

# Uma Nova Abordagem para Aplicação de Reforço em Sistemas Automáticos e Adaptativos de Detecção de Estilos de Aprendizagem

Samuel Henrique Falci<sup>1</sup>, Alessandro Vivas<sup>1</sup>, Luciana Assis<sup>1</sup>, Cristiano Pitangui<sup>2</sup>

<sup>1</sup>PPGED - UFVJM  
Diamantina, MG, Brasil

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

<sup>2</sup>DTECH - UFSJ  
Ouro Branco, MG, Brasil

pitangui.cristiano@gmail.com

**Abstract.** *Techniques for Automatic Detection of Learning Styles have been addressed to improve the performance of students who attend Distance Education. The importance of this Automatic Detection lays in the possibility of creating Virtual Learning Environments with automatic adaptation to the students' profiles, thus providing better experiences and greater efficiency in the learning process. In order to evaluate techniques that aim to detect (and adjust) the Learning Styles from students, this work uses a well-known simulator found in the literature. In this system, combinations of Learning Styles are selected and then the chosen combination is evaluated (simulating its performance) according to the student's actual learning style. If the performance is unsatisfactory, then a reinforcement is applied in order to guide the system to find the student's actual Learning Style. The objective of this work is to improve the reinforcement applied in this simulator. Results show that there are statistically significant differences and a superiority of the proposed method in relation to the prevailing literature approach.*

**Resumo.** *Técnicas de detecção automática de estilos de aprendizagem vem sido abordadas para melhorar a experiência dos alunos que optam pelo ensino à distância. A importância dessa detecção automática se da pela possibilidade de criar ambientes virtuais de aprendizagem com adaptação automática aos perfis de cada aluno, proporcionando assim melhores experiências e maior eficiência no processo de aprendizado. Para avaliar técnicas de detecção e ajuste de estilo de aprendizagem, este trabalho faz uso de um simulador encontrado na literatura. Neste sistema, são selecionadas combinações de estilo de aprendizagem e, então, esta combinação é avaliada de acordo com o estilo de aprendizagem real do aluno, simulando o seu desempenho. Se este desempenho for insatisfatório aplica-se então um reforço, para que o sistema convirja para o estilo de aprendizagem real. O objetivo deste trabalho consiste em aprimorar a forma como o reforço será aplicado neste simulador. Os resultados encontrados demonstraram que existem diferenças estatisticamente significativas e uma superioridade do algoritmo proposto em relação a abordagem da literatura.*

## 1. Introdução

Apesar de vários autores definirem Estilo de Aprendizagem (EA) de maneira diferente, a grande maioria concorda que o conceito está ligado à forma como o indivíduo recebe, processa, guarda e organiza a informação, de acordo com a sua percepção [Cerqueira 2000]. Sendo assim, assume-se que cada indivíduo possui uma maneira diferente lidar com uma informação que lhe é passada.

Felder & Silverman [Felder and Silverman 1988] afirmam que os alunos adquirem e processam informações com base em seus EAs. Baseado nessa afirmativa, vários trabalhos foram desenvolvidos na tentativa de detectar os EAs de cada indivíduo para apresentar informações condizentes com a forma que cada um deles lida com o aprendizado.

A maneira tradicional de identificar os EAs é através de um questionário que os alunos são convidados a preencher. Embora estes instrumentos apresentem boa confiabilidade e validade, eles foram submetidos a algumas críticas [Feldman et al. 2015].

Em razão dos problemas relacionados à aplicação de questionários diversas abordagens foram propostas. Alguns trabalhos da literatura fazem a detecção automática do estilo de aprendizagem do aluno através da forma como este interage com o ambiente virtual de aprendizagem [García et al. 2007, Graf et al. 2008, Sena et al. 2016].

Em outra abordagem, Fabiano Dorça [Dorça 2012], utiliza de técnicas de simulação computacional para representar o comportamento do estudante em um sistema de tutoria inteligente, com o objetivo de avaliar técnicas de detecção automática de estilo de aprendizagem. Neste sistema, são selecionadas combinações de estilo de aprendizagem e, então, esta combinação é avaliada de acordo com o estilo de aprendizado real do aluno, simulando o seu desempenho. Se este desempenho for insatisfatório aplica-se então um reforço, para que o sistema convirja para o estilo de aprendizado real.

Alguns problemas podem ocorrer durante o processo de detecção, pois o comportamento real do estudante possui um fator aleatório. Muitas vezes o sistema irá apresentar o conteúdo correto, mas por motivos adversos e inerentes ao EA, o estudante pode ter um desempenho ruim, ocasionando em uma aplicação indevida do reforço.

Assim sendo, este trabalho propõe aprimorar técnicas para detecção automática de estilos de aprendizagem baseadas no simulador proposto por Dorça, aprimorando o critério de aplicação do reforço.

## 2. Trabalhos Correlatos

Nesta seção serão abordadas técnicas utilizadas em trabalhos de detecção automática de estilos de aprendizagem. Um grande percentual das abordagens de detecção automática utilizam o modelo de Felder & Silverman, denominado Felder e Silverman Learning System Model (FSLSM) [Kinshuk et al. 2009]. Segundo Kinshuk [Kinshuk et al. 2009], o modelo de quatro dimensões de Felder & Silverman combina os principais modelos de estilos de aprendizagem, como os de Kolb [Kolb 1984], [Pask 1976], [Myers 1962].

### 2.1. Detecção por Lógica Fuzzy

A Lógica Fuzzy não é necessariamente uma técnica de IA para a detecção de estilos de aprendizagem, mas uma ferramenta utilizada conjuntamente com as técnicas de IA para

tornar a detecção mais efetiva.

