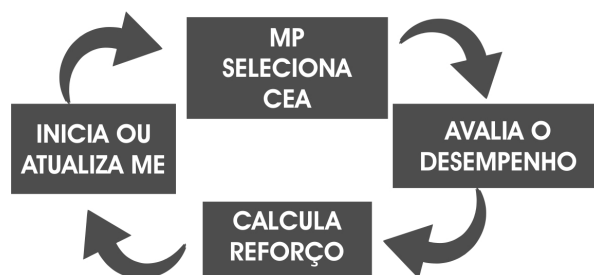
## 2.2. Sistema Adaptativo e Inteligente para Educação

Com a necessidade de ambientes adaptativos que centralizem o ensino nas características de cada aluno, vários sistemas vêm surgindo na intenção de potencializar o aprendizado com o uso dessas ferramentas. [Brusilovsky et al. 1996] faz referência a um tipo de sistema denominado Sistema Adaptativo e Inteligente para Educação (SAIE), que busca a personalização e assistência individualizada aos estudantes apoiado em técnicas de inteligência computacional. [Iglesias et al. 2009] caracteriza quatro tarefas básicas no processo de ensino em um SAIE: aquisição de dados, processamento dos dados, construção e atualização do Modelo do Estudante, e personalização da estratégia de ensino baseada em conteúdos.

Em síntese, a abordagem proposta por [Dorça 2012] obedece o ciclo exposto na figura 1.

O processo se inicia com o carregamento das informações relacionadas ao aluno contidas no Modelo do Estudante (ME), dentre elas o Estilo de Aprendizagem. Baseado neste Estilo de Aprendizagem, o Modelo Pedagógico (MP) seleciona uma Combinação de Estilos de Aprendizagem (CEA) de maneira estocástica. Esta CEA define a forma como o conteúdo será apresentado para o aluno. Por exemplo, se a CEA escolhida contiver o estilo Visual, então o conteúdo pode ser apresentado através de um vídeo.

Assim sendo, quanto melhor a seleção da CEA, ou seja, quanto mais próxima a CEA escolhida estiver do estilo de aprendizagem real do estudante, maior a probabilidade



**Figura 1. Ciclo de iterações de acordo com a abordagem proposta por DORÇA(2012)**

de assimilação do conteúdo apresentado. Porém, o Estilo de Aprendizagem do estudante é inicialmente desconhecido e o sistema precisa “aprender” quais as características do aluno. Para seleção da CEA, [Dorça et al. 2011] utilizou Cadeia de Markov.

Em seguida, de acordo com a Combinação de Estilo de Aprendizagem, o conteúdo é então ajustado para ser apresentado ao aluno. [Dorça 2012] divide o conteúdo programático em conceitos que devem atingir seis Níveis Cognitivos(NC), considerando 0 a ausência de conhecimento e 5 a assimilação total do conceito. Um mesmo conteúdo programático será apresentado ao aluno até que ele atinja o Nível Cognitivo máximo.

Para avaliar o Nível Cognitivo, é aplicada uma avaliação do desempenho ao aluno (nota) para aquele conteúdo programático atual. Detalhes do cálculo da nota pode ser encontrado em [Dorça 2012]. O autor caracteriza a nota 60 como satisfatória, se o aluno atingiu a nota 60 quer dizer que o objetivo foi atingido e seu Nível Cognitivo é incrementado. Caso contrário, aplica-se um reforço no Modelo do Estudante, mas especificamente no Estilo de Aprendizagem do aluno. Uma atualização no EA é necessária baseando no pressuposto que, se o rendimento foi ruim, a CEA escolhida pode não ser apropriada ao EA daquele aluno. Assim, na iteração seguinte, a CEA selecionada poderá refletir melhor a preferência do aluno.

Este ciclo acontece a cada iteração do usuário com o SAIE. De acordo com os testes aplicados por [Dorça et al. 2012], o aluno terá que aprender 30 conceitos e em cada conceito atingir o nível cognitivo 5, totalizando um mínimo de 360 iterações, considerando que ele apresentou desempenho satisfatório em todas as iterações.

