

## Detecção de Estilos de Aprendizagem em Ambientes Virtuais de Aprendizagem Utilizando Redes Bayesianas

Luiz Filipe C. Salazar<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)  
Diamantina, MG – Brasil

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

samuelfalci@yahoo.com.br

**Abstract.** *The Information and Communication Technologies (ICTs) and the Internet have created a scenario that offers a dynamic and autonomous learning environment, enabling models of education such as Distance Education. The present work presents a proposal of automatic detection of Student Learning Style using Bayesian Networks techniques, to create favorable conditions of adaptability in Virtual Learning Environments, characterizing an Intelligent Adaptive Tutoring System. This approach presents satisfactory results compared to one of the methods presented in the literature.*

**Resumo.** *As Tecnologias da Informação e Comunicação (TICs) e a Internet criaram um cenário que oferece um ambiente de aprendizagem dinâmico e autônomo, possibilitando modelos de educação como a Educação a Distância. O presente trabalho apresenta uma proposta de detecção automática do Estilo de Aprendizagem do Estudante utilizando técnicas de Redes Bayesianas, para criar condições favoráveis de adaptabilidade em Ambientes Virtuais de Aprendizagem, caracterizando um Sistema de Tutoria Inteligente Adaptativo. Tal abordagem apresenta resultados satisfatórios comparados a um dos métodos apresentados pela literatura.*

### 1. Introdução

Os fluxos de informação são facilitados pela revolução digital, promovendo maior inclusão e inovação nos diversos setores da economia, sociedade e política. As formas de acesso aos fluxos de informação são diversas e suas exposições ocorrem materializadas por meio de interações entre imagens, sons e textos.

As informações podem ser armazenadas e transmitidas por meio de uma plataforma de interação virtual, conectando e trocando experiências, ensinamentos e aprendizados entre povos e culturas diferentes. Tecnologias da Informação e Comunicação (TICs) e toda a rede de conectividade global proporcionaram a criação de conceitos chamados Inteligência Coletiva e Ciberespaço [Lévy 2007].

Neste cenário surgiram as Comunidades Virtuais de Aprendizagem, que segundo [Hunter 2002] é definida como um grupo de pessoas interagindo no ciberespaço, trocando

experiências, que favorece a Educação à Distância (EaD), que proporciona um montante de oportunidades tecnológicas oferecidas pelo ciberespaço.

[Belloni 2003] pontua um problema em EaD relacionado ao material didático oferecido. Todos os estudantes de um mesmo curso utilizam um material padronizado, contendo as mesmas abordagens didáticas-pedagógicas, padronizando o ensino e não observando as características individuais dos estudantes. Isso justifica a oferta de sistemas de ensino adaptado ao Estilo de Aprendizagem do Estudante, chamados Sistemas de Tutoria Inteligente Adaptativo.

De acordo com [Dorça et al. 2012], uma característica moderna de um curso em EaD é a assistência personalizada e inteligente, para atender os estudantes que apresentam perfis e necessidades diferentes.

Portanto, a proposta principal deste trabalho é apresentar uma abordagem utilizando Redes Bayesianas para detecção e definição de uma Combinação de Estilos de Aprendizagem de estudantes, de maneira dinâmica, possibilitando maior adaptatividade nas estratégias educacionais em EaD. Para viabilizar a proposta, foi utilizado um sistema de simulação de desempenho do estudante proposto por [Dorça et al. 2012].

## 2. Estilo de Aprendizagem

Estilos de Aprendizagem (EA), são maneiras preferenciais que cada indivíduo utiliza para melhor receber e processar informações e assimilar um determinado conteúdo. A diferença encontrada entre alunos durante o processo de aprendizagem conduziu à crença na existência de diferentes EA e da sua influência no aprendizado [Kolb 2014].

[Felder et al. 1988], acredita que existem aqueles que preferem aprender por mídias visuais como figuras e desenhos esquemáticos, onde outras pessoas entendem melhor com modelos matemáticos e teorias. Existem ainda os que preferem aprender as informações de forma interativa e participativa, já outros indivíduos possuem características individuais e internalizadas para adquirir conhecimentos.