Modelos tradicionais de lógica, como a booleana, conseguem representar, resolver dados e fatos determinísticos, equações matemáticas e físicas. Quando se lida com a incerteza, estes modelos não conseguem representá-la. A lógica Fuzzy fornece um modo de raciocínio qualitativo, o que está mais perto de tomada de decisão humana [Stathacopoulou et al. 2005].

Stathacopoulou [Stathacopoulou et al. 2005] cita ainda que a Lógica Fuzzy aliada a outras técnicas de IA, como as Redes Neurais, é capaz de lidar com a incerteza melhor do que outros métodos de computação. Um exemplo de aplicação de Lógica Fuzzy pode ser ilustrado ao se questionar a altura de um indivíduo que mede 1,70 metros. Ao se fazer uma pesquisa rápida, pode-se perceber que alguns entrevistados irão afirmar que esta é uma estatura mediana, enquanto outros dirão que é uma estatura alta. Com os modelos tradicionais de lógica, porém, não é possível qualificar uma estatura mediana, já que ela não representa nem uma estatura alta nem uma estatura baixa, tornando este tipo de modelo não indicado para pesquisas onde se trabalha com a incerteza.

Por estes motivos, vários trabalhos de detecção automática de estilos de aprendizagem utilizam as técnicas de IA juntamente com a Lógica Fuzzy, pois dessa maneira o comportamento humano é mais facilmente demonstrado computacionalmente.

Regina Stathacopoulou [Stathacopoulou et al. 2005] e Demetrius A Georgiou [Georgiou and Makry 2004], dentre outros utilizaram a Lógica Fuzzy juntamente com Redes Neurais para inferir o estilo de aprendizagem de estudantes.

As Redes Bayesianas, Árvores de Decisão e interação do usuário com o sistema também são comumente utilizadas juntamente à Lógica Fuzzy para inferir o estilo de aprendizagem dos alunos [Crockett et al. 2011], [García et al. 2005], [García et al. 2007], [Özpolat and Akar 2009]. Algoritmos genéticos como o Colônia de Formigas também já foram utilizados conjuntamente à Lógica Fuzzy para detecção [Basheer et al. 2013].

Em seu trabalho, Rodrigues [Rodrigues et al. 2016] utiliza a Lógica Fuzzy para selecionar a melhor

Além da detecção automática, a Lógica Fuzzy é frequentemente utilizada em sistemas de hipermídia adaptativa para a seleção de conteúdo a ser apresentado ao aluno que interage com a plataforma, levando em consideração o seu estilo de aprendizagem [Cabada et al. 2009].

## **2.2. Detecção por Indicações de Comportamento do Estudante**

Uma abordagem que não utiliza necessariamente técnicas de IA, mas que apresentou resultados satisfatórios para detecção automática de estilos de aprendizado, foi publicada em 2008 por Sabine Graf, Kinshuk e Tzu-Chien Liu [Graf et al. 2008].

Esta abordagem utilizou o modelo de Felder & Silverman para identificar os estilos de aprendizagem dos alunos de plataformas de ensino à distância já existentes na época, como o moodle. As características de cada estilo de aprendizagem apresentado no FLSM eram levadas em conta para interpretar a interação do estudante com a plataforma. Por exemplo, se um aluno frequentemente visita a seção de exercícios, podemos

inferir que o aluno tem preferência a um estilo de aprendizagem Ativo.

As inferências foram classificadas em quatro categorias: 3 indica que o comportamento do aluno dá uma forte indicação para o respectivo estilo de aprendizagem; 2 indica que o comportamento do aluno é média e, portanto, não fornece uma dica específica; 1 indica que o comportamento do estudante está em desacordo com o respectivo estilo de aprendizagem e 0 indica que nenhuma informação sobre o comportamento do aluno está disponível. Os valores das inferências foram calculados utilizando parâmetros, como por exemplo o tempo em que o aluno permanecia em alguma seção específica da plataforma ou se ele fazia avaliações com frequência, dentre outros.

As inferências para cada dimensão do FLSM eram analisadas e uma média era calculada definindo a preferência do aluno por um determinado estilo de aprendizagem. A fim de avaliar a abordagem proposta, um estudo com 127 estudantes foi realizado, comparando os resultados da abordagem automática com os do questionário estilo de aprendizagem de Felder & Soloman [Soloman and Felder 2012]. Os resultados obtidos variam de 73,33 % a 79,33 % , o que demonstra uma elevada precisão da abordagem proposta para todas as dimensões do FLSM, e, portanto, demonstram que o método proposto foi adequado para identificar os estilos de aprendizagem.

### 2.3. Árvores de Decisão

Árvores de Decisão são ferramentas para dividir uma decisão complexa em uma união de várias decisões mais simples [Safavian and Landgrebe 1991].