Este trabalho apresenta uma modificação no sistema proposto por [Dorça 2012] para a seleção de Combinação de Estilo de Aprendizagem. O autor propõe o uso de Cadeia de Markov, porém o aluno, dentro de uma dimensão, pode ter um certo grau de pertinência para cada uma das características. A Lógica *Fuzzy* pode, então, ser melhor aplicada nesta situação. A seção 3 apresenta o algoritmo proposto neste trabalho para selecionar uma CEA utilizando conceitos de Lógica *Fuzzy*.

### **3. Desenvolvimento e Detalhes de Implementação**

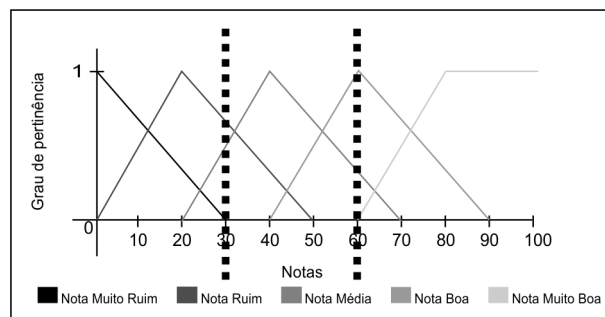
[Dorça et al. 2011] propõe um algoritmo baseado em Cadeia de Markov para selecionar uma Combinação de Estilo de Aprendizagem. São 16 combinações, considerando as 4 dimensões e, para cada dimensão, 2 características ( $2^4$ ), conforme modelo de Felder e Silverman. Neste trabalho, a seleção será substituída por Lógica *Fuzzy* que fará uso do histórico de notas (avaliação de desempenho) para ajustar os parâmetros de seleção de

CEA.

Inicialmente, quando o histórico estiver vazio ou com pouca informação, nas primeiras 32 iterações, as CEA serão selecionadas sequencialmente, permitindo que toda combinação seja utilizada e avaliada por duas vezes. Posteriormente, a seleção de CEA se dará de acordo com o algoritmo *Fuzzy*. Assim, a presente seção apresenta o algoritmo de seleção de CEA baseada na Lógica *Fuzzy*.

### 3.1. Algoritmo de Seleção de CEA utilizando Lógica *Fuzzy*

Para aplicação da Lógica *Fuzzy* é necessário definir o Universo do conjunto, Conjunto Difuso e Grau de Pertinência. Neste contexto, o Universo do conjunto (U) é composto por todas as possíveis notas que uma determinada CEA pode receber, neste caso valores entre 0 e 100. Estas notas podem ser classificadas de acordo com os seguintes conjuntos difusos: Muito Ruim, Ruim, Média, Boa e Muito Boa. Cada nota pertence a um determinado conjunto difuso com um certo grau de pertinência que varia entre 0 e 1. Por exemplo, a nota 60 pode ter grau de pertinência 1 em relação ao conjunto difuso Média, um grau de pertinência 0.6 para o conjunto Boa e grau 0 para os demais conjuntos.



**Figura 2. Funções de Pertinência para os conjuntos difusos: Muito Ruim, Ruim, Média, Boa e Muito Boa**


As funções que definem o grau de pertinência das notas pode ser observado na figura 2. Na figura, nota 0 tem grau de pertinência máximo (1) no conjunto difuso Muito Ruim. Notas acima de 30 tem grau de pertinência mínimo (0) no conjunto difuso Muito Ruim. Neste intervalo o grau de pertinência da nota  $x$  é definido pela reta apresentada na equação (1).

$$p(x) = -\frac{1}{30}x + 1 \quad (1)$$

As demais funções pode ser definidas conforme figura 3.