Existem diversos estudos sobre EA com várias teorias, propostas e modelos estudados por vários autores, dentre eles o Modelo de Estilo de Aprendizagem Felder-Silverman (FSLSM). Este modelo é um dos mais utilizados em trabalhos para detecção de EA, pois oferece uma estrutura favorável à padronização e codificação dos algoritmos, portanto, será empregado neste trabalho. O FSLSM será apresentado na subseção a seguir.

### 2.1. Modelo de Estilo de Aprendizagem Felder-Silverman

De acordo com o trabalho de [Felder and Henriques 1995], o Modelo de Estilo de Aprendizagem Felder-Silverman (FSLSM) é composto por quatro dimensões de EA. Cada dimensão possui dois EA que corresponde às preferências que um aprendiz utiliza para aprender um conhecimento, conforme apresenta a tabela 1:

**Tabela 1. Modelo de Estilo de Aprendizagem Felder-Silverman**

Processamento		Percepção		Entrada		Organização	
Ativo	Reflexivo	Sensorial	Intuitivo	Visual	Verbal	Sequencial	Global

[Felder and Henriques 1995] conclui que o processo de aprendizado possui duas etapas: a recepção e processamento de informações. A proposta do seu modelo é identificar duas formas antagônicas para os meios de como os aprendizes preferem receber e processar as informações.

- **Processamento (Ativo e Reflexivo):** indica como as informações são percebidas e convertidas em conhecimento. Os ativos preferem experimentar e participar de forma coletiva. Os reflexivos primam pela reflexão e trabalham individualmente;
- **Percepção (Sensorial e Intuitivo):** como as pessoas percebem o ambiente ao seu redor. Os sensoriais preferem fatos e dados, dando valor a experiências. Os intuitivos são menos atentos e preferem princípios teóricos;
- **Entrada (Visual e Verbal):** forma como preferem receber o conhecimento. Os visuais têm boa memória gravando figuras, desenhos, filmes, esquemas experiências práticas. Os verbais preferem receber as informações ditas, escritas ou cantadas;
- **Organização (Sequencial e Global):** relacionada com a forma que se acompanha um assunto. Os sequenciais aprendem melhor quando o material é apresentado de forma lógica, cronológica e sistemática. Os globais preferem escolher qual a sequência que vai aprender, sem respeitar cronologia ou ordem lógica.

Assim sendo, dados os conceitos apresentados referente aos EA, a seção seguinte apresenta diferentes técnicas para detectar o Estilo de Aprendizagem do estudante a fim de adaptar o sistema a estes estilos.

### 3. Detecção de Estilos de Aprendizagem

A popularização da EaD implica em uma oferta generalizada de cursos onde o mesmo conteúdo é oferecido para um grande número de estudantes. Todos os participantes de um curso utilizam o mesmo material didático para desenvolver suas atividades de aprendizagem, não desconsiderando as preferências de aprendizado individual do estudante.

[Silva and Dorça 2014] destacam que uma das mais desejadas características de um sistema de ensino baseado na *Web* é a de ser adaptável e personalizado, uma vez que é utilizado por uma grande variedade de estudantes com diferentes habilidades e EA. Para isso, é necessário reduzir a distância entre o estilo de aprendizagem do estudante e a forma como o conteúdo será apresentado, adaptando o curso às necessidades do estudante.

Os estudantes aprendem de muitas maneiras diferentes: por ver ou ouvir; refletir ou agir; raciocinar logicamente ou intuitivamente; memorização ou visualização; analogias ou construção de modelos matemáticos; de forma constante ou de forma não sequencial. O ensino e métodos também devem variar. Uma relação é estabelecida entre ensino/aprendizagem: a maior aprendizagem pode ocorrer quando o estilo de ensino corresponde aos EA do estudante [García et al. 2007].

[Dorça et al. 2012] aponta um problema em algumas técnicas estáticas para detecção de EA onde métodos tradicionais como preenchimento de questionários e cadastro no sistema pelos estudantes podem ser ineficazes, pois tais tentativas são suscetíveis a interferências por variáveis externas e resultam em valores pouco precisos. Segundo [Silva and Dorça 2014], a eficiência na detecção automática de EA de estudantes de EaD, utilizando modelos probabilísticos associados a técnicas de Aprendizagem de Máquina, apresenta resultados com alto nível de precisão e baixo custo computacional.

