

**UNIVERSIDADE FEDERAL DOS VALES DO JEQUITINHONHA E MUCURI Pós**  
**Graduação *Stricto Senso* em Educação**  
**Hilton Leslie de Oliveira**

**Uma Aplicação da Metaheurística *Vitis Vinifera* para Detecção Dinâmica e Automática  
de Estilos de Aprendizagem para Sistemas Adaptativos Inteligentes para a Educação**

**Diamantina**  
**2018**



**Hilton Leslie de Oliveira**

**Uma Aplicação da Metaheurística *Vitis Vinifera* para Detecção Dinâmica e Automática de Estilos de Aprendizagem para Sistemas Adaptativos Inteligentes para a Educação**

Dissertação de Mestrado apresentado na Pós Graduação em Educação, como parte dos requisitos exigidos para a obtenção do título de Mestre em Educação.

Orientador: Cristiano Grijó Pitangui

Coorientador: Alessandro Vivas Andrade

**Diamantina  
2018**

Elaborado com os dados fornecidos pelo(a) autor(a).

O48a

Oliveira, Hilton Lesllie de

Uma aplicação da Metaheurística Vitis Vinifera para detecção dinâmica e automática de estilos de aprendizagem para sistemas adaptativos inteligentes para a educação / Hilton Lesllie de Oliveira, 2019.

83 p. : il.

Orientador: Cristiano Grijó Pitangui

Coorientador: Alessandro Vivas Andrade

Dissertação (Mestrado – Programa de Pós-Graduação em Educação)  
- Universidade Federal dos Vales do Jequitinhonha e Mucuri,  
Diamantina, 2019.

1. Metaheurística. 2. Educação. 3. Tecnologia. 4. Aprendizado.  
I. Pitangui, Cristiano Grijó. II. Andrade, Alessandro Vivas. III. Título.  
IV. Universidade Federal dos Vales do Jequitinhonha e Mucuri.

**CDD 371.33**

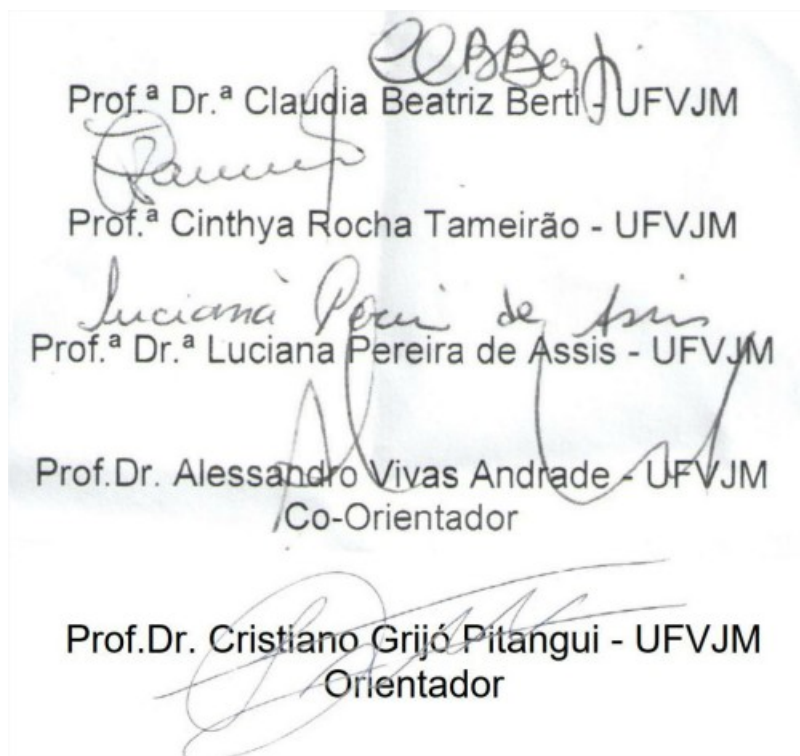
**Hilton Leslie de Oliveira**

**Uma Aplicação da Metaheurística *Vitis Vinifera* para Detecção Dinâmica e Automática de Estilos de Aprendizagem para Sistemas Adaptativos Inteligentes para a Educação**

Dissertação de Mestrado apresentado na Pós Graduação em Educação, como parte dos requisitos exigidos para a obtenção do título de Mestre em Educação.

Orientador: Prof. Dr. Cristiano Grijó Pitangui  
Coorientador: Prof. Dr. Alessandro Vivas Andrade

Data de aprovação 19/10/2018.



Prof.<sup>a</sup> Dr.<sup>a</sup> Claudia Beatriz Berti - UFVJM

Prof.<sup>a</sup> Cinthya Rocha Tameirão - UFVJM

Prof.<sup>a</sup> Dr.<sup>a</sup> Luciana Pereira de Assis - UFVJM

Prof.Dr. Alessandro Vivas Andrade - UFVJM  
Co-Orientador

Prof.Dr. Cristiano Grijó Pitangui - UFVJM  
Orientador

Diamantina  
2018



## AGRADECIMENTOS

Dou graças a Deus, pelo dom da vida e por todas as circunstâncias que me rodeiam, proporcionadas por Ele. Sou grato por cada um que Ele colocou em meu caminho e cada situação, ciente que em todas obtive êxito ou aprendizado. À videira verdadeira na qual sou um ramo firmado, agradeço com tudo que tenho e tudo que sou. Sem Ti nada posso;

Aos meus pais, nunca serei capaz de agradecer-los por tudo o que são para mim, não existiriam palavras suficientemente honrosas. Por cada sacrifício e ensinamento, por cada abraço e cada oração, por tudo o que representam para mim. Vocês tem todo meu respeito e admiração, meu amor por vocês é incomensurável. Em tudo o que eu for bem sucedido, o mérito é de vocês.

Ao meu irmão Wendel, você é simplesmente fantástico. É incrivelmente companheiro, fonte de inspiração, força, perseverança e sempre está do meu lado, pronto para estender a mão. Agradeço pelos ensinamentos e pelo exemplo que você é para mim, seria impossível pedir um irmão melhor. Te amo de verdade mano;

À minha noiva Tainá, por sempre me incentivar a dar o que tenho de melhor e buscar a excelência. Por ser meu suporte em todas as situações, cuidadosa, dedicada e por acreditar no meu potencial. Você é capaz de me fazer sorrir e esquecer as dificuldades em qualquer situação. Amo você, minha princesa.

À minha vó por ser sempre pilar de intercessão, tenho certeza que cada oração sua me proporcionou passos seguros e me sustentou, sempre serei grato a senhora, Te amo vó;

Aos amigos que proporcionaram momentos de distração, entretenimento, sendo essenciais, ao tornar toda essa caminhada mais leve e dar o apoio necessário nos momentos certos.

Aos meus professores e mestres, todos que colaboraram para minha formação desde os primeiros anos do ensino fundamental, cada um foi indispensável. Aos membros da banca, Luciana, Cinthya e Cláudia, por serem parte importante contribuírem de forma tão relevantes para aprimorar o presente trabalho.

Em especial aos meus orientadores Vivas e Cristiano:

Ao Cristiano, pelo precioso tempo dedicado, pelos desafios impostos e pela colaboração em todas as fases desse trabalho. Você sempre contribui de forma indispensável para o meu desenvolvimento pessoal e acadêmico. Sou imensamente grato.

Ao Vivas, por sempre acreditar no trabalho e confiar que seria possível alcançar os resultados almejados. Pela dedicação, zelo e por sempre conduzir pelo melhor caminho, proporcionando grandes aprendizados. Pela parceria e por estar sempre aberto a uma boa conversa, verdadeiramente te considero um amigo. Obrigado por tudo.

A todos vocês os meus mais sinceros agradecimentos.





”Eu sou a videira verdadeira...”(**Bíblia Sagrada** - João 15:1)



## RESUMO

O presente trabalho aborda o problema de detecção de traços cognitivos de estudantes para customização de Ambientes Virtuais de Aprendizagem. Neste sentido, aplica-se a Meta-heurística Vitis Vinífera para a detecção do Estilo de Aprendizagem do aluno para futura seleção de objetos de aprendizagem de forma a aprimorar o processo de ensino-aprendizagem. A abordagem proposta é avaliada em relação ao estado da arte que utiliza um Algoritmo Genético para a identificação do Estilo de Aprendizagem. Resultados experimentais apontam que a abordagem proposta é superior em relação ao estado da arte considerando o número de erros de detecção cometidos.

Palavras-chave: Metaheurística. Educação. Tecnologia. Aprendizado. MHV.



## **ABSTRACT**

The present work deals with the problem of detection of cognitive traits of students for the customization of Virtual Learning Environments. In this sense, Meta-heuristic Vitis Vinífera is applied to detect the Learning Style of the student for future selection of learning objects in order to improve the teaching-learning process. The proposed and evaluated approach is compared to the state of the art that uses a Genetic Algorithm to identify the Learning Style. Experimental results indicate that the proposed approach is superior to the state of the art considering the number of detection errors committed.

Keywords: Metaheuristics. Education. Tecnology. Learning. MHV.



## LISTA DE ILUSTRAÇÕES

Figura 1 – Hierarquia da notação O (COELHO; NETO, 2010). . . . .	37
Figura 2 – Estrutura Principal do MHV (Fonte: Próprio autor) . . . . .	52
Figura 3 – Combinação de ações Processamento. Adaptado de Yannibelli, Godoy e Amandi (2006) . . . . .	54
Figura 4 – Combinação de ações Percepção. Adaptado de Yannibelli, Godoy e Amandi (2006) . . . . .	55
Figura 5 – Combinação de ações Compreensão. Adaptado de Yannibelli, Godoy e Amandi (2006) . . . . .	56
Figura 6 – Exemplo de Fitômero com ação e peso (Fonte: Próprio Autor). . . . .	58
Figura 7 – Exemplo de Fitômero (Fonte: Próprio Autor) . . . . .	58
Figura 8 – Ações do modelo real na Unidade Acadêmica 1 (Fonte: Próprio Autor) . . .	59
Figura 9 – Vetor de ações e pesos após avaliação dos pesos (Fonte: Próprio Autor) . . .	59
Figura 10 – Exemplo de Alteração via Temperatura (Fonte: Próprio Autor) . . . . .	60
Figura 11 – Exemplo de Enxerto (Fonte: Próprio Autor) . . . . .	61
Figura 12 – Fitômero após a primeira iteração (Fonte: Próprio Autor) . . . . .	61
Figura 13 – Ações da UA2 (Fonte: Próprio Autor) . . . . .	61
Figura 14 – Pesos após a comparação do novo fitômero e UA2 (Fonte: Próprio Autor) . .	61
Figura 15 – Soma dos pesos antigos e novos (Fonte: Próprio Autor) . . . . .	62
Figura 16 – Indivíduo com os pesos atualizados (Fonte: Próprio Autor) . . . . .	62
Figura 17 – Distância Total dos EA Detectados para os Reais (Fonte: Próprio Autor) . .	65
Figura 18 – Histograma MHV (Fonte: Próprio Autor) . . . . .	66
Figura 19 – Histograma AG (Fonte: Próprio Autor) . . . . .	66
Figura 20 – Boxplot comparativo dos dados (Fonte: Próprio Autor) . . . . .	67
Figura 21 – Teste de Hipóteses - Wilcoxon (Fonte: Próprio Autor) . . . . .	67





## LISTA DE TABELAS

Tabela 1 – Teorias de Estilo de Aprendizagem . . . . .	48
Tabela 2 – Algoritmos de Detecção de Estilos de Aprendizagem . . . . .	49
Tabela 3 – Significado Processamento . . . . .	56
Tabela 4 – Significado Percepção . . . . .	57
Tabela 5 – Significado Compreensão . . . . .	57
Tabela 6 – Grau de Proximidade EA Real - EA Detectada . . . . .	63
Tabela 7 – Sumário dos resultados obtidos para a MHV e o AG . . . . .	66



## **LISTA DE ABREVIATURAS E SIGLAS**

UFVJM - Universidade Federal dos Vales do Jequitinhonha e Mucuri

SAIE - Sistemas Adaptativos Inteligentes para a Educação

STI - Sistemas de Tutoria Inteligente

IA - Inteligência Artificial

EAD - Ensino à distância

CAI - Sistema de Instrução Assistida por Computador (Computer Assisted Instruction)

ICAI - Sistema Inteligente de Instrução Assistida por Computador (Intelligent Computer Assisted Instruction)

MH - Metaheurísticas

MHV - Metaheurística *Vitis Vinifera*

AG - Algoritmo Genético



## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO . . . . .</b>	<b>21</b>
<b>1.1</b>	<b>Caracterização do Problema . . . . .</b>	<b>21</b>
<b>1.2</b>	<b>Modelagem do Problema . . . . .</b>	<b>22</b>
<b>1.3</b>	<b>Objetivo . . . . .</b>	<b>22</b>
<b>2</b>	<b>REFERÊNCIAL TEÓRICO . . . . .</b>	<b>25</b>
<b>2.1</b>	<b>Histórico . . . . .</b>	<b>25</b>
<b>2.2</b>	<b>Sistemas Tutores Inteligentes . . . . .</b>	<b>27</b>
<b>2.3</b>	<b>Estilos de Aprendizagem . . . . .</b>	<b>28</b>
<b>2.3.1</b>	<b>Detecção de Estilos de Aprendizagem . . . . .</b>	<b>28</b>
<b>2.3.1.1</b>	<b>Categorização dos Estilos de Aprendizagem . . . . .</b>	<b>30</b>
<b>2.4</b>	<b>Modelos de Estilos de Aprendizagem . . . . .</b>	<b>30</b>
<b>2.4.1</b>	<b>Kolb . . . . .</b>	<b>30</b>
<b>2.4.2</b>	<b>Biggs . . . . .</b>	<b>31</b>
<b>2.4.3</b>	<b>Felder . . . . .</b>	<b>32</b>
<b>2.5</b>	<b>Inteligência Artificial . . . . .</b>	<b>34</b>
<b>2.5.1</b>	<b>Definição de Inteligência Artificial . . . . .</b>	<b>34</b>
<b>2.5.2</b>	<b>Origem da IA . . . . .</b>	<b>34</b>
<b>2.5.3</b>	<b>Análise de Complexidade . . . . .</b>	<b>36</b>
<b>2.5.4</b>	<b>Otimização Combinatória . . . . .</b>	<b>38</b>
<b>2.5.4.1</b>	<b>Metaheurísticas . . . . .</b>	<b>38</b>
<b>2.5.4.2</b>	<b>Metaheurísticas Bio-inspiradas . . . . .</b>	<b>40</b>
<b>3</b>	<b>REVISÃO DA LITERATURA . . . . .</b>	<b>43</b>
<b>3.1</b>	<b>Metodologia . . . . .</b>	<b>43</b>
<b>3.2</b>	<b>Estrutura Frequente dos Artigos . . . . .</b>	<b>44</b>
<b>3.2.1</b>	<b>Modelos de Estilos de Aprendizagem . . . . .</b>	<b>44</b>
<b>3.2.2</b>	<b>Técnicas de Detecção de Estilos de Aprendizagem . . . . .</b>	<b>45</b>
<b>3.3</b>	<b>Revisão dos artigos coletados . . . . .</b>	<b>45</b>
<b>3.3.1</b>	<b>Teorias de Estilo de Aprendizagem . . . . .</b>	<b>45</b>
<b>3.3.1.1</b>	<b>Algoritmos de Detecção de Estilos de Aprendizagem . . . . .</b>	<b>46</b>
<b>3.4</b>	<b>Análise dos artigos revisados . . . . .</b>	<b>46</b>
<b>4</b>	<b>METODOLOGIA . . . . .</b>	<b>51</b>
<b>4.1</b>	<b>Modelo de Estilo de Aprendizagem de Felder e Silverman . . . . .</b>	<b>51</b>
<b>4.2</b>	<b>Metaheurística <i>Vitis Vinifera</i> . . . . .</b>	<b>51</b>