Uma vez que uma nova nota é obtida, analisa-se seu grau de pertinência nos conjuntos difusos e, assim, é possível fazer um histórico desses graus de pertinência para cada elemento que compõe a CEA: Sensorial, Intuitivo, Visual, Verbal, Ativo, Reflexivo, Sequencial, Global.

Por exemplo, suponhamos a seleção da seguinte CEA: Sensorial, Visual, Reflexivo, Global. Esta CEA, após avaliação de desempenho, resulta numa nota 60. Portanto, calcula-se o grau de pertinência em cada um dos conjuntos difusos, obtendo um valor de



**Figura 3. Função de pertinência dos Conjuntos Difusos - Ruim, Média e Boa**

pertinência para cada um dos 5 conjuntos (Muito Ruim, Ruim, Média, Boa, Muito Boa). Em seguida, atualiza-se o histórico dos elementos contidos na CEA (Sensorial, Visual, Reflexivo, Global). Este histórico armazena as médias obtidas de cada conjunto difuso. A tabela 1 apresenta um exemplo deste histórico para a dimensão Percepção.

Dados as informações contidas no histórico, a seleção da CEA parte do pressuposto que uma Combinação de Estilo de Aprendizagem será selecionada se suas médias de notas ruins sejam mais baixas possíveis e suas médias de notas boas sejam mais altas possíveis.

Assim sendo, a regras de Defuzzificação é definida da seguinte forma:

1. Definir um peso para cada Conjunto Difuso de forma que Estilos de Aprendizagem com menor média em notas ruins e maior média em notas boas tenham maiores probabilidades de serem selecionadas.<sup>1</sup>
2. Para cada dimensão do modelo, verificar o estilo de aprendizagem com menor média no conjuntos difusos Muito Ruim e Ruim e maior média para os conjuntos difusos Média, Boa, Muito Boa.
3. Atribuir uma recompensa para cada um desses conjuntos difusos que reflita a sua importância durante o processo de seleção de CEA.

Por exemplo, consideremos a dimensão Percepção. Suponhamos que o histórico das notas obtidas resulte nos seguintes valores médios de grau de pertinência, conforme tabela 1:

Conjunto Difuso	Muito Ruim	Ruim	Média	Boa	Muito Boa
Média Ativo	0.4	0.4	0.5	0.4	0.3
Média Reflexivo	0.6	0.2	0.4	0.3	0.4

**Tabela 1. Histórico de médias de Grau de Pertinência**

A atribuição das recompensas são feitas obedecendo o seguinte princípio:

- Recebe recompensa o estilo que apresentar a menor média: Muito Ruim e Ruim.
- Recebe recompensa o estilo que apresentar a maior média: Média, Boa e Muito Boa.

<sup>1</sup>O conjunto difuso Média está incluído no conjunto de notas boas. Os testes realizados apontaram para essa estratégia.

Considerando a recompensa de cada Conjunto Difuso como: Muito Ruim = 0.2, Ruim = 0.1, Média = 0.1, Boa = 0.1, Muito Boa = 0.4. Então, verifica-se na tabela, na coluna Muito Ruim, qual estilo apresenta menor média. Isso indica que este estilo, em geral, tem um menor grau de pertinência neste conjunto. O mesmo procedimento é analisado na coluna Ruim. Porém, nas demais colunas, Média, Boa e Muito Boa, o procedimento é contrário e observa-se o estilo que apresenta maior média. Isso indica que este estilo, na média, tem um maior grau de pertinência neste conjunto.

Assim sendo, o estilo de aprendizagem Ativo apresenta menor valor do conjunto Muito Ruim, logo, à recompensa adiciona-se o valor 0.2. Apresenta maior valor ao conjunto Ruim, neste caso não recebe a recompensa. Apresenta maior valor na coluna Média, adicionando 0.1 ao valor da recompensa, maior valor na coluna Boa, adicionando 0.1 à recompensa e pior valor na coluna Muito Boa não incrementando a recompensa. Ao término, obtém-se a seguinte valor de recompensa: Ativo =  $0.2 + 0.1 + 0.1 = 0.4$ . O mesmo processo é realizado para o estilo de aprendizagem Reflexivo, obtendo o seguinte valor de recompensa:  $0.1 + 0.4 = 0.5$ .