[García et al. 2007] afirma que uma ferramenta que apresente material educativo ao estudante de forma adequada em ambientes de aprendizagem personalizados passa pela implementação de um mecanismo de detecção automática de EA, onde os estudantes são caracterizados em um mecanismo que adapta a instrução educacional ao seu estilo de aprendizagem.

Um dos desafios em pesquisa é encontrar formas de coletar os dados que caracterizam a classificação do EA de um estudante, viabilizando o modelo do estudante. Nos últimos anos muitos pesquisadores utilizaram técnicas heurísticas para construir o modelo do estudante de forma automática. Alguns trabalhos de autores relacionados com a detecção do Estilo de Aprendizagem de Estudantes utilizam Redes Bayesianas [García et al. 2007], Modelo Oculto de Markov [Sena 2016], Cadeia de Markov [Dorça et al. 2012], Lógica de Fuzzy [Rodrigues, 2016], entre outros.

#### 4. Redes Bayesianas

As Redes Bayesianas (RBs) também chamadas de Rede de Crenças, empregam a teoria de grafos e a teoria de probabilidades para modelar relações de causa e efeito entre variáveis aleatórias. As variáveis são representadas por vértices e suas relações são representadas por arestas direcionadas. Cada vértice possui um conjunto de estados finitos mutuamente exclusivos e há influência de cada estado de uma variável sobre a outra.

Segundo [Russell and Norvig ], as RBs são largamente utilizadas no campo da Inteligência Artificial para tratamento de incertezas e apoio às tomadas de decisão sistêmicas. RBs constituem um modelo gráfico que representa de forma simples as relações de causalidade das variáveis de um sistema. Como consequência, o modelo de RB é utilizado para medir o risco operacional, identificar a influência dos fatores de risco, calcular a sensibilidade nos eventos de perda e detectar padrões e tendências [Marques and Dutra 2002].

O cálculo da probabilidade de uma Rede Bayesiana é dado pelo Teorema de Bayes que segue na equação 1:

$$P(X|Y) = \frac{P(X|Y)P(Y)}{P(X)} \quad (1)$$

A fórmula representa o funcionamento da Regra de Bayes onde, a variável  $X$  representa as probabilidades à priori, sendo valores já conhecidos, responsáveis pelas causas de um resultado. A variável  $Y$  representa as probabilidades dos valores à posteriori, responsáveis pelos efeitos de um resultado. Tal resultado é dividido pelo  $P(X)$  que representa a Probabilidade Total das variáveis conhecidas. O cálculo da Probabilidade Total é dado pela equação 2:

$$PT = P(X|Y)P(X) + P(Y|X)P(Y) \quad (2)$$

RBs têm sido utilizadas em diversos campos do conhecimento que envolvem incerteza e necessidade de auxílio para tomada de decisão. Estas áreas de conhecimento passam por: diagnóstico médico, mapas de aprendizado, entendimento de linguagem, busca heurística, entre muitos outros [Charniak 1991].

## 5. Algoritmo Proposto

O presente trabalho propõe um algoritmo baseado nas RBs para detectar o EA de um estudante em um Ambiente Virtual de Aprendizagem, composto por um Sistema de Tutoria Inteligente.

O método proposto neste trabalho é baseado no Sistema Adaptativo e Inteligente para Educação (SAIE) apresentado por [Dorça et al. 2012]. O SAIE é composto pelo Módulo do Aluno (EA probabilístico do aluno, nível cognitivo, seção de aprendizagem atual), Módulo Pedagógico (seleciona estratégia pedagógica) e Componente de Modelagem do Estudante (atualiza o EA probabilístico). Além disso, para simular o desempenho do estudante no SAIE, [Dorça et al. 2012] apresenta o Processo Estocástico de Simulação de Desempenho do Estudante (PESDE).