<b>4.3</b>	<b>Modelagem do Problema . . . . .</b>	<b>54</b>
<b>4.4</b>	<b>MHV Alicado para Detecção de EA . . . . .</b>	<b>57</b>
<b>4.4.1</b>	<b>Fitômero . . . . .</b>	<b>57</b>
<b>4.4.2</b>	<b>População Inicial . . . . .</b>	<b>58</b>
<b>4.4.3</b>	<b>Função de Qualidade (<math>q</math>) . . . . .</b>	<b>58</b>
<b>4.4.4</b>	<b>Torneio - Competição Trófica . . . . .</b>	<b>60</b>
<b>4.4.5</b>	<b>Temperatura . . . . .</b>	<b>60</b>
<b>4.4.6</b>	<b>Enxerto . . . . .</b>	<b>60</b>
<b>4.4.7</b>	<b>Finalizando a Qualidade . . . . .</b>	<b>61</b>
<b>4.5</b>	<b>Medições . . . . .</b>	<b>62</b>
<b>4.5.1</b>	<b>Escala Likert . . . . .</b>	<b>62</b>
<b>5</b>	<b>RESULTADOS E DISCUSSÕES . . . . .</b>	<b>65</b>
	<b>REFERÊNCIAS . . . . .</b>	<b>71</b>

# 1 INTRODUÇÃO

A educação é imprescindível para o desenvolvimento da humanidade, e a evolução dessa área sempre esteve associado aos mais diversos campos de estudo. Um dos campos que impulsionou mudanças significativas na educação é a tecnologia. Essa relação produz ótimos frutos, capazes de aprimorar os processos educacionais presenciais ou à distância, como é o caso do presente trabalho.

## 1.1 Caracterização do Problema

Um dos maiores desafios enfrentados pela educação, presencial ou a distância, é oferecer conteúdos de forma a atender todos os perfis de estudantes que chegam às instituições. Grande parte da dificuldade dessa tarefa está associada a forma como o estudante aprende e a forma como o conteúdo é apresentado. Para auxiliar nesse aspecto, muito têm se investido em pesquisas e desenvolvimento de sistemas educacionais com conteúdo adaptável e inteligência. [Dorça \(2012\)](#) afirma que a detecção, da forma de aprendizado do estudante, fundamentada em uma abordagem probabilística para modelagem do perfil do mesmo, é um importante problema em pesquisas. Visto a necessidade desses modelos de lidar com informações incompletas ou incertas sobre o estudante. Ressalta também que considerar processos estocásticos na modelagem do estudante e no fornecimento de adaptatividade é essencial para o sucesso das aplicações.

Esse problema tem sido abordado em diversos trabalhos na literatura, gerando o que são chamados Sistemas Adaptativos e Inteligentes para Educação (SAIE). Esses sistemas educacionais se caracterizam por adaptar o conteúdo apresentado e oferecer suporte à navegação, de acordo com as características individuais dos estudantes. Essa funcionalidade é baseada nos Sistemas de Hiperídia Adaptativa. A modelagem do estudante baseada em Estilos de Aprendizagem (EA), através do perfil psicológico do estudante, serve como base para a estruturação do ensino personalizado nesses sistemas.

Os Sistemas Adaptativos e Inteligentes para Educação são capazes de estimular e influenciar grandemente no processo de aprendizado do estudante. [Dorça et al. \(2011\)](#) atesta que a aprendizagem é facilitada quando as estratégias pedagógicas vão ao encontro dos Estilos de Aprendizagem do estudante, e afirma que utilizar material e atividades que estejam em concordância com os perfis identificados, torna o processo de aprendizagem mais efetivo e a performance do estudante é consideravelmente melhorada.

A identificação correta do perfil de aprendizado do estudante é um dos principais elementos de um SAIE, pois só assim o conteúdo é apresentado da forma mais adequada ao mesmo, proporcionando um sistema adaptativo eficaz.

Na presente pesquisa, para a identificação do perfil de aprendizado, é utilizado o modelo de EA proposto em [Felder, Silverman et al. \(1988\)](#), o FelderSilverman's Learning Styles

Model (FSLSM). Algumas características do FSLSM o tornam o modelo ideal para o presente trabalho, enquanto a maioria dos modelos classificam estudantes em tipos, este é baseado na ideia de que cada estudante possui uma preferência em cada uma das suas dimensões, conforme propõe [Felder, Silverman et al. \(1988\)](#). Além disso, ele considera estilos de aprendizagem como tendências, ou seja, estudantes possuem uma tendência por um estilo de aprendizagem.

Trabalhos como [Dorça e Lima \(2013\)](#), [Dorça et al. \(2011\)](#), [Dorça \(2012\)](#) apresentam abordagens para modelagem automática e um dos fatores-chaves para o sucesso desses sistemas é a escolha do algoritmo para modelar os processos estocásticos. Existem diversos algoritmos e meta-heurísticas que modelam processos estocásticos, por possuírem uma natureza probabilística, a escolha do método a ser utilizado influencia o sucesso do sistema.

## 1.2 Modelagem do Problema

O presente apresenta uma abordagem para a detecção dos traços cognitivos de estudantes para customização de SAIE. A detecção é feita de forma automática e dinâmica, considerando seus aspectos não-determinísticos e não-estacionários, levando em conta que os traços característicos podem mudar durante o processo de aprendizagem de uma forma inesperada e imprevisível. As ações do estudante em relação ao sistema é o que possibilita identificar os traços do mesmo, sendo levado em consideração a participação em fóruns, chats, leitura do material, acesso aos exemplos, realização dos exercícios, tempo de entrega dos exames, correções dos exercícios, mudanças das respostas e a maneira que o mesmo interage com o conteúdo (global ou sequencialmente). Tal abordagem de detecção automática foi proposta inicialmente por [Yannibelli, Godoy e Amandi \(2006\)](#) e aplicada com um Algoritmo Genético ([HOLLAND, 1992](#)), como veremos a frente.

Para a detecção na abordagem será utilizada a Meta-heurística *Vitis Vinifera*, possibilitando uma futura seleção de Objetos de Aprendizagem, consequentemente aprimorando o processo de ensino-aprendizagem. A meta-heurística escolhida foi proposta em [Oliveira \(2016\)](#), por tratar-se de uma meta-heurística que tem se mostrado potencialmente poderosa e dar bons resultados com baixíssimo tempo de execução. A mesma se mostrou potencialmente efetiva e possui aplicabilidade em diversos problemas, sendo que as características apresentadas figuram positivamente para uma abordagem como a proposta.

## 1.3 Objetivo

A finalidade do trabalho é renovar uma abordagem promissora, a saber a proposta por [Yannibelli, Godoy e Amandi \(2006\)](#), aprimorando a mesma, sendo mais eficiente e eficaz do que o estado da arte. Aprimorando a detecção dos traços cognitivos do aprendiz, possibilitando maior êxito na modelagem do mesmo, resultando em sistemas com adaptatividade mais assertiva e consequentemente aprendizado mais efetivo.



Para alcançar o objetivo foi necessário verificar a efetividade do método escolhido ao detectar os Estilos de Aprendizagens (EA) de estudantes por meio de suas iterações em um Ambiente Virtual de Aprendizagem. Para essa tarefa, levou-se em conta o modelo proposto por [Felder, Silverman \*et al.\* \(1988\)](#), combinando as ações do usuário com o ambiente em seções bem definidas, traçando assim o perfil cognitivo do mesmo.



## 2 REFERÊNCIAL TEÓRICO

No presente capítulo traremos um referencial teórico que visa introduzir a evolução dos conceitos necessários para a melhor compreensão do trabalho como um todo, bem como apresentar algumas das teorias que servem de base para o trabalho.

### 2.1 Histórico

A humanidade sofreu grandes mudanças no último século, sendo que uma das mais significativas foi a evolução tecnológica, atingindo todas as classes e tornando o mundo mais conectado. Parte dessa evolução tem início por volta de 1960, com pesquisas militares, no auge da Guerra Fria, onde qualquer inovação científica tinha valor não apenas tecnológico, mas garantia uma vantagem na disputa armamentista. A tensão crescia cada vez mais, chegando ao ápice em Outubro de 1962, quando a União Soviética implantou mísseis balísticos em Cuba. Dentro desse contexto a importância da comunicação ficava ainda mais evidente, com a temida possibilidade de perda e vazamento de informações sigilosas, informações essas que garantiam as vantagens alcançadas. Assim, o Pentágono empreendeu esforços para criar um modelo de troca e compartilhamento de informações, descentralizando a arquitetura e o modo de transmissão de forma a prevenir possíveis ataques as bases americanas (DOMINGOS, 2013).

Em 1969, a DARPA (Defense Advanced Research Projects Agency) foi encarregada do desenvolvimento de um meio de transmitir dados entre computadores de todos tamanhos, marcas, sistemas operacionais, independente do posicionamento geográfico dos mesmos e que funcionasse em situações críticas, como em ambientes de guerra. No fim da década de 60, o Departamento de Defesa dos EUA mostrou o interesse pelo projeto e financiou a pesquisa, construção e uso das redes de computadores. Foi criada então a primeira rede, a ARPANET, desenvolvida pela ARPA (Advanced Research Projects Agency). O ataque ao qual os EUA preveniam nunca aconteceu, mas a tecnologia transformou-se em uma rede cotidiana para identificar, compartilhar e transmitir informações e ideias, trocando gráficos, vídeos, sons e animação para centenas de milhões de usuários em todo o mundo (COHEN-ALMAGOR, 2011).

Nascia a Internet, porém o seu alcance mundial só foi possível a partir de 1989, quando foi criada a *World Wide Web*. Desenvolvida por físicos e engenheiros do CERN, o Laboratório de Física de Partículas da Europa em Genebra, Suíça, em colaboração com muitos outros institutos. A ideia da Web partiu de uma experiência positiva de um pequeno sistema de hipertexto pessoal, usado para acompanhar informações pessoais em um projeto distribuído. Seu objetivo inicial era ser um agrupamento do conhecimento humano, o que permitiria aos colaboradores compartilhar suas pesquisas, ideias e todos os aspectos de um projeto comum. A escalabilidade do projeto foi o que permitiu que a Web se expandisse rapidamente desde suas origens no CERN, alcançando o mundo, independentemente dos limites entre nações

([BERNERS-LEE ROBERT CAILLIAU, 1994](#)). Assim o primeiro site da internet foi colocado no ar em 1991 ([SENA \*et al.\*, 2016](#)).

Com a criação da Web e o uso do hipertexto, a dinâmica de compartilhamento de conteúdo sofreu grandes alterações, possibilitando ao leitor adequar a ordem com que assimila o conteúdo. Juntamente com a contínua evolução dos sistemas computacionais, a capacidade e formato das páginas mudaram, suportando não apenas texto, mas utilizando sistemas multimídias, como imagens, sons, vídeos, áudios e etc. o que deixou os conteúdos disponibilizados ainda mais ricos e informativos.

Mesmo com todos os avanços a Web contava apenas com o fluxo unilateral dos dados, ou seja, o leitor era impossibilitado de participar ativamente da construção e elaboração do conteúdo. Porém isso mudaria com a Web 2.0, permitindo a interação social no qual conteúdos podem ser gerados de forma compartilhada nos mais diferentes formatos. As mídias sociais permitem a criação e troca de Conteúdo Gerado pelo Utilizador a partir de ferramentas baseadas na Web 2.0, tais como: blogs, redes sociais e Wikis ([KAPLAN; HAENLEIN, 2010](#)).

[Castells \(1999\)](#) afirma que, o processo de transformação tecnológica expande-se exponencialmente, devido a capacidade de criar uma interface entre os campos tecnológicos, e mediante uma linguagem digital comum, na qual a informação é gerada, armazenada, recuperada, processada e transmitida. Essa interface citada por Castells é o que permite que todos os aspectos do nosso cotidiano sejam alcançados e transformados pela tecnologia.

Vivendo em um mundo digital a influência exercida pela tecnologia se estende a todos os setores, incluindo o educacional, pois as mídias sociais trouxeram um novo paradigma de comunicação e interação. Essa interação viabiliza a educação à distância, visto que o processo de aprendizagem requer essa interação para a construção do saber. Com a possibilidade de reunir pessoas com um objetivo de estudo em comum em um mesmo ambiente, criam-se as comunidades virtuais de estudo. Surgem assim os Ambientes Virtuais de Aprendizagem(AVA) proporcionando aos alunos e professores, o compartilhamento de experiências, troca de informações e aprendizado por parte de todo o grupo. Essas ferramentas permitem maior interatividade entre estudantes e professores, além de gerenciar as informações e materiais otimizando os recursos disponibilizados.