De acordo com as somas das recompensas o estilo de aprendizagem selecionado para compor a próxima CEA na dimensão de Percepção será “Reflexivo”. O mesmo procedimento é aplicado às outras 3 dimensões.

#### 4. Testes e Análise dos Resultados Obtidos

Os testes foram realizados utilizando a carga de 60 conceitos e cada conceito deve atingir o NC=5, como é proposto por [Dorça 2012]. Esta seção apresenta uma comparação do algoritmo proposto por [Dorça 2012] utilizando Cadeia de Markov para seleção de CEA's, com o algoritmo proposto no qual se aplica Lógica Fuzzy para o mesmo fim.

Ambos algoritmos foram avaliados considerando duas métricas: número de notas abaixo de 60 que foram obtidas (define um desempenho insatisfatório) e a média das notas obtidas durante as iterações do algoritmo. Um dos parâmetros de entrada do algoritmo é o estilo de aprendizagem real do estudante. Este estilo é utilizado para auxiliar o cálculo do reforço do aluno e o cálculo da nota, conforme apresentado por [Dorça et al. 2012]. De acordo com este estilo de aprendizagem real, o algoritmo pode apresentar um melhor ou pior desempenho. Assim, ambos os métodos comparados, proposto por [Dorça 2012] e o proposto neste trabalho baseado em Lógica *Fuzzy*, foram executados 16 vezes, possibilitando avaliar todas as 16 combinações diferentes de estilos de aprendizagem. Por fim, para avaliar a média de desempenho desses algoritmos, cada uma dessas 16 combinações o algoritmo foi executado 30 vezes de forma independente para manter a consistência dos dados obtidos e uma melhor análise estatística. Resumindo, o número de amostras avaliadas foram:  $16 \times 30 = 480$  amostras para cada algoritmo.

Para cada métrica foi aplicado o mesmo teste estatístico, buscando encontrar as diferenças significativas entre os algoritmos. Para cada métrica, a hipótese nula indica a ausência de diferença entre os dois algoritmos avaliados: Dorça (1) e Fuzzy (2), contra sua hipótese alternativa. Dessa forma, deseja-se avaliar se a média entre os algoritmos são iguais, ou seja, a hipótese nula é:  $H_0 = \mu_1 = \mu_2$

Para a análise dos experimentos foi considerado um número de significância de 95% o que corresponde a um valor de  $\alpha$  igual a 0.05. Para evitar suposições de que os

dados apresentam uma distribuição normal, foi utilizado o teste de Wilcoxon de Postos com Sinal ou Wilcoxon *signed-rank* com observações pareadas.

Os testes foram executados utilizando recompensas atribuídas da seguinte forma: Muito Ruim = 0.2, Ruim = 0.1, Média = 0.1, Boa = 0.1, Muito Boa = 0.4. O conjunto difuso Média está sendo considerado do mesmo grupo das Boas e Muito Boas, aplicando a recompensa para o Estilo de Aprendizagem que apresentar melhor valor. A tabela 2 apresenta o resultado das amostras analisadas. Na tabela, a primeira coluna indica a CEA de entrada que indica o Estilo de Aprendizagem real do estudante, a segunda e terceira coluna apresentam a média das quantidade de notas menores que 60 obtidas nas 30 execuções dos algoritmos Dorça (1) e Fuzzy(2), respectivamente. As duas últimas colunas apresentam a média das notas obtidas pelos algoritmos Dorça (1) e Fuzzy(2), respectivamente, nas 30 execuções do algoritmo.