Conforme mencionado na seção 2.1, o FSLSM apresenta 4 dimensões, cada dimensão apresenta dois estilos de aprendizagem. Assim sendo, existem 16 Combinações de estilos de aprendizagem (CEA), que representam as estratégias pedagógicas.

A cada iteração o módulo pedagógico do SAIE seleciona uma CEA utilizando Cadeia de Markov. O PESDE simula o desempenho do aluno dada a estratégia selecionada, o EA real do aluno (parâmetro de entrada do simulador) e uma variável aleatória que define fatores externos, inerentes ao sistema. Se nota (desempenho) for insatisfatória (nota menor que 60), o módulo Componente de Modelagem do Estudante atualiza as probabilidades dos EA armazenadas no Módulo do Aluno utilizando o algoritmo *Q-Learning* de Aprendizagem por Reforço.

O método proposto modifica o Componente de Modelagem do Estudante e substitui o algoritmo de Aprendizagem por Reforço por uma Rede Bayesiana para atualizar os EA probabilístico do aluno. A Rede Bayesiana é alimentada pelo histórico do desempenho do estudante.

Para explicar o funcionamento do algoritmo, será utilizado um exemplo considerando somente a dimensão Processamento do (FSLSM), que possui os EA Ativo e Reflexivo. Os procedimentos aqui apresentados foram estendidos para as demais dimensões.

O algoritmo 1 apresenta as modificações aplicadas ao Componente de Modelagem do Estudante. O procedimento recebe uma nota que representa do desempenho do aluno e a CEA (estratégia pedagógica que resultou neste desempenho). Em seguida, o algoritmo atualiza os contadores o "EA Ativo" e "EA Reflexivo", respectivamente.

Em seguida, o sistema "*contadorAtivo*" e "*contadorReflexivo*" que contém o número de CEAs selecionadas, contabiliza o número de notas satisfatórias retornadas pelas CEAs que contém o EA Ativo ("*contadorNotaBoaAtivo*") e CEAs contendo EA Reflexivo ("*contadorNotaBoaReflexivo*"). A Rede Bayesiana é definida a partir de notas satisfatórias, ou seja, calcula-se a probabilidade de se obter uma nota "boa" selecionando CEA com EA Ativo e probabilidade de se obter uma nota "boa" selecionando CEA com EA Reflexivo.

Os passos seguintes calculam a probabilidade total (equação 2) e aplica o teorema de Bayes (equação 1). O valor obtido ("*probabilidadeFinalAtivo*") indica a probabilidade de obter uma nota satisfatória selecionando CEA com EA Ativo. Como as probabilidades de EA de uma mesma dimensão são complementares, a probabilidade de se obter uma

nota satisfatória selecionando CEA com EA Reflexivo é dada por:  $1 - \text{"probabilidadeFinalAtivo"}$ . Por fim, os valores das probabilidades obtidos são utilizados para atualizar o EA probabilístico contido no Módulo do Aluno do SAIE.

É importante ressaltar que este procedimento é estendido para todas as dimensões do FSLSM. Para simplificar e facilitar o entendimento, apenas a dimensão Processamento foi apresentada no algoritmo 1, uma vez que, para as demais dimensões, o procedimento é similar.

---

**Algoritmo 1:** Ajuste do EA probabilístico utilizando Rede Bayesiana

---

**Entrada:** Nota, CEA  
**Saída:** EA Probabilístico

```

1 início
2   Atualiza a quantidade de CEA geradas: Ativo/Reflexivo;
3   se CEA = "Ativo" então
4     | contadorAtivo++;
5   fim
6   se CEA = "Reflexivo" então
7     | contadorReflexivo++;
8   fim
9   Atualiza a quantidade de notas boas de cada CEA: Ativo/Reflexivo
10  se nota >= 60 então
11    | se CEA = "Ativo" então
12      | contadorNotaBoaAtivo++;
13    fim
14    | se CEA = "Reflexivo" então
15      | contadorNotaBoaReflexivo++;
16    fim
17  fim
18  Calcula probabilidades: Ativo/Reflexivo
19  probabilidadeAtivo ← contadorNotaBoaAtivo / contadorAtivo;
20  probabilidadeReflexivo ← 1 - probabilidadeAtivo;
21  probabilidadeTotal ← probabilidadeAtivo * contadorNotaBoaAtivo
    + probabilidadeReflexivo * contadorNotaBoaReflexivo) (Equação.
    2);
22  probabilidadeFinalAtivo ← (probabilidadeAtivo *
    contadorNotaBoaAtivo) / probabilidadeTotal (Equação. 1);
23  retorna Atualiza EA probabilístico(probabilidadeFinalAtivo,
    1 - probabilidadeFinalAtivo);
24 fim