Para [Soffner e Barbosa \(2011\)](#) as tecnologias modernas podem ser utilizadas como substitutas de alguns dos recursos escolares tradicionais, num ambiente educacional e de propósitos pedagógicos, e também no aumento da produtividade de aulas expositivas tradicionais. Mesmo mantendo o caráter instrucionista desta prática, a tecnologia pode prover recursos para a ação criativa em comunidades de prática e de aprendizagem.

Com o advento da tecnologia e sua ligação com a educação, diversas aplicações foram desenvolvidas para oferecerem suporte a atividades relacionadas a aprendizagem. E o contínuo desenvolvimento da tecnologia em diversas áreas foi criando novas vertentes de aplicações educacionais integrando essas novas tecnologias, sejam estratégias de gamificação, chat's ou até mesmo Tutoria Inteligente com base na Inteligência Artificial (IA) moderna.

## 2.2 Sistemas Tutores Inteligentes

Os Sistemas Tutores Inteligentes (STI) tem sua origem ligada a Inteligência Artificial (IA). Na década de 1950, a expectativa de como a IA iria evoluir acabou frustrando parte dos pesquisadores, que aguardavam máquinas autônomas e inteligentes. Mesmo com a evolução do poder computacional das máquinas esse avanço não aconteceu. Parecia razoável assumir que, sendo criadas máquinas com capacidade de pensar, elas poderiam também realizar tarefas associadas ao pensamento humano como, por exemplo, o ensino (GAVIDIA; ANDRADE, 2003).

Os primeiros Sistemas de Tutoria Inteligente (STI) foram os chamados Sistemas de Instrução Assistida por Computador (CAI - *Computer-Assisted Instruction*), que nasceram na década de 1950. Os CAI apresentavam o conteúdo em lições, que não poderiam ser alteradas quanto a ordem ou forma de apresentação e aplicavam reforço negativo no caso de um erro, sendo assim era pouco interativo e limitado em relação a estrutura de apresentação do conteúdo.

Na década de 1970 surgiram as primeiras iniciativas de imitar a interação humana. Estes sistemas ficaram conhecidos como ICAI (*Intelligent Computer Assisted Instruction*) que começaram a utilizar técnicas de IA (ASSIS; PITANGUI; ANDRADE, 2016). Esses sistemas possuem uma estrutura diferenciada de trabalhar com domínios educacionais, visto que além da IA utilizam Psicologia Cognitiva ao conduzir o processo de ensino-aprendizagem (GAVIDIA; ANDRADE, 2003). Uma forma de aumentar a interação de um sistema com o usuário é a partir do uso de hipermídia. Na década de 1990 surgiram as primeiras pesquisas em hipermídia (ASSIS; PITANGUI; ANDRADE, 2016). Essa evolução dos STI's começa a delinear diferentes categorias, sendo cada uma aprimorada ao longo dos anos.

A maioria das técnicas inteligentes nos Sistemas de Tutoria Inteligente, podem ser classificadas em três grupos ou três tecnologias: Sequência Curricular, Suporte Interativo à Solução de Problemas e Solução Inteligente para Análise do Estudante. Todas essas três tecnologias visam apoiar os deveres inteligentes de um professor humano, que não podem ser fornecido por sistemas tradicionais de tutoria não-inteligente. Sequência curricular e Solução Inteligente de Análise do Estudante são as tecnologias mais antigas e melhor estudadas no domínio dos STI's. A maioria dos STI's desenvolvidos durante os primeiros 10 anos de sua história pertence a esses grupos. Já a tecnologia de Suporte Interativo à Solução de Problemas é mais recente, mas também é mais "inteligente" e oferece um melhor suporte (BRUSILOVSKY, 1996).

Dorça *et al.* (2002) afirmam que um aspecto importante em EAD é a assistência personalizada e inteligente, que normalmente já ocorre no ensino presencial. Um outro aspecto a ser observado é que estudantes neste tipo de curso podem apresentar perfis bastante diferenciados. Sendo assim, um determinado curso projetado para um determinado estudante pode não ser adequado a outros estudantes. Este é um aspecto importante, pois cada estudante tem seu próprio ritmo de aprendizagem.

## 2.3 Estilos de Aprendizagem

A importância da assistência personalizada têm se tornado cada vez mais notável, em parte devido a evolução tecnológica que traz sistemas personalizados, pois se mostram mais adequados aos seus usuários, e em parte devido a força que o campo tem ganhado por parte dos pesquisadores e educadores. [Coffield et al. \(2004\)](#), afirma que foram relatados mais de 70 teorias que se desenvolveram ao passar dos anos.

[Herod \(2004\)](#) argumenta que diferentes estudantes possuem diferentes maneiras de aprender. Alguns talvez consigam compreender mais rápido através de imagens, outros talvez prefiram textos e leituras. Alguns trabalham melhor com teorias, outros com experimentos e exemplos. Obtendo esclarecimentos através de diferentes estilos de aprendizagem, cada estilo oferta novos meios para fornecer intervenções que adaptam as necessidades individuais. Para os estudantes, insights nos próprios estilos permite maior confiança no aprendizado e otimiza os esforços empreendidos.

Estudantes adquirem e processam informações baseado nos seus estilos de aprendizagem ([FELDER; SILVERMAN et al., 1988](#)). A identificação de estilos de aprendizagem é importante pois auxilia na melhoria do desempenho de aprendizagem, aumenta a motivação e satisfação, e reduz o tempo de aprendizagem ([POPESCU, 2010](#)).

Para [Keefe \(1979\)](#) estilos de aprendizagem são compostos pelas características cognitivas, afetivas e fatores psicológicos que servem como indicadores relativamente estáveis de como um estudante percebe, interage com e responde ao ambiente de aprendizado. Um modelo de estilo de aprendizagem classifica os estudantes de acordo com onde eles se encaixam em um número de escalas pertencentes aos modos aos quais eles recebem e processam informação ([FELDER; SILVERMAN et al., 1988](#)). [Keefe \(1979\)](#) ainda define como “a composição de características cognitivas, afetivas e fatores psicológicos que servem como indicadores relativamente estáveis de como um estudante percebe interage com, responde para os ambientes de aprendizagem”.

Estilo de Aprendizagem de acordo com [MacKeracher \(2004\)](#) é a maneira que as pessoas:

- recebem uma informação;
- selecionam determinadas informações para posterior processamento;
- usam significados, valores, habilidades, estratégias para resolver problemas, tomar decisões e criar novos significados e
- alteram qualquer ou todos os processos ou estruturas descritos nesta lista.

### 2.3.1 Detecção de Estilos de Aprendizagem

A detecção do EA dos estudantes pode ser feita de diversas maneiras, sendo que, a mais tradicional é a utilização de questionários e pesquisas. Normalmente os questionários

são preenchidos pelos próprios alunos, sendo uma avaliação da sua conduta segundo suas próprias convicções. [Viola et al. \(2006\)](#) alerta que questionários apresentam limitações devido a inconfiabilidade dos dados das respostas recebidas, seja intencionalmente ou não. Alguns dos aspectos negativos deste modo de detecção são apresentados por [Feldman, Monteserin e Amandi \(2014\)](#):

- preencher questionários é uma tarefa tediosa;
- estudantes tendem a fazer escolhas arbitrárias, por não saber a importância do questionário;
- podem ser influenciados pela forma como o questionário é apresentado;
- os questionários assumem que os estudantes conheçam suas preferências, fato que nem sempre ocorre e
- por ser estático, considera o estilo de aprendizagem apenas no momento.

Essas desvantagens encorajaram um número crescente de pesquisadores a integrar o quadro de estilos de aprendizagem em sistemas de e-learning. Os sistemas de *e-learning*, permitem aos pesquisadores observar os comportamentos dos alunos ao longo do processo de aprendizagem. Com o uso de mineração de dados e algoritmos computadorizados, torna-se possível identificar e analisar rapidamente tendências em grandes conjuntos de dados. Essa perspectiva fornece oportunidades para desenvolver uma nova estrutura, afim de observar e medir estilos de aprendizagem através do comportamento on-line. Os estilos de aprendizagem são também fontes úteis para desenvolver sistemas adaptativos de *e-learning* que efetivamente personaliza os recursos de aprendizagem para as necessidades de aprendizagem dos indivíduos ([TRUONG, 2016](#)).

Alguns dos aspectos positivos do uso de sistemas automatizados em relação as abordagens tradicionais, é apontado por [Feldman, Monteserin e Amandi \(2014\)](#):

- as informações são obtidas por meio da interação com o sistema educacional, sendo um retrato mais fiel ao comportamento do estudantes;
- o não acumulo de trabalho desnecessário por parte dos estudantes, como: responder questionários ou prover feedback explícito sobre suas preferências;
- maior potencial de precisão e menor probabilidade de erros simples;
- permite que o estudante foque no aprendizado, ao invés de perder tempo respondendo questionários e perdendo tempo provendo feedback.

O processo de detecção dos estilos de aprendizagem consiste em construir um modelo que descreva as preferências de aprendizagem do estudante enquanto ele usa o sistema educacional ([FELDMAN; MONTESERIN; AMANDI, 2014](#)).

### 2.3.1.1 Categorização dos Estilos de Aprendizagem

Herod (2004) afirma que tem havido um crescimento da pesquisa sobre o tema dos estilos de aprendizagem na última década, e o resultado tem sido inúmeras maneiras de categorizar estilos de aprendizagem. Em sua abordagem, eles são agrupados em três categorias:

- **Domínio físico** - estilos visual, auditivo e motor;
- **Domínio cognitivo** - concreto, abstrato, seqüencial, estilos aleatórios;
- **Domínio afetivo** - interno e externo psicológico e fisiológico fatores que afetam a forma como nos sentimos.

Segundo Coffield *et al.* (2004) nos últimos 30 anos, foram desenvolvidas mais de 70 teorias, sendo que alguns deles podem se sobrepôr, como por exemplo o de Felder-Silverman que em algumas dimensões se assemelham aos modelos de Kolb e Riding. Coffield *et al.* (2004) ainda afirma que a maioria das teorias de estilos de aprendizagem sofre em termos de validade e confiabilidade. Consequentemente, não há uma teoria que supera as outras.

## 2.4 Modelos de Estilos de Aprendizagem

Truong (2016) ressalta que todos os estilos de aprendizagem mais utilizados pertencem ao mesmo grupo de teorias, os que propõe que EA's são indicadores bastante estáveis, mas que podem mudar ao longo do tempo, afirmação também feita por Coffield *et al.* (2004). Em outras palavras, o grupo que pressupõe que os EA's não são estáticos, nem mudam com grande frequência parece ser favorecido sobre os outros no ambiente on-line. Truong (2016) diz que a escolha por um desses modelos, nem sempre é clara e bem embasada. Apenas um pequeno número dos artigos citados por ele inclui alguma fundamentação teórica por trás de suas aplicações.

### 2.4.1 Kolb

Um dos modelos citados por Truong (2016) é o chamado Inventário de estilos de aprendizagem de Kolb (1981).

Kolb criou um instrumento chamado Inventário de Estilos de Aprendizagem (*Learning Style Inventory* - LSI) projetado para auxiliar estudantes a entender o processo de experiência de aprendizado e seus EA's pela experiência. Feldman, Monteserin e Amandi (2014) afirmam que foram publicadas cinco versões do LSI nos últimos 35 anos .

Kolb propõe um modelo baseado na Teoria de Aprendizagem Experiencial (KOLB, 1981), teoria que descreve um processo de aprendizagem com base em experiências concretas. Essas experiências são seguidas por reflexão e observação, guiando à uma formulação de abstração de conceitos e generalizações, implicações que depois são testadas em novas situações através de experimentação ativa. Esse processo de quatro estágios é um fundamento do modelo



de Kolb, que define os seguintes tipos de estilos de aprendizagem (FELDMAN; MONTESERIN; AMANDI, 2014):

- **Acomodador:** Descreve estudantes que fazem coisas ativamente, aprendem fazendo, tentativa e erro, executando planos e experimentos, e se envolvendo em novas experiências.
- **Divergente:** Descreve estudantes que preferem situações concretas em muitas perspectivas diferentes.
- **Convergente:** Descreve estudantes que gostam de encontrar aplicações práticas para as ideias, resolução de problemas e tomadas de decisão.
- **Assimilador:** Descreve estudantes que gostam de raciocínio indutivo e assimilando observações isoladas em explicações integradas.

Germanakos *et al.* (2008) e Truong (2016) sugerem que teorias como a de Kolb são complexas e fortemente correlacionadas com as teorias da personalidade e, portanto, não são adequadas, nem facilmente quantificadas.

#### 2.4.2 Biggs

O modelo proposto por Biggs (1987) analisa a abordagem dos estudantes para o aprendizado. Basicamente, uma abordagem para aprendizado descreve o que os estudantes fazem quando eles vão aprender e como fazem. Biggs identificou três abordagens:

- **Superficial:** O propósito principal desta abordagem é encontrar os requisitos mínimos, o equilíbrio entre esforçar demais e falhar.
- **Profunda:** Estudantes dessa abordagem estudam para atualizar os interesses e competências em particular assuntos acadêmicos.
- **Objetiva:** Baseia-se na competição e na valorização do ego, obtendo altas notas ou ele não se interessa.

Os profissionais da educação usam o Inventário de Estilos de Aprendizagem de Biggs (*Biggs Inventory Learning Style - BILS*) para identificar a abordagem dos estudantes. O BILS é constituído por uma lista de declarações sobre estratégias de estudo, motivação e atitudes. Ele inclui 120 declarações relativas aos estudos e pesquisa (FELDMAN; MONTESERIN; AMANDI, 2014).

### 2.4.3 Felder

Feldman, Monteserin e Amandi (2014) afirmam que o modelo de Felder é baseado nas ideias de Kolb e Myers-Biggs. Segundo Felder, Silverman *et al.* (1988) o processo de aprendizado pode ser melhorado se o estilo de ensino dos educadores são compatíveis ao estilo de aprendizagem dos estudantes. A proposta do modelo de Felder, Silverman *et al.* (1988) é que os estudantes são caracterizados por valores em quatro dimensões que descrevem o modo como funciona o processo de aprendizado. O modelo de Felder tem sido amplamente utilizado em sistemas educacionais principalmente devido ao fornecimento de um instrumento que permite aos praticantes da educação quantificar os estilos de aprendizagem dos estudantes (FELDMAN; MONTESERIN; AMANDI, 2014).