Árvores de Decisão foram utilizadas com êxito em diversas áreas, tais como classificação de sinal de radar, caráter reconhecimento, sensoriamento remoto, diagnóstico médico, sistemas especialistas e reconhecimento de fala. Na detecção automática de estilos de aprendizagem, as árvores de decisão ajudam a inferir o estilo de aprendizagem de um aluno com base em informações sobre o mesmo como a sua interação com o sistema, notas em exames, dentre outros, como exemplificado na Figura 1

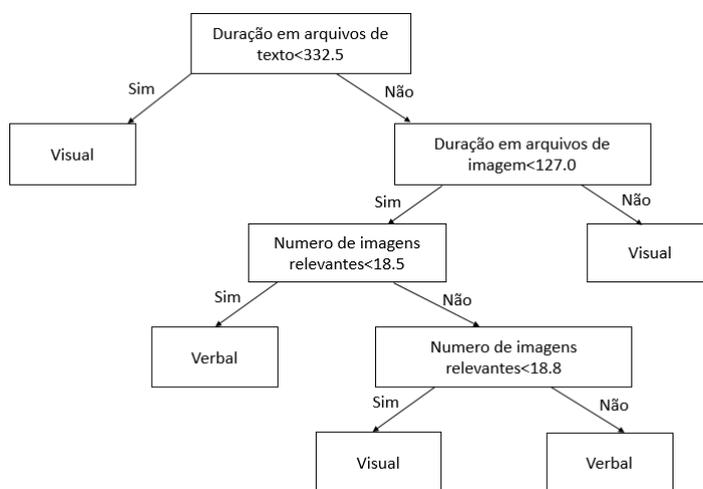


Figura 1. Árvore de decisão Adaptado de - [Feldman et al. 2015]

Alguns exemplos de abordagens que utilizaram Árvores de Decisão para detecção automática de estilos de aprendizagem são citadas nos trabalhos de [Crockett et al. 2011], [Ahmad and Shamsuddin 2010], [Özpolat and Akar 2009].

## 2.4. Redes Bayesianas

Segundo Feldman [Feldman et al. 2015], as Redes Bayesianas provavelmente constituem o método de detecção automática de estilos de aprendizagem mais utilizado na literatura. Alguns exemplos de abordagens que utilizaram Redes Bayesianas para detecção automática de estilos de aprendizagem são citadas nos trabalhos de [Alkhuraji et al. 2011]; [Carmona et al. 2008]; [García et al. 2007]; [Ahmad and Shamsuddin 2010]; [Kelly and Tangney 2006].

Em seu trabalho Garcia [García et al. 2005] define que uma Rede Bayesiana (RB) é uma representação gráfica do conhecimento incerto. A RB nos permite descobrir novos conhecimentos através da combinação de conhecimento de domínio perito com dados estatísticos. É um grafo direcionado acíclico cujos nós são rotulados por variáveis aleatórias. Em aplicações de agente, variáveis aleatórias representam características de um domínio de interesse. Na abordagem de García, as variáveis aleatórias representam as diferentes dimensões do FSLSM, estilos e fatores que determinam cada um dos aspectos de cada estilo de aprendizagem. Nesta abordagem também foi utilizada a interação do aluno com uma plataforma de educação à distância e uma RB foi usada para tratar os dados dessa interação e inferir o estilo de aprendizagem do estudante.

Garcia utilizou apenas 3 dimensões do FSLSM em seu trabalho. A dimensão Entrada foi descartada, pois vídeos e simulações não foram considerados pelos autores como parte dos cursos Web. Além disso, a dimensão organização também foi descartada, pois foi demonstrado que a maioria dos estudantes de engenharia eram indutivos. Sendo assim, no trabalho foi utilizado o FSLSM de 5 dimensões, mas apenas 3 delas foram levadas em consideração. A RB gerada nesta abordagem é representada na Figura 2.

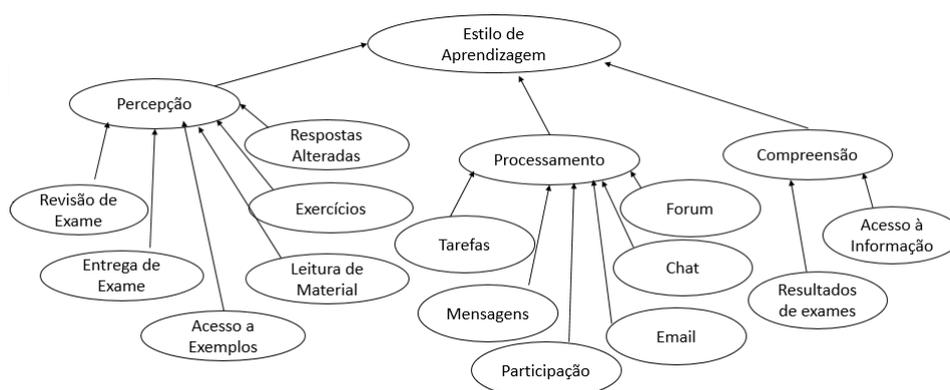


Figura 2. Rede Bayesiana proposta por García Adaptado de - [Feldman et al. 2015]

Dois passos são necessários para construir uma RB. Em primeiro lugar, a estrutura da rede deve ser definida (modelo qualitativo). Em seguida, os parâmetros da rede devem ser definidos (modelo quantitativo) [Brusilovsky and Millán 2007]. A Figura 2 mostra um exemplo da estrutura de uma RB, onde nós folha representam comportamento observável

do aluno e nós raiz representam os estilos de aprendizagem para inferir. A estrutura da rede pode ser induzida a partir de dados, pode ser definida por um especialista ou alguém com conhecimento profundo do domínio [Feldman et al. 2015].

## 2.5. Redes Neurais

Assim como as RB, as Redes Neurais (RN) são largamente utilizadas para a detecção automática de estilos de aprendizagem e, constantemente, a Lógica Fuzzy é associada à esta técnica neste contexto. As redes neurais são modelos computacionais com base na estrutura neural biológica do cérebro. Grosso modo, uma rede neural é um conjunto de unidades conectadas de entrada / saída, em que cada ligação tem um peso associado a este conjunto [Han and Kamber 2006].