```

---

Conforme apresentado no algoritmo 1, o método recebe de entrada a CEA selecionada e a nota gerada a partir desta CEA. Em seguida, as variáveis "contadorAtivo" e "contadorReflexivo" são atualizadas e irão armazenar a quantidade de CEA selecionadas com o EA Ativo e o EA Reflexivo, respectivamente. Posteriormente, se nota for satisfatória, atualiza-se as variáveis "contadorNotaBoaAtivo" e "contadorNotaBoaReflexivo" que armazenam a quantidade de notas boas geradas a partir de CEA com EA Ativo e EA

Reflexivo, respectivamente.

Com essas variáveis, é possível calcular as probabilidades das notas boas pertencerem a cada EA, aplicando o Teorema de Bayes. Com o resultado se atualiza o EA probabilístico no Módulo do Estudante.

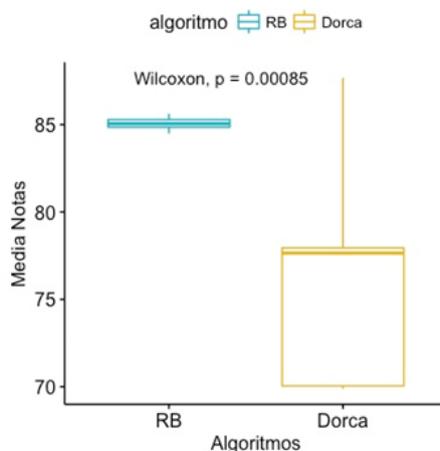
## 6. Resultados

Esta seção apresenta o planejamento experimental adotado para avaliação dos resultados obtidos pelos algoritmos RB e [Dorça et al. 2012]. O algoritmo RB representa o método proposto neste trabalho, que utiliza uma Rede Bayesiana para ajustar os EA probabilísticos dos estudantes. O algoritmo Dorça, consiste na abordagem apresentada por [Dorça et al. 2012] no qual o ajuste dos EA probabilísticas é feito utilizando algoritmo de Aprendizagem por Reforço. Todos os algoritmos analisados foram implementados com base na arquitetura do SAIE e PESDE, proposto por [Dorça et al. 2012].

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 EA real. Dessas 30 replicações, foram computadas as médias, totalizando 16 amostras (tabela 1). Os testes foram executados de maneira independente e foram avaliadas as seguintes medidas de qualidade: quantidade de notas abaixo de 60 e média das notas obtidas nas seções de aprendizagem. Para cada métrica foi aplicado o mesmo teste estatístico, buscando encontrar as diferenças significativas entre os algoritmos considerando cada uma delas.

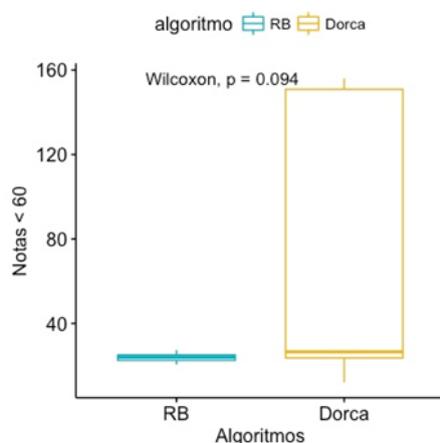
Para cada métrica considerada, a hipótese nula indica a ausência de diferença entre os algoritmos avaliados: RB (1) e Dorça (2), contra sua hipótese alternativa de que existe diferença em pelo menos dois algoritmos. Caso os algoritmos apresentem o mesmo desempenho e não haja diferença significativa, a hipótese nula é aceita. Por outro lado, caso haja diferenças significativas no desempenho dos algoritmos avaliados a hipótese nula é rejeitada. Para a análise dos experimentos foi considerado um nível 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 Signed Rank* [Montgomery 2017]. Este teste é uma alternativa onde não é possível afirmar ou justificar sobre a normalidade dos dados.