O modelo de Felder tem quatro dimensões (com tipos opostos de estilo de aprendizagem):

- **Processamento:** Essa dimensão descreve a maneira como a informação é processada e transformada em conhecimento. Suas dimensões são:
  - *Ativo:* estudantes ativos não aprendem muito em situações que requerem passividade. Eles trabalham bem em grupo e tendem a ser experimentalistas.
  - *Reflexivo:* estudantes reflexivos não aprendem muito em situações que não fornecem oportunidade de pensar a respeito da informação apresentada. Eles trabalham bem melhor sozinhos ou com poucas pessoas e tendem a ser teóricos.
- **Percepção:** Essa dimensão está relacionada ao tipo de informação que os estudantes preferem compreender. As dimensões possíveis nela são:
  - *Sensitiva:* gostam de fatos, dados e experimentos. Eles gostam de resolver problemas por métodos padronizados e não gostam de “surpresas”. São pacientes com detalhes, mas não gostam de complicações. Sensores são bons para memorizar fatos e cuidados, mas podem ser lentos.
  - *Intuitiva:* intuitivos preferem princípios e teorias. Eles gostam de inovação e não gostam de repetição. Eles ficam entediados com detalhes e complicações são bem-vindas. Intuitivos são bons em aprender novos conceitos e são rápidos, mas podem ser descuidados.
- **Entrada:** Essa dimensão considera o modo como os estudantes preferem receber informação externa. As dimensões presentes são:
  - *Visual:* estudantes visuais lembram-se melhor do que veem: fotos, diagramas, fluxogramas, linhas temporais, filmes, demonstrações.
  - *Verbal:* estudantes verbais lembram-se muito melhor do que eles ouvem e mais ainda daquilo que ouvem e então dizem.

- **Compreensão:** Essa dimensão descreve o modo como estudantes avançam em direção ao conhecimento. Os estilos de aprendizagem dessa dimensão são:
  - *Sequencial:* estudantes sequenciais seguem um raciocínio linear do processo quando solucionam problemas e podem trabalhar com material quando eles entendem parcialmente ou superficialmente.
  - *Global:* estudantes globais fazem pulos intuitivos e podem ser incapazes de explicar como eles chegaram a solução. Eles podem talvez ter grande dificuldade em entender informações parciais.

Como afirmado por [Viola et al. \(2006\)](#), o *Index of Learning Styles* ou Índice de Estilos de Aprendizagem (ILS) é usado para detectar o grau (Fraco, Moderado ou Forte) e a preferência do estudante em cada dimensão no modelo de Felder. Esse instrumento é um questionário com 44 itens, proposto por [Soloman e Felder \(1999\)](#). O questionário tem 11 questões para cada dimensão e cada item tem duas opções mutuamente exclusivas. Assim, as preferências de aprendizagem do estudante são expressas por valores que variam entre -11 e +11 por dimensão. Se um estudante marca na escala entre -3 e +3, ele/ela é muito bem balanceada nos dois estilos da dimensão. Do contrário, o estudante tem uma preferência moderada/forte por um dos estilos de aprendizagem da dimensão ([FELDER; BRENT, 2005](#)).

O modelo de estilos de aprendizagem de Felder e Silverman é o mais referenciado no campo de detecção automática de estilos de aprendizagem. Na pesquisa realizada por [Feldman, Monteserin e Amandi \(2014\)](#) 70% dos trabalhos pesquisados fazem uso desse modelo, e na pesquisa realizada por [Truong \(2016\)](#) 70,6% fazem o uso desse modelo.

Alguns autores que fazem uso desse modelo trazem justificativas que servem como base para compreender melhor o motivo da preferência desse modelo em aplicações.

[Germanakos et al. \(2008\)](#), propuseram-se a aplicar a teoria de Felder-Silverman como uma escala distintiva pela correspondência a diferentes aspectos do processo de aprendizagem.

[Feldman, Monteserin e Amandi \(2014\)](#) justifica sua escolha de se concentrar no estilo particularmente de percepção, afirmando que o mesmo mostrou forte ligação com outros fatores importantes, tais como preferências de carreira, aptidões e estilos de gestão.

[Dorça et al. \(2013\)](#), além disso, argumentaram que Felder-Silverman se destacou por combinar diferentes modelos de estilos de aprendizagem principais.

Segundo Viola ([VIOLA et al., 2006](#)), apesar de existirem outros Modelos de Estilos de Aprendizagem, o FLSM (Felder-Silverman Learning Styles Models) é o mais utilizado em ambientes eletrônicos de aprendizagem (Electronic Learning Environments - ELEs). Isso graças a descrição detalhada das dimensões e a noção do nível preferências de cada nível - Forte, Moderado, Fraco.

## 2.5 Inteligência Artificial

A evolução da IA foi crucial para o desenvolvimento dos STI como apresentados hoje. A detecção automática dos EA's em um Sistema de Aprendizagem Inteligente para a Educação(SAIE), faz uso de alguns conceitos da IA, bem como algumas técnicas e algoritmos, que possibilitam que a detecção aconteça automaticamente e dinamicamente. Alguns desses conceitos, bem como outros aspectos relevantes são apresentadas nessa seção.

### 2.5.1 Definição de Inteligência Artificial

Diversos autores tentaram dar uma definição para o termo Inteligência Artificial, porém, em sua grande maioria, nenhum afirma que a definição seja imutável ou que não possa ser revista. [Coppin \(2004\)](#) afirma que definir a palavra “inteligência” é uma questão complexa com uma resposta não bem definida que confunde biólogos, psicólogos e filósofos por séculos. [Rich e Knight \(1991\)](#) não usam o termo inteligência, trazendo assim uma definição bastante interessante. Definem, como “o estudo de como fazer os computadores realizarem tarefas que, no momento, as pessoas fazem melhor.”, afirmando em seguida que essa exposição é efêmera, porque se baseia no estado atual da computação. Uma definição que se encaixa de forma bem consistente com o presente trabalho, é a usada pelo próprio [Coppin \(2004\)](#), “Inteligência artificial envolve o uso de métodos baseados no comportamento inteligente de humanos e outros animais para resolver problemas complexos.” Dado a aplicação do presente trabalho, que usa uma metaheurística que tem como base replicar o comportamento da videira, a definição é bastante precisa e útil. Uma outra definição possível é considerar a IA como o estudo da aplicação de padrões comportamentais ou estruturais que, segundo a compreensão humana, tendem a seguir uma lógica que se assemelha ao comportamento humano, para a realização de tarefas.

### 2.5.2 Origem da IA

A IA ganhou grande notoriedade a partir da década de 1950, quando em uma conferência no campus do Dartmouth College em Hanover - USA, John MacCarthy cunhou formalmente tanto o termo Inteligência Artificial, quanto o campo de pesquisa ([ZUBEN, 2013](#)). Porém a primeira referência a uma máquina que possui comportamentos humanos, é incerta, visto as referências desde poemas épicos da mitologia grega como, por exemplo, Hefesto - deus dos ferreiros e atividades com metais - que construía assistentes de metal e dotava-as de inteligência. Além disso outros escritos trouxeram essa temática, ressaltando entre estes, ficções como Frankenstein (*Frankenstein: or the Modern Prometheus*), *Rossum's Universal Robots* e as obras de Isaac Asimov ([OLIVEIRA, 2016](#)). Apesar do foco inicial em robôs, esse não é o único eixo de pesquisa da IA, também trata-se da compreensão dos processos inteligentes na natureza e a ação usando computadores como dispositivos experimentais ([RUSSELL; NORVIG; INTELLIGENCE, 1995](#)).

Alguns eventos marcaram fortemente a evolução da IA ao longo dos anos, alguns deles são (SOMA; SHANKER, 2016):

**1957** - Frank Rosenblatt desenvolve o Perceptron, uma rede neural artificial inicial que permite o reconhecimento de padrões com base em uma rede de aprendizado de computador de duas camadas.

**1958** - John McCarthy desenvolve a linguagem de programação Lisp, que se torna a linguagem de programação mais popular usada na pesquisa de inteligência artificial.

**1961** - O primeiro robô industrial, Unimate, começa a trabalhar em uma linha de montagem em uma fábrica da General Motors em Nova Jersey.

**1961** - James Slagle desenvolve SAINT (Symbole Automatic INTEgrator), um programa heurístico que resolveu problemas de integração simbólica em cálculos de calouro.

**1965** - Herbert Simon prevê que "as máquinas serão capazes, dentro de vinte anos, de fazer qualquer trabalho que um homem possa fazer".

**1965** - Hubert Dreyfus publica "Alquimia e AI", argumentando que a mente não é como um computador e que havia limites para além dos quais a IA não progrediria.

**1965** - Joseph Weizenbaum desenvolve ELIZA, um programa interativo que realiza um diálogo em inglês em qualquer tópico.

**1965** - Edward Feigenbaum, Bruce G. Buchanan, Joshua Lederberg e Carl Djerassi começam a trabalhar no DENDRAL na Universidade de Stanford. O primeiro sistema especializado automatizou o processo de tomada de decisão e o comportamento de resolução de problemas de químicos orgânicos, com o objetivo geral de estudar a formação de hipóteses e construir modelos de indução empírica na ciência.

**1966** - Shakey, o robô é o primeiro robô móvel de propósito geral a poder raciocinar sobre suas próprias ações. Em um artigo da revista Life 1970 sobre esta "primeira pessoa eletrônica", Marvin Minsky é citado dizendo com "certeza": "De três a oito anos teremos uma máquina com a inteligência geral de um ser humano médio".

**1970** - O primeiro robô antropomórfico, o WABOT-1, é construído na Universidade Waseda no Japão. Consistia em um sistema de controle de membros, um sistema de visão e um sistema de conversação.

**1973** - James Lighthill relata ao British Science Research Council sobre a pesquisa estatal de inteligência artificial, concluindo que "em nenhuma parte do campo as descobertas produzidas até agora produziram o impacto prometido", levando a redução drástica do apoio governamental para as pesquisas em IA .

**1979** - O Stanford Cart atravessa com sucesso uma sala cheia de cadeiras sem intervenção humana em cerca de cinco horas, tornando-se um dos primeiros exemplos de um veículo autônomo.

**1984** - Na reunião anual da AAAI, Roger Schank e Marvin Minsky advertem sobre o "Inverno da IA", prevendo um estouro iminente da bolha de IA (o que aconteceu três anos depois), semelhante à redução do investimentos em IA e do financiamento da pesquisa em

meados da década de 70.

Diversos especialistas afirmaram, como Herbert Simon em 1965, que em poucos anos, seria possível obter uma máquina inteligente tão ou até mais capaz do que um ser humano. Com o tempo, observou-se que os esforços para produzir tal máquina superavam em muito a estimativa antes percebida. Com os problemas mais complexos, parte dos ânimos se esfriaram, dado a complexidade dos mesmos. Os problemas combinatórios, por exemplo, mostraram que cálculos simples com duas ou três variáveis levariam anos para um número maior de variáveis. Tais problemas serão apresentados a seguir, mas antes, faz-se necessário clarear o conceito de complexidade.

### 2.5.3 Análise de Complexidade

A complexidade de um problema é medida de acordo a sua dificuldade inerente, relativo aos recursos necessários para a sua resolução. A complexidade de um problema está relacionada ao tempo ou ao espaço, sendo complexidade espacial o espaço de memória necessário para executar até o fim, e complexidade temporal o tempo que demora a executar (tempo de execução) (OLIVEIRA, 2016). Um método amplamente utilizado para se analisar a complexidade de um algoritmo é a chamada Notação O Grande (Conhecida também como Big-O Notation, Notação Landau, Notação Bachmann–Landau ou ainda Notação Assintótica). Ela descreve o comportamento limitante de uma função quando o argumento tende a um determinado valor ou ao infinito, geralmente em termos de funções mais simples (CARRANO *et al.*, 1998)

Matematicamente, se  $f$  e  $g$  são funções, a notação  $f(n) = O(g(n))$  é usada para expressar o fato de que a taxa de crescimento de  $f$  não é maior do que a de  $g$ , ou seja  $f(n) = O(g(n))$  significa que  $\exists c \forall n (|f(x)| \leq c \cdot |g(n)|)$ . Aqui presume-se que  $f$  e  $g$  são funções com o mesmo domínio e contradomínio. A definição assume ainda que noções de multiplicação e valor absoluto são definidas no contradomínio (AVIGAD; DONNELLY, 2004).

Em relação a um algoritmo  $A$  é  $O$  de  $f(n)$  – denotado  $O(f(n))$  – se a constante  $k$  e  $n_0$  existem tal que  $A$  gaste não mais que  $k * f(n)$  unidades de tempo para resolver um problema de tamanho  $n \geq n_0$ .

Se um Algoritmo  $A$  gasta um tempo proporcional a  $f(n)$  é dito que  $A$  é  $O(f(n))$ . O exemplo a seguir ilustra a definição (CARRANO *et al.*, 1998):

Supondo que um algoritmo gaste  $n^2 - 3 * n + 10$  segundos para resolver um problema de tamanho  $n$ . Se a constante  $k$  e  $n_0$  existem tal que:

- $k * n^2 > n^2 - 3 * n + 10 \forall n > n_0$  o algoritmo é ordem  $n^2$ . De fato, se  $k$  é 3 e  $n_0$  é 2,  $3 * n^2 > n^2 - 3 * n + 10 \forall n > 2$  Assim o algoritmo não gasta mais do que  $k * n^2$  unidades de tempo para  $n > n_0$ , portanto é  $O(n^2)$ .

A Figura 1 apresenta os limites mais comumente vistos na aplicação da notação  $O$ , uma hierarquia básica de complexidade da notação  $O$ , sendo da menor complexidade ( $O(1)$ ) até a maior ( $O(n!)$ ).