As RN são constituídas de 3 estruturas: a estrutura de entrada, que possui neurônios que recebem as informações do meio externo; a estrutura oculta que recebe as informações da estrutura de entrada, faz o processamento e envia o sinal para a estrutura de saída, que por sua vez retorna os dados para o meio externo Figura 3.

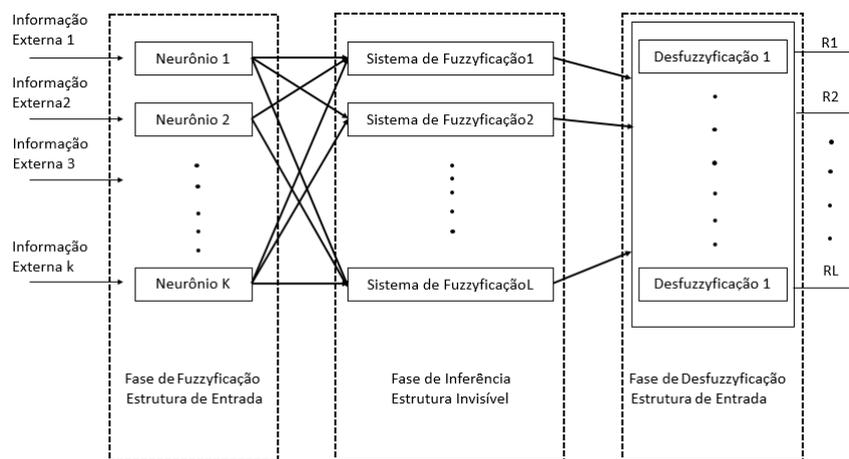


Figura 3. Rede Neural Adaptado de - [Georgiou and Makry 2004]

Em uma rede neural, para detectar o estilo de aprendizagem dos estudantes as estruturas são divididas por uma camada de entrada com neurônios para o comportamento rastreado de cada estudante, uma camada oculta com neurônios que fornecem a capacidade de processamento da rede e uma camada de saída com um neurônio para cada estilo de aprendizagem detectado. No entanto, a definição do número de neurônios das camadas ocultas é uma tarefa complexa e, embora existam algumas regras empíricas para determinar o número desejável de neurônios, não existem regras teóricas para determinar o número ideal [Villaverde et al. 2006]. Assim, todos os trabalhos pesquisados definem este parâmetro arquitetônico através da experimentação de tentativa e erro.

## 2.6. Aprendizagem por reforço

Alguns trabalhos apresentam abordagens não determinísticas para detecção automática de estilos de aprendizagem. Tal abordagem, apesar de utilizar técnicas semelhantes a outras desenvolvidas, utiliza de conceitos para aproximar as simulações computacionais à realidade [Dorça 2012, Gonçalves et al. 2016].

Para desenvolver o sistema de detecção, Dorça utilizou o modelo de Felder & Silverman [Felder and Silverman 1988] para determinar os estilos de aprendizagem presentes em um aluno hipotético simulado computacionalmente.

O sistema de detecção de Dorça é dividido então em 3 partes principais: o modelo do estudante (ME), o módulo pedagógico (MP) e o componente de modelagem do estudante (CME).

### 2.6.1. O Modelo do Estudante

No Modelo do Estudante são armazenadas informações a respeito do aprendiz simulado no sistema, tais como: estilo de aprendizagem, os objetivos de aprendizagem e o estado cognitivo.

Os objetivos de aprendizagem são um conjunto de conceitos que o aluno deverá aprender ao longo do curso. Durante este processo de assimilação, para cada objetivo de aprendizagem, o aluno deve passar por cinco níveis cognitivos (NC), definidos de acordo com a Taxonomia de Bloom [Krathwohl 2002]. Para que um estudante aprenda algum conceito é necessário que ele atinja o nível de conhecimento 5 a respeito deste conceito. O EA armazenado no ME, denominado por Dorça como EA probabilístico, será atualizado durante o processo, com o objetivo de refletir o EA real do aluno.

A Tabela 1 apresenta um exemplo de representação do ME. Neste modelo o EA probabilístico baseia-se nas dimensões do FSLSM.

Tabela 1. Modelo Estudante

EA Probabilísticos							
Processamento		Percepção		Entrada		Organização	
Ativo	Reflexivo	Sensitivo	Intuitivo	Visual	Verbal	Sequencial	Global
0,35	0,65	0,17	0,83	0,89	0,11	0,84	0,16
Objetivos de Aprendizagem e Estado Cognitivo							
$OA = \{(C_0, 5) \dots (C_{n-1}, 5)\}$ $EC = \{(C_0, -1) \dots (C_{n-1}, -1)\}$							

### 2.6.2. Módulo Pedagógico

O módulo pedagógico é responsável por selecionar, a cada iteração, uma nova Combinação de Estilos de Aprendizagem (CEA).

Conforme apresentado na Tabela 1, o estilo de aprendizagem do aluno é organizado em quatro dimensões: processamento, Percepção, Entrada e Organização. Para cada uma destas dimensões o aluno apresenta uma preferencia de aprendizagem, por exemplo, na dimensão processamento, o aluno pode ser Ativo ou Reflexivo, desta forma são possíveis 16 combinações diferentes de estilos de aprendizagem. Logo, o módulo pedagógico irá selecionar uma das 16 possíveis CEAs a cada iteração. Esta seleção é feita através da utilização de Cadeias de Markov [Dorça 2012].

Outros trabalhos utilizam outros métodos para a seleção da CEA, como Lógica Fuzzy [Rodrigues et al. 2016].