O resultado do teste de hipótese aponta para a rejeição da hipótese nula para a métrica "média das notas". A figura 1 apresenta o p-valor e o *boxplot* das diferenças entre os algoritmos. Na figura, observa-se que o p-valor entre os algoritmos RB (1) e Dorça (2) é de 0.00085, demonstrando que existem diferenças estatisticamente significativas entre eles. Analisando o gráfico, observa-se que as médias obtidas pelo algoritmo RB são superiores às médias obtidas pelo algoritmo proposto na literatura.



**Figura 1. Boxplot dos resultados dos algoritmos RB(1) e Dorça (2) referente à métrica Médias das Notas**

Quanto a métrica quantidade de notas menores que 60, o algoritmo proposto tem menor variabilidade, porém a diferença entre as medianas são próximas de zero, como mostra a figura 2. Assim, o teste de *Wilcoxon* indicou que a hipótese nula não deve ser rejeitada ( $p\text{-valor} > 0.05$ ), pois não existe evidências suficiente para isso.



**Figura 2. Boxplot dos resultados dos algoritmos RB(1) e Dorça (2) referente à métrica Quantidade de Notas Insatisfatórias (notas < 60).**

A tabela 2 apresenta os resultados obtidos para ambas as métricas avaliadas, para os dois algoritmos avaliados. Cada linha indica os resultados obtidos dada uma CEA real utilizada como parâmetro de entrada do PESDE. Os melhores resultados estão destacados na tabela. Os resultados da tabela corroboram com as análises estatísticas realizadas, demonstrando superioridade do método proposto em relação às médias das notas obtidas durante as seções de aprendizagem.

Na tabela 2 é possível verificar que o algoritmo proposto apresenta baixa variabilidade nos resultados e um melhor desempenho do algoritmo nas métricas analisadas. O algoritmo proposto mostrou estabilidade nos resultados, independente do EA real do estudante.

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

EA Real	Notas < 60		Médias das Notas	
	RB (1)	Dorça (2)	RB (1)	Dorça (2)
A - I - Ve - Seq	22.03	<b>14.56</b>	85.42	<b>86.91</b>
A - I - Vi - Seq	24.96	<b>20.66</b>	<b>84.96</b>	78.29
A - S - Ve - G	24.69	<b>20.33</b>	<b>85.03</b>	78.22
A - S - Vi - G	<b>23.73</b>	156.06	<b>84.88</b>	69.88
A - S - Ve - Seq	<b>24.36</b>	24.60	<b>84.85</b>	77.63
A - S - Vi - Seq	<b>27.36</b>	153.66	<b>84.49</b>	70.06
R - I - Ve - G	<b>21.96</b>	152.73	<b>85.29</b>	69.98
R - I - Vi - G	<b>23.00</b>	24.69	<b>85.10</b>	77.83
R - I - Ve - Seq	<b>20.50</b>	25.96	<b>85.61</b>	77.85
R - S - Vi - Seq	<b>24.50</b>	149.89	<b>85.14</b>	70.00
A - I - Ve - G	<b>26.13</b>	153.03	<b>84.58</b>	70.03
R - S - Ve - Seq	<b>26.69</b>	27.13	<b>84.70</b>	77.66
R - S - Vi - G	<b>25.39</b>	150.26	<b>84.84</b>	70.05
R - S - Ve - G	<b>22.63</b>	24.89	<b>85.39</b>	77.72
R - I - Vi - Seq	<b>22.80</b>	33.56	<b>85.07</b>	77.09
A - I - Vi - G	21.86	<b>12.00</b>	85.28	<b>87.67</b>

Analisando as notas abaixo de 60, apenas em quatro entradas o algoritmo de Redes Bayesianas apresenta pior resultado. A superioridade do algoritmo proposto também pode ser observado quanto a baixa variabilidade dos resultados, comportando-se de maneira estável.