$\mathcal{O}(1)$ : ordem constante $\mathcal{O}(\log_a n)$ : ordem logarítmica $\mathcal{O}(n)$ : ordem linear $\mathcal{O}(n \log_a n)$ : $n \log n$ $\mathcal{O}(n^2)$ : ordem quadrática $\mathcal{O}(n^3)$ : ordem cúbica $\mathcal{O}(n^r)$ : ordem polinomial $r \geq 0$ $\mathcal{O}(b^n)$ : ordem exponencial $b > 1$ $\mathcal{O}(n!)$ : ordem fatorial.
---

Figura 1 – Hierarquia da notação O (COELHO; NETO, 2010).

Ainda sobre a complexidade, existem duas grandes classes de problemas, os tratáveis e os intratáveis. Um problema tratável pode ser solucionado por um computador em um tempo aceitável, já problemas intratáveis podem levar séculos mesmo para entradas muito pequenas.

Utiliza-se um sistema de classes para separação de problemas quanto a sua complexidade. Essas classes são (ORNELAS *et al.*, 2006):

- A classe NP, conjunto de todos os problemas que podem ser resolvidos por algoritmos não deterministas em tempo polinomial.
- A classe P, conjunto de todos os problemas que podem ser resolvidos por algoritmos deterministas em tempo polinomial.

A principal forma de verificar que um determinado problema está em NP, é apresentar um algoritmo não determinista que execute em tempo polinomial para resolver o problema. Uma outra maneira é encontrar um algoritmo determinista polinomial para verificar que uma dada solução é válida.

- Há ainda a classe NP-Completo, essa classe é um subconjunto de NP, eles são classificados como problemas que possuem uma roupagem diferente, porém uma raiz igual. Por esse motivo, no caso da resolução de qualquer destes em tempo polinomial, então todos outros problemas NP-completos terão soluções em tempo polinomial. Atualmente, ainda não se conhece nenhum algoritmo que resolva um problema NP-completo em tempo polinomial (ORNELAS *et al.*, 2006).

Problemas da classe NP-Completo são considerados os problemas mais complexos dentro da classe NP. Ainda não se sabe se os problemas em NP podem ser todos resolvidos em tempo polinomial, porém para os problemas dessa classe em específico, ainda não existe algoritmo que o faça. Entre os problemas da classe NP, estão os problemas de otimização combinatória, dos quais falaremos a seguir.



### 2.5.4 Otimização Combinatória

Os algoritmos de otimização combinatória são uma área de grande importância para a computação e para outras diversas áreas. Eles possibilitam a análise e otimização de problemas em diversas campos, desde gerenciamento de estoque a mapeamento genético.

Um problema de otimização combinatória pode ser definido por um conjunto  $E = \{1, \dots, n\}$ , um conjunto de soluções viáveis  $F \subseteq 2^E$  e uma função objetivo  $f : 2^E \rightarrow \mathbb{R}$ , todos definidos para cada problema específico (LOPES; RODRIGUES; STEINER, 2013).

Exemplos de problemas de Otimização Combinatória (OC) são: o Problema do Caixeiro Viajante, o Problema da Cobertura Mínima por Conjuntos, o Problema da Mochila, o Problema da Árvore de Steiner, dentre outros. Esses problemas possuem aplicações em diversas áreas, tais como projeto de redes de telecomunicações, análise de dados, projeto de circuitos impressos, empacotamento de contêineres, roteamento de veículos, análise de cadeias de DNA, etc. (CARNEIRO *et al.*, 2014).

Encontrar comprovadas soluções ótimas em problemas de otimização combinatória é uma tarefa árdua, mas muito progresso vem sendo alcançado com o emprego de técnicas como *branch and bound* (BALAKRISHNAN; BOYD; BALEMI, 1991) (BOYD; MATTINGLEY, 2007), plano de corte e programação dinâmica, assim como soluções aproximadas via algoritmos aproximados. Porém muitos problemas de otimização combinatória se beneficiam de métodos heurísticos, esses geralmente são embasados em alguma metaheurística, e que rapidamente produzem soluções de boa qualidade sem necessariamente garantir a otimalidade. Neste sentido, muitas heurísticas modernas para otimização combinatória seguem os padrões descritos no Guidelines (HERTZ; WIDMER, 2003), tais como: algoritmos genéticos (HOLLAND, 1992)(MITCHELL, 1995), *simulated annealing* (BERTSIMAS; TSITSIKLIS, 1993), busca tabu (GLOVER; LAGUNA; MARTI, 2003) (GLOVER, 1989), *variable neighborhood search* (MLADENOVIĆ; HANSEN, 1997) (AVANTHAY; HERTZ; ZUFFEREY, 2003), *scatter search* (MARTÍ; LAGUNA; GLOVER, 2006), *path relinking* (YAGIURA; IBARAKI; GLOVER, 2006), *iterated local search* (LOURENÇO; MARTIN; STUTZLE, 2003), *ant colony optimization* (DORIGO; BIRATTARI; STUTZLE, 2006), *swarm optimization* (KHANESAR; TESHNEHLAB; SHOOREHDELI, 2007) (EBERHART; KENNEDY, 1995) (KENNEDY; EBERHART, 1997) e procedimento de busca guloso, aleatório e adaptativo (LOPES; STEINER, 2013).

#### 2.5.4.1 Metaheurísticas

O termo heurística tem sua origem no grego *heuriskein* = descobrir, do mesmo radical que deu origem a palavra heureka, imortalizada pelo matemático e filósofo grego Arquimedes. Uma heurística é um procedimento algorítmico desenvolvido através de um modelo cognitivo, usualmente através de regras baseadas na experiência dos desenvolvedores (CORDENONSI *et al.*, 2007).

Alguns problemas possuem um número gigantesco de soluções possíveis, fazendo



com que seja necessário muitos dias, meses ou anos para encontrar a solução ótima. A aplicação de métodos exatos tem como intuito, encontrar todas as possíveis soluções para um problema, ou realizam combinações para encontrar a melhor solução possível. Tendo isso em vista, para esse tipo de problema, muitas vezes não é possível o uso de um método exato. As heurísticas, por outro lado, utilizam estratégias, procedimentos e métodos aproximativos, visando encontrar soluções boas, não necessariamente a melhor, dentro de um tempo computacional aceitável.

[Dorigo, Birattari e Stutzle \(2006\)](#) afirmam que metaheurística é um conjunto de conceitos algorítmicos que podem ser usados para definir métodos heurísticos aplicáveis a um vasto conjunto de problemas diferentes. Outra definição é dada por [LEJBMAN, 2009](#) que diz que uma metaheurística é um conjunto de conceitos que pode ser utilizado para definir métodos não exatos (heurísticos) aplicáveis a uma ampla gama de problemas diversos. Então podemos concluir que uma metaheurística pode ser vista como uma estrutura algorítmica geral que pode ser empregada na resolução de diferentes problemas, sendo eles de otimização ou não. Elas podem ser adaptadas para o tratamento de cada problema específico, passando por um número relativamente reduzido de modificações.

A ordem de complexidade para encontrar a solução ótima de um determinado problema cresce consideravelmente a medida que o tamanho do espaço de busca do problema cresce. Por espaço de busca ou espaço de estados, entende-se um conjunto  $S$  de estados e por um conjunto  $A$ , sendo que as ações  $A$  mapeiam um estado do conjunto  $S$  em outro do mesmo conjunto.

O uso de metaheurísticas tem aumentado significativamente a capacidade de encontrar soluções de alta qualidade, para os problemas de otimização combinatória, em um tempo razoável. Em geral, tais algoritmos não asseguram a obtenção da solução ótima, porém, avaliações estatísticas mostram que, com boa regularidade, eles retornam soluções de boa qualidade e em tempo computacional aceitável ([LOPES; STEINER, 2013](#)).

[Gendreau e Potvin \(2005\)](#) descrevem as propriedades fundamentais que caracterizam uma metaheurística:

- Metaheurísticas são estratégias que “guiam” o processo de busca.
- Tem como objetivo explorar o espaço de busca de forma eficiente a fim de encontrar a solução ótima ou uma próxima a esta.
- Técnicas que constituem metaheurísticas vão de simples procedimentos de buscas locais a complexos processos de aprendizado.
- Metaheurísticas são aproximadas e normalmente não são determinísticas.
- Algumas vezes incorporam mecanismos para evitar o estacionamento em áreas confinadas do espaço de busca.
- Metaheurísticas não são específicas para um determinado problema.

- Metaheurísticas podem usar o conhecimento específico de domínio sob a forma de heurísticas que são controladas por estratégias de nível superior.

Hoje as mais avançadas metaheurísticas usam a experiência de pesquisa (incorporada como uma forma de memória) para guiar a busca. Em suma, podemos dizer que as metaheurísticas são estratégias de alto nível para explorar espaços de busca usando métodos diferentes.

Ao longo dos últimos anos, grande parte do esforço das pesquisas em IA tiveram como foco o desenvolvimento de metaheurísticas, usando principalmente dois princípios: busca local e busca populacional.

A busca local é um método onde a exploração intensa do espaço de soluções é executada, movendo a cada passo de uma solução corrente para outra solução promissora na vizinhança. *Simulated Annealing*, Busca Tabu e o *Variable Neighbourhood Search* (VNS) são os mais famosos métodos de busca local (HERTZ; WIDMER, 2003).

A busca populacional consiste em encontrar e manter uma gama de boas soluções e combiná-las, a fim de produzir soluções ainda melhores. Exemplos clássicos são algoritmos genéticos (HERTZ; WIDMER, 2003).

#### 2.5.4.2 Metaheurísticas Bio-inspiradas

As metaheurísticas bio-inspiradas são um grupo de técnicas interno as metaheurísticas, que se valem de inspirações biológicas, para a construção de estratégias de busca. As inspirações podem ser encontradas nos mais diversos comportamentos, sendo então abstraídos e moldados, fornecendo então meios de aplicar esse comportamento aos mais diversos problemas. Alguns exemplos de inspirações utilizados são: Morcegos, Formigas, Lobos, Plantas daninhas, Videira, Vagalume, entre outros. Boa parte dessas são técnicas bio-inspiradas que seguem um comportamento de população, sendo chamadas de buscas populacionais.

Métodos de buscas populacionais são técnicas de soluções que tem um grupo de indivíduos inicialmente e faz com que eles sejam moldados de acordo com algumas regras previamente estabelecidas. Normalmente a cada iteração, períodos de auto adaptação são intercalados com períodos de cooperação (HERTZ; WIDMER, 2003).

Uma metaheurística populacional inicia o processo de otimização com um conjunto de soluções, denominado população inicial, sendo que cada indivíduo da população representa uma solução viável para o problema. Iterativamente ela gera novos indivíduos e troca a população corrente por uma nova população de soluções (TALBI *et al.*, 2012) regras previamente estabelecidas são a base da evolução desses indivíduos, são elas que determinam as alterações que os mesmos sofrerão ao longo da existência.

Existem duas formas de evolução dos indivíduos que fazem com que os mesmos sejam alterados, são os períodos de auto adaptação e os períodos de cooperação. A auto adaptação significa que os indivíduos evoluem de forma independente, enquanto a cooperação implica uma troca de informações entre os indivíduos. Muitos algoritmos diferentes podem ser descritos

por essa abordagem, por exemplo, os operadores de seleção e de cruzamento dos algoritmos genéticos podem ser visto como procedimentos do período de cooperação, enquanto o operador de mutação pode ser visto como procedimento do período de auto adaptação (HERTZ; WIDMER, 2003). Existem diversas metaheurísticas bio-inspiradas, algumas, como o Algoritmo Genético (HOLLAND, 1992) e a Colônia de formigas (DORIGO; BIRATTARI; STUTZLE, 2006), são mais conhecidas devido a eficiência em problemas complexos como os de otimização combinatória.



### 3 REVISÃO DA LITERATURA

Abordagens automáticas de detecção dos EA's ganharam notável dedicação por partes dos pesquisadores nas últimas décadas.

Dado a grande quantidade de artigos relacionados a temática de detecção de EA, realizou-se uma breve análise de um conjunto de artigos desta temática. Para essa análise foram seguidos os seguintes passos:

- A metodologia utilizada para a pesquisa onde são apresentados os padrões utilizado nas buscas, escopo temporal, palavras utilizadas nas buscas, os repositórios que serviram de base e outras características da pesquisa;
- Uma apresentação da estrutura comum dos artigos coletados da temática a ser analisada.
- A descrição de algumas características relevantes e a análise dos artigos obtidos são apresentados a seguir. Abordando a forma como os artigos foram catalogados, qual porcentagem dos artigos pertencem a cada classificação e em seguida levando em consideração os artigos de detecção, divide-se segundo os modelos utilizados e segundo os algoritmos de detecção utilizados.
- Por fim, uma visão sobre a análise realizada, com um parecer a respeito dos dados apresentados.

#### 3.1 Metodologia

Para essa breve revisão de literatura, foram utilizados uma grande variedade de artigos, que trabalham com estilos de aprendizagem, esses foram coletados nas bases: IEEEExplore, Science Direct, RBIE, entre outras.

Foram encontrados um total de 84 artigos. Do total de artigos encontrados, 49 pertencem ao IEEEExplore, 24 ao Science Direct, 7 ao RBIE e 4 de outras bases (Redirecionados de artigos lidos previamente).

Os artigos captados encontram-se distribuídos ao longo dos últimos 10 anos (de 2007 a 2017), sendo considerado esse o escopo temporal de revisão do trabalho.

Devido o principal foco ser a detecção de estilos de aprendizagens, foram utilizadas as seguintes palavras chaves nas buscas, bem como uma grande diversidade das variações e combinações das mesmas: Learning Styles, Estilo de Aprendizagem, Detection of Learning Styles, Detecção de Estilo de Aprendizagem, Students Model, Modelo do Estudante, Intelligent Tutoring System, Sistemas de Tutoria Inteligente, Hypermídia Adaptativa, Adaptative hypermidia, Computer assisted learning e Aprendizado assistido por computador.

## 3.2 Estrutura Frequente dos Artigos

Os artigos analisados apresentam frequentemente:

- **Modelos de Estilos de Aprendizagem:** Normalmente esses seguem uma teoria cognitiva, que serve para traçar o perfil de aprendizagem do estudante. Pode ser utilizado um, mais de um ou modelos personalizados, independentes de uma teoria cognitiva.
- **Técnicas de Detecção de Estilos de Aprendizagem:** Tradicionalmente são técnicas de Inteligência Artificial, que servem para detectar os EA's, para assim modelar o ambiente e adequar o conteúdo. Também pode fazer uso de um ou mais, além de combinações de técnicas.