### 2.6.3. Componente de Modelagem do Estudante

O componente de modelagem do estudante é responsável por atualizar o EA probabilístico, os objetivos de aprendizagem e os estados cognitivos armazenados em ME.

Uma vez selecionada uma CEA o algoritmo simula o desempenho do aluno (a nota de uma avaliação) levando em consideração o EA real e o EA selecionado (CEA). Se o desempenho for insatisfatório, é aplicado um reforço ao EA probabilístico utilizando técnicas de aprendizado por reforço, em específico, o algoritmo Q-Learning.

Segundo Sutton e Barto [Sutton and Barto 1998], a aprendizagem por reforço AR é uma técnica da IA que permite que um agente aprenda a partir da sua interação com o ambiente no qual ele está inserido. A aprendizagem se dá através do conhecimento sobre o estado do indivíduo no ambiente, das ações efetuadas no ambiente e das mudanças de estado decorrentes das ações. Formalmente, AR utiliza uma estrutura composta de estados, ações e recompensas [Dorça 2012].

Caso o desempenho seja satisfatório (nota  $\geq 60$ ), o NC do aluno é incrementado. Caso o NC atinja o nível 5, o objetivo de aprendizagem também é incrementado.

### 2.6.4. O Funcionamento do Sistema

O sistema inicializa o EA probabilístico, os objetivos de aprendizagem e nível cognitivo. Posteriormente, inicia-se o processo de simulação com a seleção de uma CEA utilizando Cadeias de Markov.

Dada a CEA selecionada o algoritmo calcula o desempenho do aluno levando em consideração o EA real (dado de entrada do sistema) e a CEA selecionada. Além disso considera-se um fator aleatório que reflete fatos adversos e inerentes ao EA.

Segundo Dorça [Dorça 2012], o desempenho do aluno é formulado de acordo com a Equação 1.

$$PFM = 100 - (QPNS \times K \times \beta) \quad (1)$$

QPNS = diferença entre as duas CEAS

K = constante de valor 20

$\beta$  = Numero aleatório de 0 a 1

Caso o desempenho (PFM) calculado seja menor que 60 um reforço é aplicado para cada dimensão da EA probabilístico armazenado no ME, seguindo a regra apresentada na Equação 2.

$$R = \frac{1}{PFM \times DEA} \quad (2)$$

DEA = distância entre os dois estilos de aprendizagem de cada dimensão.

Após a atualização do EA probabilístico, seleciona-se novamente uma CEA utilizando Cadeias de Markov e o sistema repete todas as etapas para esta nova seleção.

Alguns problemas podem ocorrer durante o processo de detecção, pois o desempenho do aluno (PFM) leva em consideração um fator aleatório. Muitas vezes o sistema irá selecionar uma CEA corretamente, mas devido ao fator aleatório, o estudante pode ter um desempenho ruim, ocasionando em uma aplicação indevida do reforço.

A Seção 3 apresenta uma alternativa à decisão de aplicabilidade do reforço minimizando os problemas decorrentes de aplicação indevida do mesmo na abordagem proposta por Dorça.

### **3. Abordagem Proposta**

Alguns problemas podem ocorrer em sistemas de detecção automática de estilos de aprendizagem, pois o comportamento real do estudante possui um fator aleatório. Muitas vezes o sistema irá apresentar o conteúdo correto, mas por motivos adversos e inerentes ao EA, o estudante pode ter uma performance ruim (nota inferior a 60) e o sistema atualizará suas probabilidades incorrendo em uma falha no processo de detecção.

Na tentativa de minimizar os problemas de aprendizagem oriundos de aplicações indevidas de reforço, a abordagem proposta visa analisar um histórico de performances obtidas para cada CEA em cada iteração do sistema. Este histórico é utilizado para calcular a média de performance obtida ao longo da execução do sistema para cada uma das 16 CEAs possíveis.

Em posse das médias de performance de cada uma das CEAs é possível tomar decisões mais precisas na aplicabilidade do reforço, diminuindo, assim, os problemas de aprendizado, mantendo ainda o funcionamento não determinístico do sistema proposto por [Dorça 2012] e a consideração dos fatores aleatórios ao cálculo das performances.

O novo cálculo do reforço a ser aplicado à CEA probabilística se dá através da categorização destes reforços, levando em consideração a média das performances obtidas anteriormente para cada uma das 16 CEAs possíveis. Sendo assim a decisão de aplicabilidade do reforço se dá não somente a performances abaixo de 60%, mas diferentes reforços são aplicados, de acordo com a categoria em que a performance se encaixa.

Para definir as categorias, as médias das performances são analisadas e uma variação é aplicada a esta média. A variação é definida através de valores entre  $media-20$  e  $media+20$ . A partir desta variação as categorias são definidas conforme demonstrado no Algoritmo 1.

---

**Algoritmo 1: CATEGORIZAÇÃO DOS REFORÇOS**

---

```
início
   $V_{min} = M - 20;$ 
   $V_{max} = M + 20;$ 
   $cat1 = R_d * 3;$ 
   $cat2 = R_d * 2;$ 
   $cat3 = R_d;$ 
   $cat4 = R_d * 0.5;$ 
   $cat5 = R_d;$ 
   $cat6 = R_d * 2;$ 
  se  $PFM < 60$  e  $PFM < V_{min}$  então
    |  $R = cat1;$ 
  fim
  se  $PFM < 60$  e  $PFM < V_{max}$  e  $PFM > V_{min}$  então
    |  $R = cat2$ 
  fim
  se  $PFM < 60$  e  $PFM > V_{max}$  então
    |  $R = cat3$ 
  fim
  se  $PFM \geq 60$  e  $PFM < V_{min}$  então
    |  $R = cat4$ 
  fim
  se  $PFM \geq 60$  e  $PFM < V_{max}$  e  $PFM > V_{min}$  então
    |  $R = cat5$ 
  fim
  se  $PFM \geq 60$  e  $PFM > V_{max}$  então
    |  $R = cat6$ 
  fim
fim
```

---

Onde  $M$  representa a média da performance acumulada,  $R_d$ , representa o reforço aplicado pela abordagem de Dorça,  $R$  representa o novo reforço obtido pelo algoritmo de categorização e  $PFM$  representa a performance obtida na atual iteração do sistema.