Tal otimização proporcionou uma forma mais eficiente de detecção de EA, utilizando RBs, conforme mostram os resultados apresentados comparados ao método encontrado na literatura. Isso valida a proposta de gerar adaptações no aprendizado, atingindo os objetivos esperados.

## 7. Considerações Finais

O objetivo principal deste trabalho foi otimizar a detecção de EA para possibilitar a oportunidade de oferecer materiais didáticos mais adaptados aos estudantes, caracterizando um sistema inteligente e adaptativo em AVA, tomando como incentivo o trabalho desenvolvido por [Dorça et al. 2012]

Tal otimização proporcionou uma nova forma de detecção de EA, utilizando um algoritmo de Rede Bayesianas, que foi comparado com resultados comprovados no trabalho de [Dorça et al. 2012], onde os testes encontram-se na seção 6, validando a proposta de detectar automaticamente os EA de estudantes em AVA, atingindo os objetivos esperados.

A principal contribuição deste trabalho considera uma abordagem capaz de identificar as preferências individuais e cognitivas de estudantes em ambientes virtuais de aprendizagem e atualizar automaticamente seus estilos de aprendizagem probabilístico. Tal abordagem utiliza técnicas de Redes Bayesianas, baseadas em informações contida no modelo do estudante para atualizar suas probabilidades do EA probabilístico e assim

determinar qual a melhor combinação de estilos de aprendizagem adaptada às preferências de um aprendiz.

Os resultados obtidos no presente trabalho apontam para um futuro promissor em pesquisas na área de detecção de estilos de aprendizagem em AVA, abrindo precedentes para pesquisas como ampliação dos parâmetros probabilísticos utilizados pela RB para aumentar sua precisão, a aplicação da proposta utilizando dados reais de estudante em AVA, e abordagens de RB na recomendação de Objetos de Aprendizagem compatíveis com os EA dos estudantes.

## Referências

- Belloni, M. L. (2003). Educação a distância. In *Educação contemporânea*. Autores Associados.
- Charniak, E. (1991). Bayesian networks without tears. *AI magazine*, 12(4):50.
- Dorça, F. A. et al. (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.
- Felder, R. M. and Henriques, E. R. (1995). Learning and teaching styles in foreign and second language education. *Foreign language annals*, 28(1):21–31.
- Felder, R. M., Silverman, L. K., et al. (1988). Learning and teaching styles in engineering education. *Engineering education*, 78(7):674–681.
- García, P., Amandi, A., Schiaffino, S., and Campo, M. (2007). Evaluating bayesian networksâ precision for detecting studentsâ learning styles. *Computers & Education*, 49(3):794–808.
- Hunter, B. (2002). Learning in the virtual community depends upon changes in local communities. *Building virtual communities: Learning and change in cyberspace*, pages 96–126.
- Kolb, D. A. (2014). *Experiential learning: Experience as the source of learning and development*. FT press.
- Lévy, P. (2007). *Inteligência coletiva (A)*. Edições Loyola.
- Marques, R. L. and Dutra, I. (2002). Redes bayesianas: o que são, para que servem, algoritmos e exemplos de aplicações. *Coppe Sistemas–Universidade Federal do Rio de Janeiro, Rio de Janeiro, Brasil*.
- Montgomery, D. C. (2017). *Design and analysis of experiments*. John Wiley & Sons.
- Russell, S. and Norvig, P. *Inteligência artificial*, 3e.[sl: sn], 2013. Technical report, ISBN 978-85-352-3701-6.
- Sena, E. B. d. (2016). Proposta de uma abordagem computacional para detecção automática de estilos de aprendizagem utilizando modelos ocultos de markov e fsm. Master's thesis, UFVJM.
- Silva, D. H. and Dorça, F. A. (2014). Uma abordagem automática para personalização do processo de ensino baseada em estilos de aprendizagem em sistemas adaptativos e inteligentes para educação a distância. *Revista Brasileira de Informática na Educação*, 22(2):1–15.