### 3.2.1 Modelos de Estilos de Aprendizagem

Segundo [Coffield et al. \(2004\)](#) nos últimos 30 anos, foram desenvolvidas mais de 70 teorias, sendo que alguns deles podem se sobrepor, como por exemplo o de Felder-Silverman que em algumas dimensões se assemelham aos modelos de Kolb e Riding. Em segundo lugar, ainda de acordo com Coffield, a maioria das teorias de estilos de aprendizagem sofre em termos de validade e confiabilidade. Consequentemente, não há uma teoria que supera as outras.

[Truong \(2016\)](#) ressalta que todos os estilos de aprendizagem mais utilizados pertencem ao mesmo grupo de teorias, os que propõe que os estilos de aprendizagem são indicadores bastante estáveis, mas que podem mudar ao longo do tempo, afirmação também feita por [Coffield et al. \(2004\)](#). Em outras palavras, este grupo que pressupõe que EA não é fixo, nem mudam muito rapidamente para cada situação parece ser favorecido sobre os outros no ambiente on-line.

A escolha do modelo de EA a ser utilizado tem um grande peso no sistema, pois o processo de detecção consiste justamente na construção do modelo enquanto ele usa o sistema educacional. O modelo diz a forma como o estudante recebe o conteúdo, além de informar se o mesmo é o ideal. A oferta de Objetos de Aprendizagem, que fornece a adaptação do sistema é baseada no modelo escolhido.

Diversos modelos foram aplicados no decorrer dos anos, sendo que alguns foram mais amplamente usados. Entre os modelos existentes, destacam-se os: Felder-Silverman ([FELDER; SILVERMAN et al., 1988](#)), Kolb ([KOLB, 1981](#)), Myers-Briggs ([MCCAULLEY, 1990](#)), VARK ([FLEMING; MILLS, 1992](#)), Gardner ([GARDNER, 2008](#)), Honey-Mumford ([HONEY; MUMFORD, 1989](#)), Briggs ([BIGGS, 1987](#)) e Felder-Solomon ([SOLOMAN; FELDER, 1999](#)).

[Truong \(2016\)](#) diz que a escolha teórica por um desses modelos, nem sempre é clara. Apenas um pequeno número de artigos revisados inclui alguma motivação e intuição por trás de suas aplicações.

### 3.2.2 Técnicas de Detecção de Estilos de Aprendizagem

Um grande número de técnicas de Inteligência Artificial (IA) têm sido propostas para a detecção automática de estilos de aprendizagem. A abordagem de detecção automática de estilos de aprendizagem por dados dirigidos é realizada por uma classificação de algoritmos de IA que leva o modelo do usuário como entrada e retorna as preferências de estilo de aprendizagem do aluno como saída. Já as abordagens baseadas na literatura usam o modelo do usuário para receber dicas sobre as preferências dos estilos de aprendizagem dos estudantes e então aplicam um método para calcular essas preferências do número de palpites correspondentes. Os trabalhos que empregam abordagens baseadas em dados dirigidos aplicam vários algoritmos de classificação de IA para a detecção de estilos de aprendizagem.

A identificação correta dos EA's do estudante é o principal elemento de um Sistema adaptativo inteligente para a educação, pois só assim o conteúdo é apresentado da forma mais adequada ao estudante. Um dos fatores-chaves para o sucesso desses sistemas é a escolha do algoritmo para modelar os processos estocásticos e assim detectar os EA's.

Algumas técnicas para a detecção de estilos de aprendizagem são amplamente usadas na literatura, algumas delas são: Redes Bayesianas (PELIKAN; GOLDBERG; CANTÚ-PAZ, 1999) (SINGH; VALTORTA, 1993), Rede Neurais (ADORF; JOHNSTON, 1990) (BOSE; LI-ANG, 1996), Algoritmo Genético (HOLLAND, 1992), Fuzzy (PASSINO; YURKOVICH; REINFRANK, 1998), Enxame de Partículas (KENNEDY; EBERHART, 1997) (EBERHART; KENNEDY, 1995), Árvore de decisão (KEARNS; MANSOUR, 1996), Cadeia de Markov (GILKS; RICHARDSON; SPIEGELHALTER, 1995), Naive-Bayes (KONONENKO, 1989), QLearning (LITTMAN; BOYAN, 1993), Colônia de Formigas (DORIGO; BIRATTARI; STUTZLE, 2006), etc.

### 3.3 Revisão dos artigos coletados

Foram analisados diversos artigos, sendo alguns são revisões, estudos e aplicações, enquanto outros focam diretamente na Classificação, Modelagem e Detecção, portanto, os artigos foram divididos segundo essa lógica. Essa breve revisão é focada nos artigos que se concentram na Classificação, Modelagem e Detecção de estilos de aprendizado usando diferentes algoritmos informatizados.

Entre os 84 artigos, a maioria dos artigos, 58.3% possuem uma abordagem na Classificação, Modelagem e Detecção de estilos de aprendizado usando diferentes algoritmos informatizados, sendo os outros 41.6% focados em revisões, estudos e aplicações de estilos de aprendizagem.

#### 3.3.1 Teorias de Estilo de Aprendizagem

A Tabela 1 traz os artigos analisados e sintetizados, de acordo com as diretrizes citadas o modelo proposto por Felder, Silverman *et al.* (1988) foi amplamente mais utilizado,

dos 49 artigos catalogados como detecção, ele é utilizado por 39, quase 80% do total.

Entre as outras teorias referenciadas, apenas a teoria de Kolb (1981) foi usada mais de uma vez, sendo usado por Botsios, Georgiou e Safouris (2008) e por Moura *et al.* (2013). Além das teorias, outros autores utilizaram modelos personalizados ou adaptados de acordo com as necessidades encontradas pelos autores.

### 3.3.1.1 Algoritmos de Detecção de Estilos de Aprendizagem

A Tabela 2 apresenta a classificação dos algoritmos de IA mais utilizados nesse levantamento de artigos realizado. Em alguns artigos foram utilizados mais de uma técnica simultaneamente.

O método mais utilizado nos artigos da revisão foi o baseado em regras, sendo utilizado 14 vezes, ou seja, foi utilizado 28.6% das vezes; Sendo seguido pelas Redes Bayesianas que foram utilizadas 11 vezes (22.4); Logo depois as Rede Neurais, com 5 usos (10.2); O Algoritmo Genético e a Lógica Fuzzy foram aplicados 4 vezes cada um (8.17); Já o Enxame de Partículas, a Árvore de decisão, a Árvore-Fuzzy e a Fuzzy-Neural foram utilizados 2 vezes cada um (4.08); Todos os demais foram referenciados apenas uma vez cada.

As Redes Bayesianas, a segunda mais utilizada na literatura, se baseia no teorema de Bayes:

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)} \quad (3.1)$$

O teorema é lido como a probabilidade de A dado B é igual à probabilidade de B dado A vezes a probabilidade de A, dividido pela probabilidade de B. Quando se aplica à classificação de estilos de aprendizagem, os pesquisadores usam a equação para estimar a probabilidade de um usuário pertencer a um determinado estilo dado suas ações.

As Redes Bayesianas apresentaram uma ótima performance na grande maioria das aplicações.

## 3.4 Análise dos artigos revisados

Revisando os 84 artigos, foi possível analisar as abordagens utilizadas nas partes do processo de detecção, categorizando os artigos e contabilizando os usos dos modelos de estilos de aprendizagem e as técnicas abordadas. Algumas importantes considerações podem ser feitas com base nos dados obtidos na revisão.

A teoria cognitiva mais popular foi a de Felder-Silverman, sendo amplamente utilizada por quase 80% dos artigos visitados. Grande parte da motivação tem seus fundamentos na possibilidade de quantificar os estilos de aprendizagem dos estudantes, além de ser mais detalhado. Além disso, por já ser o mais utilizado, o modelo é o que mais possui resultados obtidos, para comparativo com novos problemas, fator que pesa na escolha do modelo para novos trabalhos.



Nos algoritmos de detecção, o mais utilizado é o algoritmo baseado em regras com 27%, sendo que das técnicas de IA destaca-se as Redes Bayesianas, a qual foi empregada em outros 21% . Essa técnica tem apresentado ótimos resultados na maioria dos trabalhos implementados e por isso é empregada frequentemente, inclusive em combinações com outras técnicas da literatura.

Tabela 1 – Teorias de Estilo de Aprendizagem

Teorias de EA	Nº de Artigos	%	Referências
Felder-Silverman	39	79.59	(AHMAD; SHAMSUDDIN, 2010) (AHMAD <i>et al.</i> , 2013) (ÖZPOLAT; AKAR, 2009) (FELDMAN; MONTESERIN; AMANDI, 2014) (ALKHURAJI; CHEETHAM; BAMASAK, 2011) (CARMONA; CASTILLO; MILLÁN, 2008) (GARCÍA <i>et al.</i> , 2007) (GARCÍA; SCHIAFFINO; AMANDI, 2008) (SCHIAFFINO; GARCIA; AMANDI, 2008) (CABADA; Barrón Estrada; Reyes García, 2011) (DORÇA <i>et al.</i> , 2013) (GRAF; KINSHUK; LIU, 2008) (GRAF; LIU, 2009) (GRAF; KINSHUK, 2010) (LATHAM <i>et al.</i> , 2012) (SANGINETO <i>et al.</i> , 2007) (SCOTT <i>et al.</i> , 2014) (WEN <i>et al.</i> , 2007) (AMIR <i>et al.</i> , 2016) (BERNARD <i>et al.</i> , 2017) (CABADA <i>et al.</i> , 2009) (CHANG <i>et al.</i> , 2009) (CROCKETT <i>et al.</i> , 2011) (CROCKETT <i>et al.</i> , 2013) (SILVA; DORÇA, 2014) (DORÇA <i>et al.</i> , 2013) (DORÇA, 2012) (DORÇA <i>et al.</i> , 2013) (ELGHOUCHE <i>et al.</i> , 2016) (HIDAYAT; UTOMO, 2016) (HMEDNA <i>et al.</i> , 2016) (KOLEKAR, 2010) (LESCANO <i>et al.</i> , 2016) (MOKHTAR; ABDULLAH; ZIN, 2011) (REDDY <i>et al.</i> , 2013) (SEVARAC; DEVEDZIC; JOVANOVIĆ, 2012) (SPROCK, 2016) (YANG <i>et al.</i> , 2014) (CROCKETT; LATHAM; WHITTON, 2016)
Kolb	2	4.08	(BOTSIOS; GEORGIU; SAFOURIS, 2008), (MOURA <i>et al.</i> , 2013)
Felder-Solomon	1	2.04	(LIU, 2008)
Myers-Briggs	1	2.04	(BACHARI; ABELWAHED; ADNANI, 2011)
VAK	1	2.04	(HAMTINI; ATEIA, 2015)
Gardner	1	2.04	(MOURA <i>et al.</i> , 2013)
Outros	5	10.20	(FERNANDEZ; PONNUSAMY, 2015) (KASER <i>et al.</i> , 2017) (KHALID; YUSOF; XIANG, 2016) (NEDUNGADI, 2014) (NENKOV <i>et al.</i> , 2016)

Tabela 2 – Algoritmos de Detecção de Estilos de Aprendizagem

Algoritmo de Detecção de EA	Nº de Artigos	Referências
Baseado em Regras	14	(AHMAD; SHAMSUDDIN, 2010) (DORÇA; LIMA, 2013) (SILVA; DORÇA, 2014) (GRAF; KINSHUK; LIU, 2008) (GRAF; LIU, 2009) (GRAF; KINSHUK, 2010) (HAMTINI; ATEIA, 2015) (HIDAYAT; UTOMO, 2016) (LATHAM <i>et al.</i> , 2012) (LIU, 2008), (REDDY <i>et al.</i> , 2013) (SANGINETO <i>et al.</i> , 2007) (SCOTT <i>et al.</i> , 2014), (WEN <i>et al.</i> , 2007)
Redes Bayesianas	11	(AHMAD; SHAMSUDDIN, 2010) (ALKHURAJI; CHEETHAM; BAMASAK, 2011) (BACHARI; ABELWAHED; ADNANI, 2011) (BOTSIOS; GEORGIOU; SAFOURIS, 2008) (CARMONA; CASTILLO; MILLÁN, 2008) (ELGHOUGH <i>et al.</i> , 2016) (GARCÍA <i>et al.</i> , 2007) (GARCÍA; SCHIAFFINO; AMANDI, 2008) (KASER <i>et al.</i> , 2017) (NEDUNGADI, 2014) (SCHIAFFINO; GARCIA; AMANDI, 2008)
Redes Neurais	5	(BERNARD <i>et al.</i> , 2017) (CABADA; Barrón Estrada; Reyes García, 2011) (HMEDNA <i>et al.</i> , 2016) (KOLEKAR, 2010) (NENKOV <i>et al.</i> , 2016)
Algoritmo Genético	4	(BERNARD <i>et al.</i> , 2017), (DORÇA, 2012) (DORÇA <i>et al.</i> , 2013), (LESCANO <i>et al.</i> , 2016)
Fuzzy	4	(CROCKETT <i>et al.</i> , 2013), (KHALID; YUSOF; XIANG, 2016) (MOKHTAR; ABDULLAH; ZIN, 2011), (SPROCK, 2016)
Enxame de Partículas	2	(BERNARD <i>et al.</i> , 2017) (MOURA <i>et al.</i> , 2013)
Árvore de decisão	2	(ÖZPOLAT; AKAR, 2009) (AHMAD; SHAMSUDDIN, 2010)
Árvore-Fuzzy	2	(CROCKETT <i>et al.</i> , 2011) (CROCKETT; LATHAM; WHITTON, 2016)
Fuzzy-Neural	2	(CABADA <i>et al.</i> , 2009) (SEVARAC; DEVEDZIC; JOVANOVIĆ, 2012)
Algoritmo Genético com KNN	1	(CHANG <i>et al.</i> , 2009)
Cadeia de Markov	1	(FERNANDEZ; PONNUSAMY, 2015)
Naive-Bayes	1	(FELDMAN; MONTESERIN; AMANDI, 2014)
QLearning	1	(DORÇA; LIMA, 2013)
Reconhecimento de padrões c/ SA	1	(YANG <i>et al.</i> , 2014)
Colônia de Formigas	1	(BERNARD <i>et al.</i> , 2017)



## 4 METODOLOGIA

A metodologia de desenvolvimento pode ser definida como a abordagem organizada para se atingir um objetivo seguindo um conjunto de procedimentos predefinidos. Sendo assim, nesse capítulo, são apresentados alguns dos procedimentos e a estratégia utilizada.