#### 4. Testes Realizados

Para a validação deste trabalho, testes foram realizados com os mesmos parâmetros utilizados por Dorça em sua abordagem. O ME inicial foi configurado conforme a Tabela 2.

Tabela 2. ME Inicial

EA Probabilísticos							
Processamento		Percepção		Entrada		Organização	
Ativo	Reflexivo	Sensitivo	Intuitivo	Visual	Verbal	Sequencial	Global
0,70	0,30	0,70	0,30	0,70	0,30	0,70	0,30
Objetivos de Aprendizagem e Estado Cognitivo							
$OA = \{(C_0, 5) \dots (C_{59}, 5)\}$							
$EC = \{(C_0, -1) \dots (C_{59}, -1)\}$							

Para uma carga de 60 conceitos, então, em um sistema onde hipoteticamente o estudante nunca obtivesse uma nota ruim, seu funcionamento iria encerrar com 360 iterações pois para cada um dos conceitos são necessárias 6 avaliações, referentes aos estados cognitivos. Todas as iterações, além das 360 ideais, são consideradas problemas de aprendizado.

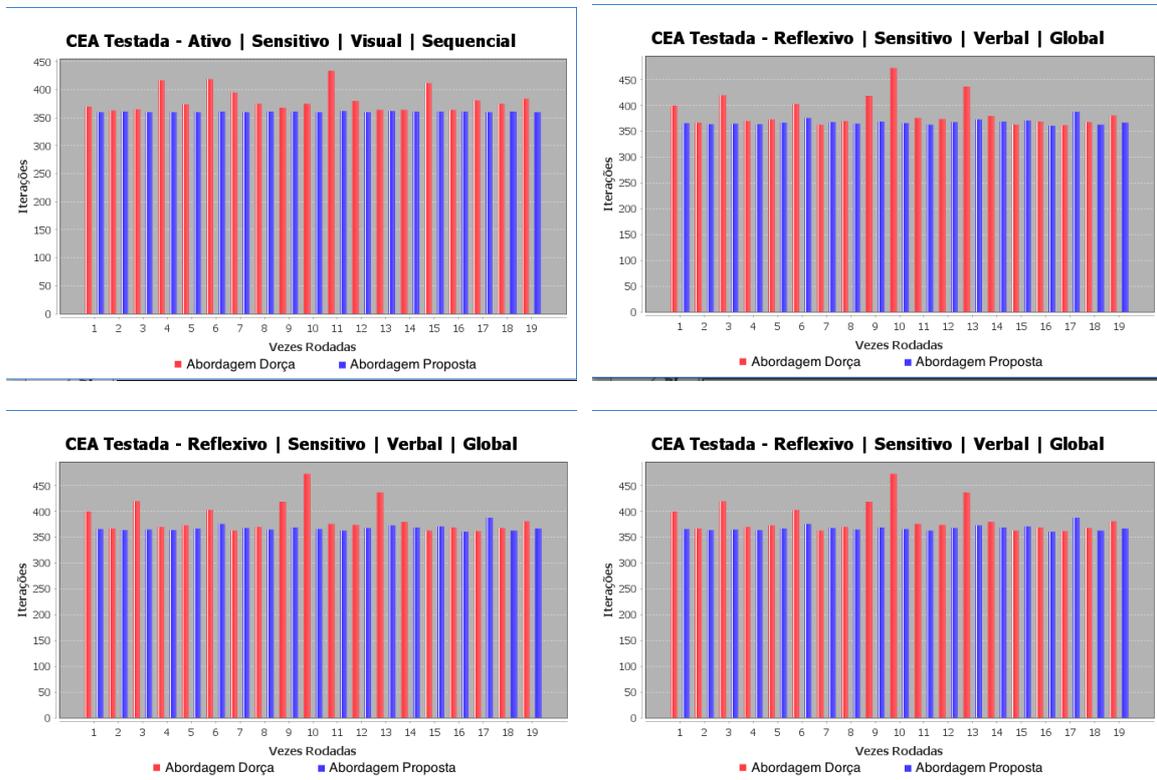
O sistema foi iniciado 30 vezes para validação dos resultados em que todas as 16 possíveis CEAs foram testadas. Os testes executam simultaneamente o sistema proposto por Dorça e a abordagem proposta neste trabalho. Para cada CEA testada 30 execuções foram feitas afim de ter maior precisão na validação desta abordagem. Ao fim das 30 execuções, uma média de iterações foi calculada para cada CEA, assim como o desvio padrão dessas iterações, como pode ser observado na Tabela 3.