CEA	Notas < 60		Média Notas	
	Dorça(1)	Fuzzy(2)	Dorça(1)	Fuzzy(2)
A - I - Ve - Seq	28.33	<b>11.30</b>	77.41	<b>81.26</b>
A - I - Vi - Seq	151.90	<b>10.83</b>	69.98	<b>81.31</b>
A - S - Ve - G	26.30	<b>10.07</b>	77.61	<b>81.40</b>
A - S - Vi - G	150.13	<b>9.47</b>	70.21	<b>81.22</b>
A - S - Ve - Seq	152.07	<b>10.60</b>	70.09	<b>81.26</b>
A - S - Vi - Seq	22.87	<b>9.17</b>	77.58	<b>81.22</b>
R - I - Ve - G	21.73	<b>10.77</b>	78.25	<b>81.28</b>
R - I - Vi - G	155.37	<b>10.37</b>	69.79	<b>81.25</b>
R - I - Ve - Seq	152.80	<b>11.17</b>	70.06	<b>81.23</b>
R - S - Vi - Seq	<b>7.87</b>	10.87	<b>86.10</b>	81.32
A - I - Ve - G	14.67	<b>9.37</b>	<b>87.00</b>	81.11
R - S - Ve - Seq	25.40	<b>10.50</b>	<b>77.60</b>	72.19
R - S - Vi - G	23.17	<b>9.93</b>	78.06	<b>81.20</b>
R - S - Ve - G	154.93	<b>10.00</b>	69.86	<b>81.22</b>
R - I - Vi - Seq	31.53	<b>10.53</b>	76.99	<b>81.20</b>
A - I - Vi - G	34.90	<b>10.33</b>	77.23	<b>81.34</b>

**Tabela 2. Número de notas abaixo de 60 e média das notas obtidas pelos algoritmos Dorça (1) e Fuzzy(1) - Média das 30 execuções.**

Na tabela 2 é possível verificar a superioridade do algoritmo proposto devido à sua baixa variabilidade nos resultados e ao melhor desempenho do algoritmo em ambas métricas analisadas. O algoritmo proposto se mostrou bastante estável independente do estilo de aprendizagem real do estudante.

Em relação à quantidade de notas insatisfatórias (abaixo de 60), em apenas uma das entradas o algoritmo proposto apresenta pior resultado. A superioridade do algoritmo proposto também pode ser observado ao aplicar o teste de Wilcoxon com observações pareadas, no qual obteve-se um p-valor igual à  $6.104e - 05$ , abaixo de 0.05, rejeitando a hipótese nula, ou seja, comprovando a existência de diferenças significativas entre os métodos avaliados.

Ao analisar a média das notas obtidas nas 30 execuções do algoritmo, o algoritmo



proposto também apresenta baixa variabilidade nos resultados. Em três situações o algoritmo proposto apresenta pior resultado, nos outras situações o algoritmo baseado em Lógica *Fuzzy* apresenta melhor média de notas, ou seja, aluno apresenta melhor aprendizagem. O teste de Wilcoxon também aponta para rejeição da hipótese nula, no qual pode-se comprovar a presença de diferenças estatisticamente significativa entre ambos algoritmos.

## 5. Conclusões

O objetivo principal deste trabalho foi otimizar a seleção de conteúdos a serem apresentados à cada aluno de uma forma personalizada. Através de adaptação destes conteúdos baseando em Combinações de Estilo de Aprendizagem (CEA's), incentivado pelo trabalho desenvolvido por Dorça (2012).

Essa otimização teve seu ponto principal no Modelo Pedagógico(MP), onde através de cadeias de Markov, as CEA's eram selecionadas estocasticamente. Com a nova proposta essas CEA's passaram a ser selecionadas por um algoritmo baseado em Lógica *Fuzzy*.

Os testes foram comparados com a proposta central de Dorça (2012) e, através dos resultados pode-se constatar a validade da proposta como foi apresentado na Seção 4, onde a seleção proposta utilizando Lógica *Fuzzy* atingiram o objetivo de assimilação dos conceitos com mais eficiência que a abordagem da literatura.