Alguns dos aspectos dessa estratégia são indispensáveis, afim de proporcionar uma melhor compreensão e facilitar a replicação dos resultados aqui apresentados. São esses: a definição da técnica e do modelo utilizado, além da forma como esse segundo é estruturalmente representado no algoritmo.

No capítulo três foram apresentados algoritmos e métodos comumente aplicados na literatura. Dado o grande número de opções e combinações possíveis, a próxima seção explicitará qual modelo de EA e qual técnica foram empregados, justificando a escolha dos mesmos.

### 4.1 Modelo de Estilo de Aprendizagem de Felder e Silverman

Primeiramente, faz-se necessário a definição do Modelo de Estilo de Aprendizagem a ser utilizado, sendo então o modelo de [Felder, Silverman \*et al.\* \(1988\)](#) o escolhido. A justificativa encontra-se principalmente na ampla utilização da mesma na literatura e na facilidade de quantificar os EA's. A vasta maioria dos artigos empregam esse modelo com resultados significativos, facilitando muito a comparação afim de verificar a efetividade das técnicas.

O modelo inicialmente proposto por Felder contava com 16 ( $2^4$ ) EA, sendo quatro dimensões cada uma contendo dois possíveis valores absolutos. Para explorar mais profundamente as possibilidades de cada dimensão, Felder desenvolveu o *Index of Learning Styles* ou Índice de Estilos de Aprendizagem (ILS). Com isso, cada dimensão pode ser classificada com valores extremos, médios ou neutro, incorporando alunos neutros e alunos com uma tendência a um estilo, mas que possui características de outro. Com essas alterações, é possível atribuir um de 5 valores a cada dimensão (percepção, entrada, processamento e compreensão) assim expandindo para 625 ( $5^4$ ) EA, um universo muito mais abrangentes.

### 4.2 Metaheurística *Vitis Vinifera*

A Metaheurística *Vitis Vinifera* ou **MHV** é uma Metaheurística Bio-inspirada, proposta em ([OLIVEIRA, 2016](#)), que tem como inspiração o comportamento da videira. Assim como o crescimento da planta é alterado pelos fatores iniciais e pelas influências exercidas no seu desenvolvimento, os parâmetros iniciais e alterações durante o desenvolvimento, moldam a videira pelo espaço de busca e as soluções encontradas. Com isso, pode-se traçar um padrão de desenvolvimento e encontrar as melhores circunstâncias para produção e crescimento, de acordo com o ambiente e condições no meio em que ela se encontra.

O fluxograma do **MHV** pode ser observado na Figura 2. Ele retrata a estrutura e funcionamento do mesmo de forma sucinta e é seguido por uma descrição mais detalhada dos processos.

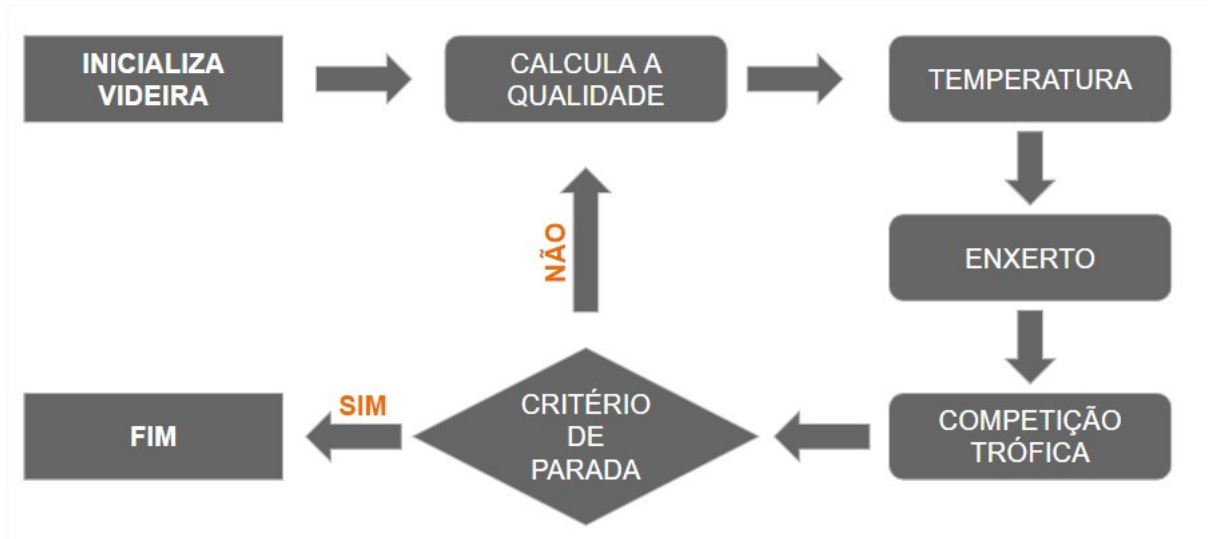


Figura 2 – Estrutura Principal do **MHV** (Fonte: Próprio autor)

A videira é iniciada com condições básicas (parâmetros), nessas condições são geradas as soluções iniciais aleatoriamente para o problema em questão. Com as soluções iniciais conhecidas, é calculado a qualidade( $q$ ) de cada uma, de acordo com a função objetivo e parâmetros definidos pelo problema.

O processo de busca consiste na geração de novos fitômeros pela Equação 4.1 que simula as alterações da temperatura do ambiente, a videira após as alterações é chamado de *VideiraFutura*, em seguida será aplicado o método de seleção entre a videira com os fitômeros novos e antigos e são decididos os que permanecerão para a próxima geração de fitômeros, o processo é repetido  $N$  vezes, até o último fitômero. Sendo o que retrata o processo de crescimento, desenvolvimento e podas ou diminuição da quantidade da seiva em alguns galhos menos promissores.

Equação de Temperatura

$$\Delta T = \frac{|t - t_i|}{t} \quad (4.1)$$

A segunda etapa do processo representa a atuação do enxerto onde, de acordo com uma probabilidade preestabelecida inicialmente, é selecionado um dos melhores  $n$  fitômeros com um  $q_n$  aleatório e outro fitômero aleatório na videira com  $q_i$ . Se o  $q_n$  é melhor do que  $q_i$  o enxerto é aplicado, com uma probabilidade que indica o quanto aquele fitômero será alterado pelo enxerto, após o fim do enxerto, o método de seleção é aplicado e é decidido se o fitômero que recebeu o enxerto substitui o fitômero antigo.

O ciclo se encerra com as alterações do fitômero pelo enxerto e pela temperatura e sendo a *VideiraAtual* completamente definida. Após isso é novamente calculado a qualidade( $q$ ) de cada fitômero de acordo com a função objetivo e parâmetros definidos pelo problema em questão. Define-se então o melhor e verifica se o número máximo de iterações foi alcançado, caso afirmativo o melhor valor é retornado e o algoritmo se encerra, caso negativo os parâmetros são atualizados de acordo com a iteração e novamente será realizado o ciclo. Para uma melhor compreensão é apresentado a seguir o Algoritmo 1 abaixo:

---

**Algoritmo 1:** MHV

---

```

1 Funcao objetivo  $f(x), x = (x_1, x_2, \dots, x_d)^E$ 
2  $VideiraAtual = x_i (i = 1, 2, \dots, n)$ 
3 Define o valor  $q_i$  de cada  $x_i$ 
4 Classifica os fitomeros da VideiraAtual e localiza o melhor
   Entrada: VideiraAtual
   Saída: Melhor Fitomero
5 while  $N < N^\circ$  Maximo de Iteracoes do
6    $l =$  Valor aleatorio entre a faixa de alteracao da temperatura estabelecida
7    $T_i =$  Temperatura ideal do Ciclo Fenologico atual
8    $T =$  Temperatura ambiente inicial + limite  $l$ 
9   início
10    para cada Fitomero faça
11      Gera novas solucoes pela Equacao 4.1
12       $VideiraFutura =$  Equacao 4.1(VideiraAtual)
13      Aplica o Torneio e decide quais dos valores permanecem.
14       $VideiraAtual =$  Torneio( $V_{Atual}, V_{Futura}$ )
15      Calcula o melhor Fitomero ate o momento
16    fim
17    if ( $valor\ sorteado < probabilidade\ de\ enxerto$ ) then
18      Pega um dos  $n$  melhores Fitomeros
19      if ( $q\ do\ Fitomero\ x_n > q\ do\ Fitomero\ x_i\ aleatorio$ ) then
20        Aplica o Enxerto de  $x_n$  no receptor  $x_i$ 
21         $x_i :=$  Enxerto( $x_n, x_i$ )
22        Aplica o Torneio e decide se o Fitomero  $x_i$  gerado substitui o Fitomero  $x_i$ 
23        antigo.
24      end
25    end
26    Verifica as solucoes obtidas e retorna o melhor  $x^*$ 
27  fim
28 retorna Melhor Fitomero

```

---

O **MHV** tem se mostrado uma ótima abordagem para os mais diversos tipos de problema, obtendo resultados de excelente qualidade em um curto tempo de execução. Além disso, é um trabalho recente na literatura, devendo ser mais explorado, dado o seu potencial para resolução de problemas com grau de dificuldades consideráveis.

Com a escolha do **MHV** de [Oliveira \(2016\)](#) como Metaheurística e o modelo de estilos de aprendizagem de [Felder, Silverman \*et al.\* \(1988\)](#), faz-se necessário apresentar a modelagem do problema em si.

### 4.3 Modelagem do Problema

Para a modelagem do problema seguiu-se a linha proposta por [Yannibelli, Godoy e Amandi \(2006\)](#), que propõe a detecção do EA do aluno. A estrutura proposta visa detectar a combinação de ações que o aluno normalmente realiza ao frequentar uma unidade acadêmica, considerando que um curso é composto por várias unidades acadêmicas. Para isso, é necessário observar a interação dos alunos com um sistema educacional através de várias unidades acadêmicas. A combinação das ações observadas define a combinação de ações preferidas pelo aluno e são então mapeadas em um dos EA do FSLSM.

As duas ações da Figura 3 são relacionadas à dimensão de processamento, indicando se os alunos preferem trabalhar sozinhos (reflexivos) ou em grupos (ativos). As ações da Figura 4 são referentes a dimensão de percepção, mostrando se o aluno é sensitivo ou intuitivo. A Figura 5 e última ação pertencem à dimensão compreensiva, relevando as relações de pensamento seqüencial ou global.

A dimensão de entrada não é levada em consideração no estudo realizado por [Yannibelli, Godoy e Amandi \(2006\)](#), devido os vídeos e demonstrações não estarem inclusos no sistema utilizado.

DIMENSÃO	AÇÕES POSSÍVEIS	VALOR
Participação em fóruns	Não participa.	0
	Apenas lê as mensagens no fórum.	1
	Lê as mensagens no fórum e responde.	2
	Envia mensagens que inicie discussões.	3
Participação em chat	Não participa.	0
	Apenas lê as mensagens no chat.	1
	Lê as mensagens no chat e responde.	2

Figura 3 – Combinação de ações Processamento. Adaptado de [Yannibelli, Godoy e Amandi \(2006\)](#)



DIMENSÃO	AÇÕES POSSÍVEIS	VALOR <sup>TM</sup>
Leitura do material	Apenas lê o material teórico.	0
	Lê todo o material teórico e parte do prático.	1
	Lê o material teórico e também o prático.	2
	Lê todo o material prático e parte do teórico.	3
	Apenas lê o material prático.	4
Acesso aos exemplos	Observa menos de 10% dos exemplos apresentados.	0
	Observa entre 10% e 30% dos exemplos apresentados.	1
	Observa entre 31% e 50% dos exemplos apresentados.	2
	Observa entre 51% e 70% dos exemplos apresentados.	3
	Observa mais de 70% dos exemplos apresentados.	4
Realização dos exercícios	Faz menos de 10% dos exercícios apresentados.	0
	Faz entre 10% e 30% dos exercícios apresentados.	1
	Faz entre 31% e 50% dos exercícios apresentados.	2
	Faz entre 51% e 70% dos exercícios apresentados.	3
	Faz mais de 70% dos exercícios apresentados.	4
Tempo de entrega do exames	Usa menos de 40% do tempo dado.	0
	Usa entre 41% a 50% do tempo dado.	1
	Usa entre 51% a 60% do tempo dado.	2
	Usa entre 61% a 70% do tempo dado.	3
	Usa mais de 70% do tempo dado.	4
Correção dos Exames	Usa menos de 5% do tempo dado para revisão do exame.	0
	Usa entre 5% e 10% do tempo dado para revisão do exame.	1
	Usa , entre 11% e 15% do tempo dado para revisão do exame.	2
	Usa entre 16% e 20% do tempo dado para revisão do exame.	3
	Usa mais de 20% do tempo dado para revisão do exame.	4
Mudanças de Respostas	Muda menos de 10% das respostas dadas.	0
	Muda entre 10% e 30% das respostas dadas.	1
	Muda entre 31% e 50% das respostas dadas.	2
	Muda entre 51% e 70% das respostas dadas.	3
	Muda acima de 70% das respostas dadas.	4

Figura 4 – Combinação de ações Percepção. Adaptado de [Yannibelli, Godoy e Amandi \(2006\)](#)

DIMENSÃO	AÇÕES POSSÍVEIS	VALOR
Informações de Acesso	Acesso todos itens de forma sequencial.	0
	Acesso a maioria dos itens de forma sequencial e o restante de forma global.	1
	Distribui igualmente em sequencial e global a forma de acesso.	2
	Acesso a maioria dos itens de forma global e o restante de forma sequencial.	3
	Acesso todos os itens de forma completamente global.	4