Tabela 3. Testes Computacionais

CEA	Média de iterações		Desvio Padrão		Problemas de aprendizagem	
	Abordagem Dorça	Abordagem Proposta	Abordagem Dorça	Abordagem Proposta	Abordagem Dorça	Abordagem Proposta
Ati—Sen—Vis—Seq	378,83	361,20	14,83	1,97	18,83	1,20
Ref—Sen—Vis—Seq	380,80	366,17	21,63	8,37	20,80	6,17
Ati—Int—Vis—Seq	388,00	368,30	27,93	12,41	28,00	8,30
Ref—Int—Vis—Seq	509,03	520,17	11,44	14,35	149,03	160,17
Ati—Sen—Ver—Seq	389,20	365,77	22,84	6,14	29,20	5,77
Ref—Sen—Ver—Seq	519,63	520,93	13,73	15,39	159,63	160,93
Ati—Int—Ver—Seq	513,97	515,13	13,34	15,61	153,97	155,13
Ref—Int—Ver—Seq	391,57	369,77	30,67	7,20	31,57	9,77
Ati—Sen—Vis—Glo	389,90	364,50	25,17	4,82	29,90	4,50
Ref—Sen—Vis—Glo	515,20	518,90	14,57	17,97	155,20	158,90
Ati—Int—Vis—Glo	512,77	521,03	13,63	14,81	152,77	161,03
Ref—Int—Vis—Glo	395,30	367,80	29,66	6,65	35,30	7,80
Ati—Sen—Ver—Glo	514,43	524,50	14,65	13,60	154,43	164,50
Ref—Sen—Ver—Glo	390,10	368,07	31,68	6,12	30,10	8,07
Ati—Int—Ver—Glo	383,30	368,27	21,70	7,99	23,30	8,27
Ref—Int—Ver—Glo	380,30	364,37	20,62	3,08	20,30	4,37

Como pode-se perceber a hipótese de que um reforço aplicado indevidamente desviava o sistema negativamente pode ser comprovada ao analisar a Tabela 3 e a Figura 4.

Figura 4. Gráficos dos testes computacionais



Na Figura 4, pode-se novamente comprovar a hipótese dos reforços aplicados indevidamente, ao se analisar os picos de iterações indevidas na abordagem de Dorça. Por outro lado, com a categorização dos reforços o sistema se mostra mais estável, sem desvios que levam à maiores números de problemas de aprendizagem.

## 5. Considerações Finais

Neste trabalho foi feito um planejamento experimental para avaliação dos resultados obtidos pelos algoritmos apresentado por Dorça [Dorça 2012] e o algoritmo proposto neste trabalho. Com o planejamento do experimento e a análise estatística dos dados obtidos é possível averiguar se há diferenças significativas entre o desempenho dos algoritmos e estimar o tamanho dessas diferenças.

Para cada algoritmo foram realizadas 30 replicações para cada CEAs, que representa o estilo de aprendizagem real do estudante, que é um parâmetro do algoritmo. Os testes foram executados de maneira independente e foram avaliadas as seguintes medidas de qualidade: número de iterações e problemas de aprendizagem.

Para cada métrica considerada, a hipótese nula indica a ausência de diferença entre os dois algoritmos avaliados: Dorça (1) e Proposto (2), contra sua hipótese alternativa.

Para evitar suposições de que os dados apresentam uma distribuição normal, é utilizado o teste Wilcoxon de Postos com Sinal ou *Wilcoxon signed-rank* com observações pareadas [Montgomery 2003].

Os resultados obtidos nos testes mostram que o desempenho médio dos algoritmos

são significativamente diferentes para as duas métricas utilizadas. Em relação ao número de iterações, o p-valor obtido foi de 0.0155, o que indica a rejeição da hipótese nula, considerando um valor de  $\alpha = 0.05$  e pseudo-mediana de 8.47, demonstrando que, na maior parte das amostras, o número de iterações do algoritmo proposto por Dorça é maior que o número de iterações do algoritmo proposto.

Em relação aos problemas de aprendizagem, o p-valor obtido foi 0.0155, também rejeitando a hipótese nula e pseudo-mediana de 8.47, demonstrando que o algoritmo do Dorça apresenta um número maior de notas abaixo de 60, ou seja, apresenta um número maior de problemas de aprendizagem na maior parte das amostras.

Os resultados obtidos na análise em ambas as métricas apresentam os mesmos valores já que uma está relacionada com a outra. Para cada problema de aprendizagem, o algoritmo apresenta uma iteração a mais.

Devido à superioridade do algoritmo proposto trabalhos futuros poderão aplicá-lo à ambientes virtuais de aprendizagem. Além disso este trabalho demonstrou que melhorias nas técnicas de aplicação do reforço melhoram significativamente a convergência do algoritmo, portanto pode-se considerar o estudo de técnicas mais robustas para a decisão de aplicabilidade do reforço, tais como a Lógica Fuzzy ou outras de aprendizagem de máquina.

## Referências

- Ahmad, N. B. H. and Shamsuddin, S. M. (2010). A comparative analysis of mining techniques for automatic detection of student's learning style. In *2010 10th International Conference on Intelligent Systems Design and Applications*, pages 877–882. IEEE.
- Alkhurairji, S., Cheetham, B., and Bamasak, O. (2011). Dynamic Adaptive Mechanism in Learning Management System Based on Learning Styles. *2011 IEEE 11th International Conference on Advanced Learning Technologies*, pages 215–217.
- Basheer, G. S., Ahmad, M. S., and Tang, A. Y. C. (2013). A Conceptual Multi-agent Framework Using Ant Colony Optimization and Fuzzy Algorithms for Learning Style Detection. pages 549–558.
- Brusilovsky, P. and Millán, E. (2007). User Models for Adaptive Hypermedia and Adaptive Educational Systems. *The Adaptive Web*, pages 3–53.
- Cabada, R. Z., Estrada, M. L. B., Cabada, R. Z., and García, C. A. R. (2009). A fuzzy-neural network for classifying learning styles in a web 2.0 and mobile learning environment. In *2009 Latin American Web Congress - Joint LA-WEB/CLIHC Conference*, pages 177–182.
- Carmona, C., Castillo, G., and Millán, E. (2008). Designing a Dynamic Bayesian Network for Modeling Students' Learning Styles. In *2008 Eighth IEEE International Conference on Advanced Learning Technologies*, pages 346–350.
- Cerqueira, T. C. S. (2000). *Estilos de aprendizagem em universitários*. PhD thesis.
- Crockett, K., Latham, A., Mclean, D., Bandar, Z., and O'Shea, J. (2011). On predicting learning styles in conversational intelligent tutoring systems using fuzzy classification trees. *2011 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE 2011)*, pages 2481–2488.