## Referências

- Allport, G. W. (1937). *Personality: A psychological interpretation*. Holt and Co., New York, NY, USA.
- Brusilovsky, P., Schwarz, E., and Weber, G. (1996). ELM-ART: An intelligent tutoring system on World Wide Web. In *Intelligent tutoring systems*, pages 261–269.
- Carvalho, V. C. D., Dorc, F. a., Cattelan, R. G., and Computac, F. D. (2014). Uma Abordagem para Recomendacao Automática e Dinâmica de Objetos de Aprendizagem Baseada em Estilos de Aprendizagem. (Cbie):1188–1197.
- Cavellucci, L. C. B. (2005). Estilos de aprendizagem: em busca das diferenças individuais. *Curso de Especialização em Instrucional Design*, page 33.
- de Almeida, K. R. (2010). Descrição e análise de diferentes estilos de aprendizagem. *Revista Interlocução*, 3(3).
- de Oliveira, C. C., da Costa, J. W., and Moreira, M. (2001). *Ambientes informatizados de aprendizagem: produção e avaliação de software educativo*. Papirus.
- Dorça, F. A. (2012). *Uma Abordagem Estocástica Baseada em Aprendizagem por Reforço para Modelagem Automática e Dinâmica de Estilos de Aprendizagem de Estudantes em Sistemas Adaptativos e Inteligentes para Educação a Distância*. PhD thesis, Universidade de Uberlândia.
- Dorça, F. A., Lima, L. V., Fernandes, M. A., and Lopes, C. R. (2011). Detecção e Correção Automática de Estilos de Aprendizagem em Sistemas Adaptativos para Educação. *Revista de Informática Teórica e Aplicada*, 18(2).

- Dorça, F. a., Lima, L. V., Fernandes, M. a., and Lopes, C. R. (2012). Avaliação de Políticas de Aprendizagem por Reforço para Modelagem Automática e Dinâmica de Estilos de Aprendizagem : Uma Análise Experimental. *Anais do 23º Simpósio Brasileiro de Informática na Educação (SBIE 2012)*, 9(Sbie):26–30.
- dos Santos, E. O. (2002). Ambientes virtuais de aprendizagem: por autorias livres, plurais e gratuitas. *Educação e Contemporaneidade*, 11(18):424.
- Felder, R. and Silverman, L. (1988). Learning and teaching styles in engineering education. *Engineering education*, 78(June):674–681.
- Graf, S. (2009). Advanced adaptivity in learning management systems by considering learning styles. *Proceedings of the 2009 IEEE/WIC/ACM International . . .*, 3(December 2007):235–238.
- Iglesias, A., Martinez, P., Aler, R., and Fernandez, F. (2009). Learning teaching strategies in an adaptive and intelligent educational system through reinforcement learning. *Applied Intelligence*, 31(1):89–106.
- Jung, C. G. (2012). *Tipos psicológicos*, volume 6. Editora Vozes Limitada.
- Kolb, D. A. (1984). *Experimental learning: Experience as the source of learning and development*. Prentice Hall, New Jersey.
- Moore, J. L., Dickson-Deane, C., and Galyen, K. (2011). E-Learning, online learning, and distance learning environments: Are they the same? *Internet and Higher Education*, 14(2):129–135.
- Pimentel, A. (2007). A teoria da aprendizagem experiencial como alicerce de estudos sobre desenvolvimento profissional. *Estudos de psicologia*, 12(2):159–168.
- SANCHO, J. M. and Hernández, F. (2006). De tecnologias da informação e comunicação a recursos educativos. *Tecnologias para transformar a educação. Porto Alegre: Art-med*, pages 15–41.
- Senra, C. M. S. (2009). *Os Estilos de Aprendizagem de Felder a partir de Jung*. Dissertação, Centro Federal de Educação de Minas Gerais.
- Type, T. M.-b., MbtI, I., and Briggs, I. (1985). Myers-Briggs Type Indicator (MBTI). *New York*, 60:2–5.