- Dorça, F. A. (2012). *Uma Abordagem Estocástica Baseada em Aprendizagem por Reforço para Modelagem Aprendizagem de Estudantes em Sistemas Automática e Dinâmica de Estilos de Adaptativos e Inteligentes para Educação a Distância*. Tese, Universidade Federal de Uberlândia.
- Felder, R. and Silverman, L. (1988). Learning and teaching styles in engineering education. *Engineering education*, 78(June):674–681.
- Feldman, J., Monteserin, A., and Amandi, A. (2015). Automatic detection of learning styles: state of the art. *Artificial Intelligence Review*, 44(2):157–186.
- García, P., Amandi, A., Schiaffino, S., and Campo, M. (2005). Using Bayesian Networks to Detect Students' Learning Styles in a Web-based education system. (11):29–30.
- García, P., Amandi, A., Schiaffino, S., and Campo, M. (2007). Evaluating Bayesian networks' precision for detecting students' learning styles. *Computers and Education*, 49(3):794–808.
- Georgiou, D. A. and Makry, D. (2004). A learner's style and profile recognition via Fuzzy Cognitive Map. In *Proceedings - IEEE International Conference on Advanced Learning Technologies, ICAALT 2004*, pages 36–40.
- Gonçalves, A. V., Vivas, A., Assis, L., Pitanguí, C., and Dorça, F. (2016). Avanços na modelagem automática e dinâmica de estilos de aprendizagem de estudantes em sistemas adaptativos e inteligentes para educação: uma análise experimental. In *Simpósio Brasileiro de Informática na Educação*, page 1006.
- Graf, S., Kinshuk, and Liu, T. C. (2008). Identifying learning styles in learning management systems by using indications from students' behaviour. *The 8th IEEE International Conference on Advanced Learning Technologies*, pages 482–486.
- Han, J. and Kamber, M. (2006). *Data Mining: Concepts and Techniques*, volume 54.
- Kelly, D. and Tangney, B. (2006). Adapting to intelligence profile in an adaptive educational system. *Interacting with Computers*, 18(3):385–409.
- Kinshuk, Liu, T. C., and Graf, S. (2009). Coping with mismatched courses: Students' behaviour and performance in courses mismatched to their learning styles. *Educational Technology Research and Development*, 57(6):739–752.
- Kolb, D. A. (1984). *Experiential Learning: Experience as The Source of Learning and Development*. Prentice Hall, Inc., (1984):20–38.
- Krathwohl, D. R. (2002). A Revision of Bloom's Taxonomy : An Overview. *Theory Into Practice*, 41(4):212–218.
- Montgomery, D. C. (2003). *Applied Statistics and Probability for Engineers Third Edition*, volume 37.
- Myers, I. B. (1962). *The Myers-Briggs Type Indicator: Manual (1962)*.
- Özpolat, E. and Akar, G. B. (2009). Automatic detection of learning styles for an e-learning system. *Computers and Education*, 53(2):355–367.
- Pask, G. (1976). STYLES AND STRATEGIES OF LEARNING. *J. educ. Psychol .@BULLET*, 46:128–148.

- Rodrigues, L. H. S., Assis, L., Vivas, A., Pitanguí, C., and Falci, S. (2016). Análise comparativa de novas abordagens para modelagem automática e dinâmica de estilos de aprendizagem em sistemas adaptativos e inteligentes para educação. In *Simpósio Brasileiro de Informática na Educação*, page 1076.
- Safavian, S. R. and Landgrebe, D. (1991). A Survey of Decision Tree Classifier Methodology A SURVEY OF DECISION TREE CLASSIFIER METHODOLOGY 1. *Electrical Engineering*, 21(3):660–674.
- Sena, E., Vivas, A., Assis, L., and Pitanguí, C. (2016). Proposta de uma Abordagem Computacional para Detecção Automática de Estilos de Aprendizagem Utilizando Modelos Ocultos de Markov e FSLSM. In *Simpósio Brasileiro de Informática na Educação*, page 1126.
- Soloman, B. a. and Felder, R. M. (2012). Index of Learning Styles Questionnaire. *Learning*, pages 1–5.
- Stathacopoulou, R., Magoulas, G. D., Grigoriadou, M., and Samarakou, M. (2005). Neuro-fuzzy knowledge processing in intelligent learning environments for improved student diagnosis. *Information Sciences*, 170(2-4):273–307.
- Sutton, R. S. and Barto, a. G. (1998). Reinforcement learning: an introduction. *IEEE transactions on neural networks / a publication of the IEEE Neural Networks Council*, 9(5):1054.
- Villaverde, J. E., Godoy, D., and Amandi, A. (2006). Learning styles' recognition in e-learning environments with feed-forward neural networks. *Journal of Computer Assisted Learning*, 22(3):197–206.