Figura 5 – Combinação de ações Compreensão. Adaptado de [Yannibelli, Godoy e Amandi \(2006\)](#)

Sendo o comportamento em relação a participação do fórum e chat relacionados à dimensão de processamento, caso a soma das duas notas sejam 0, o aluno possui um comportamento extremamente passivos, sendo então reflexivos. Caso contrário, o aluno fez uso do fórum e do chat e a soma das dimensões do mesmo tenham valores iguais a 5, o aluno é extremamente ativo. Além disso, se os valores forem intermediários o estudante pode ser considerado médio reflexivo, neutro ou médio ativo. As notas possíveis na dimensão processamento e os seus respectivos significados podem ser vistos na tabela 3:

Tabela 3 – Significado Processamento

X	Significado da Dimensão Processamento
0	Extremamente Passivo
1	Médio Passivo
2 ou 3	Neutro
4	Médio Ativo
5	Extremamente Ativo

As ações listadas na Figura 4 oferecem resultados referentes a dimensão de percepção, sendo a soma das notas igual a 0, o aluno possui comportamento extremamente intuitivo. Sendo a soma dos valores 24 o aluno mostra um comportamento sensitivo, tendo usado o material prático, observando mais de 70% dos exemplos, fazendo mais de 70% dos exercícios, usando mais de 70% do tempo dado para o exame, usando mais de 20% do tempo para revisar o exame e modificando mais de 70% das respostas dadas. No caso de valores intermediários, o aluno poderá ter um comportamento médio intuitivo, neutro ou médio sensitivo, dependendo do valor obtido. As notas possíveis na dimensão percepção e os seus respectivos significados podem ser vistos na tabela 4:

Tabela 4 – Significado Percepção

X	Significado da Dimensão Percepção
$0 \leq X \leq 4$	Extremamente Intuitivo
$4 < X \leq 8$	Médio Intuitivo
$8 < X \leq 16$	Neutro
$16 < X \leq 20$	Médio Sensitivo
$20 < X \leq 24$	Extremamente Sensitivo

A ação listada na Figura 5 remete à dimensão compreensiva, equivalendo o 0 a extremamente sequencial, 1 a médio sequencial, 2 a neutro, 3 a médio global e 4 extremamente global. As notas possíveis na dimensão compreensão e os seus respectivos significados podem ser vistos na tabela 5:

Tabela 5 – Significado Compreensão

X	Significado da Dimensão Compreensão
0	Extremamente Sequencial
1	Médio Sequencial
2	Neutro
3	Médio Global
4	Extremamente Global

Como exemplo, um aluno que tenha o comportamento: 1- Apenas lê as mensagens no fórum; 2- Lê as mensagens no fórum e responde; 4- Apenas lê o material prático; 2- Observa entre 31% e 50% dos exemplos apresentados; 4- Faz mais de 70% dos exercícios apresentados; 3- Usa entre 61% e 70% do tempo dado; 4- Usa mais de 20% do tempo dado; 3- Modifica entre 51% e 70% das respostas dadas e 1- Verifica a maioria dos itens de uma forma sequencial e o resto de modo global.

Tal aluno receberia como resultado para a dimensão processamento 1+2, ou seja, nota 3, na dimensão percepção 4+2+4+3+4+3, nota 20, e na dimensão compreensão nota 1. Sendo caracterizado como Processamento Neutro, Percepção Médio Sensitivo e Compreensão Médio Sequencial.

#### 4.4 MHV Alicado para Detecção de EA

A adaptação da videira para detecção de EA segue o padrão lógico mostrado no Fluxograma da Figura 2, para a aplicação do modelo proposto por [Yannibelli, Godoy e Amandi \(2006\)](#), alguns parâmetros e processos do **MHV** devem ser apresentados.

##### 4.4.1 Fitômero

O fitômero, exemplificado na Figura 6, associa cada ação tomada a uma posição do vetor. Essa mesma ação irá possuir um peso relacionado, cuja utilidade será esclarecida mais a frente.

<b>4</b>	<b>3</b>	<b>5</b>	<b>5</b>	<b>5</b>	<b>5</b>	<b>5</b>	<b>5</b>	<b>5</b>	<b>AÇÃO</b>
<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>PESO</b>

Figura 6 – Exemplo de Fitômero com ação e peso (Fonte: Próprio Autor).

Seguindo esse raciocínio, a Figura 7 mostra o aluno citado anteriormente, que possui como ações a sequência de valores: 1, 2, 4, 3, 2, 0, 0, 3 e 1.

<b>1</b>	<b>2</b>	<b>4</b>	<b>3</b>	<b>2</b>	<b>0</b>	<b>0</b>	<b>3</b>	<b>1</b>
<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>

Figura 7 – Exemplo de Fitômero (Fonte: Próprio Autor)

#### 4.4.2 População Inicial

A população inicial é o grupo de alunos ou soluções, cada fitômero é composto pelas ações realizadas pelo aluno. A geração dessas soluções é aleatória, sendo iniciados diversos alunos, com um conjunto de ações realizadas. Quanto mais diferenciado o grupo de alunos, mais abrangente será e conseqüentemente, terá mais chances de convergir para a EA real do aluno.

O número de ramos utilizados foram 10000, sendo esses compostos pelos fitômeros que mapeiam o comportamento. Esse valor representa 1% do espaço de busca, porém como observado por [Yannibelli, Godoy e Amandi \(2006\)](#), permite um bom nível de diversidade por geração aleatória da população inicial.

#### 4.4.3 Função de Qualidade ( $q$ )

Para medir a qualidade( $q$ ) de cada solução da videira, a função irá atribuir uma pontuação de acordo com o quanto próximo do ideal de solução está a solução avaliada. Na detecção a qualidade reflete a distância do conjunto de ações encontrado no fitômero para o conjunto de ações do aluno.

Para avaliar um determinado ramo de uma videira, a função de qualidade baseia-se nas ações realizadas pelo aluno enquanto frequenta uma unidade acadêmica específica. Assim, a função de qualidade é baseada em um grupo de ações  $A = \{a_1, a_2, \dots, a_9\}$ , pertencentes às ações descritas nas Figuras 3, 4 e 5. No início, cada fitômero  $F_i (i = 1, 2, 3 \dots 9)$  que forma um ramo é avaliado de acordo com a ação  $A_i$  observada. Se o fitômero  $F_i$  tiver o mesmo valor que a ação  $A_i$ , o peso atribuído ao fitômero é um, caso contrário, recebe o peso zero, como é mostrado na Equação 4.2.

Considerando o fitômero da Figura 7 como nosso modelo de estudante, e partindo do pressuposto que as ações do aluno real na unidade acadêmica 1 sejam mapeadas no fitômero exibido na Figura 8.

<b>1</b>	<b>3</b>	<b>4</b>	<b>2</b>	<b>2</b>	<b>4</b>	<b>0</b>	<b>1</b>	<b>0</b>
----------	----------	----------	----------	----------	----------	----------	----------	----------

Figura 8 – Ações do modelo real na Unidade Acadêmica 1 (Fonte: Próprio Autor)

Ao comparar com o fitômero representado na Figura 7, os resultados serão dados de acordo com a Equação 4.2, e a Figura 9 apresenta o vetor com as ações e pesos dessa avaliação.

<b>1</b>	<b>2</b>	<b>4</b>	<b>3</b>	<b>2</b>	<b>0</b>	<b>0</b>	<b>3</b>	<b>1</b>
<b>1</b>	<b>0</b>	<b>1</b>	<b>0</b>	<b>1</b>	<b>0</b>	<b>1</b>	<b>0</b>	<b>0</b>

Figura 9 – Vetor de ações e pesos após avaliação dos pesos (Fonte: Próprio Autor)

Equação para avaliação de pesos para Qualidade

$$AvaliacaoQ(F_i, A_i) = \begin{cases} 1 & F_i = A_i \\ 0 & F_i \neq A_i \end{cases} \quad (4.2)$$

Após a atribuição dos pesos, os mesmos são somados aos obtidos na iteração anterior, afim de que a solução seja penalizada ou recompensada com o passar das iterações, com o desenvolvimento da videira, quanto mais repetido for o comportamento, maior peso terá aquela ação.

No exemplo dado, a iteração vigente é a primeira, não existindo portanto valores anteriores e o vetor de pesos permanecendo os mesmos.

Equação para atualização de pesos  $q$  da ação com as iterações

$$Pesoq_i = Pesoq_{i-1} + AvaliacaoQ(F_i, A_i) \quad (4.3)$$

Por fim, a qualidade total do ramo é o somatório dos pesos atribuídos ao longo das iterações  $q$ , como observado na Equação 4.4:

Equação para obtenção da Qualidade  $q$

$$Qualidade(F) = \sum_{i=1}^9 Peso(q_i) \quad (4.4)$$

No exemplo citado, os pesos obtidos seriam somados, obtendo a  $Qualidade = 1 + 0 + 1 + 0 + 1 + 0 + 1 + 0 + 0 = 4$ .

#### 4.4.4 Torneio - Competição Trófica

O torneio é o método de seleção aplicado, por simular a competição trófica que ocorre internamente na videira. A disputa pelos nutrientes faz com que os ramos mais promissores recebam maior quantidade de seiva, enquanto os localizados em regiões menos promissoras podem receber uma quantidade menor de seiva ou as vezes nem receber, cortando o crescimento da planta para aquela direção.

O torneio consiste em comparar os ramos pela qualidade de cada um, sendo esse realizado entre dois ou mais ramos. No presente trabalho, o torneio implementado realiza a competição entre três ramos selecionados aleatoriamente, tendo como retorno o melhor deles. As competições são realizadas até que a videira alcance seu número máximo de ramos.

#### 4.4.5 Temperatura

A alteração dos fitômeros leva em consideração a temperatura do local onde o mesmo está situado, os fitômeros que estão em locais, cuja temperatura estão mais próxima da temperatura ideal, terão uma menor probabilidade de sofrer alteração. Os fitômeros, cuja temperatura estejam mais distantes da ideal, terão uma maior probabilidade de sofrer uma alteração.

As alterações ocorrem no conjunto de ações detectado, mudando o comportamento daquela determinada ação, como mostrado na imagem 10, alterando o fitomero da Figura 7 na posição 3 de 4 para 2.

1	2	2	3	2	0	0	3	1
---	---	---	---	---	---	---	---	---

Figura 10 – Exemplo de Alteração via Temperatura (Fonte: Próprio Autor)

#### 4.4.6 Enxerto

O enxerto consiste na inserção de características de uma videira em outra, na tentativa de melhorar dados comportamentos. A aplicação de um enxerto no algoritmo resume-se em selecionar um ramo *I* com alta qualidade e um ramo aleatório *A*, caso o ramo *A* tenha menor qualidade do que o ramo *I*, será retirado uma parte do ramo *I* e inserido no ramo *A* substituindo uma parte de mesmas proporções. O objetivo central dessa intervenção é inserir partes promissoras em ramos menos promissores, possibilitando assim uma convergência melhor em diversas regiões do espaço de busca. Um exemplo de enxerto é mostrado a seguir na Figura 11, onde o fitômero da Figura 7 sofre uma nova alteração, sendo inserido os valores 4, 2 e 1 no lugar dos valores 3, 2 e 0.

1	2	2	4	2	1	0	3	1
---	---	---	---	---	---	---	---	---

Figura 11 – Exemplo de Enxerto (Fonte: Próprio Autor)

#### 4.4.7 Finalizando a Qualidade

O exemplo dado até o momento, passou pelos processos descritos no Fluxograma da Figura 2. Sendo inicializado na Figura 7; Efetuado o cálculo da qualidade ao comparar as Figuras 8 e 9, com base nas equações 4.2, 4.3 e 4.4 e Alterado pela temperatura na Figura 10; Alterado pelo enxerto na Figura 11. Após todas essas operações, a população passaria pela Competição trófica e os fitômeros resultantes dessas operações estariam na próxima iteração. Seguindo com os procedimentos, em uma nova iteração, na Unidade Acadêmica 2 (UA2), o processo se repetiria, porém o fitômero apresentado na Figura 7 estará com as ações mostradas na Figura 12.

1	2	2	4	2	1	0	3	1
---	---	---	---	---	---	---	---	---

Figura 12 – Fitômero após a primeira iteração (Fonte: Próprio Autor)

O cálculo da qualidade desse novo fitômero prosseguiria aplicando primeiramente a comparação dos valores do fitômero novo com os da UA2 exibidos na Figura 13. A comparação resulta em um novo conjunto de pesos, que pode ser observados na Figura 14.

1	2	4	2	3	1	0	3	0
---	---	---	---	---	---	---	---	---

Figura 13 – Ações da UA2 (Fonte: Próprio Autor)

1	2	2	4	2	1	0	3	1
1	1	0	0	0	1	1	1	0

Figura 14 – Pesos após a comparação do novo fitômero e UA2 (Fonte: Próprio Autor)

Após isso, a Equação 4.3 irá realizar a soma dos pesos do vetor da última iteração, com os pesos do vetor obtido com a comparação do novo fitômero e a UA2, como pode ser visto na Figura 15

1	0	1	0	1	0	1	0	0	ANTIGO
1	1	0	0	0	1	1	1	0	NOVO
2	1	1	0	1	1	2	1	0	

Figura 15 – Soma dos pesos antigos e novos (Fonte: Próprio Autor)

Finalmente aplica-se a Equação 4.4 sobre o fitômero representado na Figura 16 e obtém-se a *Qualidade* =  $2 + 1 + 1 + 0 + 1 + 1 + 2 + 1 + 0 = 9$ . Segue-se então os passos subsequentes, até que o critério de parada seja atendido e a metaheurística retorne o melhor resultado obtido.

1	2	2	4	2	1	0	3	1
2	1	1	0	1	1	2	1	0

Figura 16 – Indivíduo com os pesos atualizados (Fonte: Próprio Autor)

## 4.5 Medições

Para verificar a precisão da metaheurísticas, foi adotado uma metodologia de medição que fornecesse uma boa compreensão entre a proximidade dos valores obtidos e dos valores reais, essa metodologia é apresentada nessa seção.

### 4.5.1 Escala Likert

A Escala de Likert é uma escala de resposta psicométrica frequentemente usada em questionários. Ao responderem a um questionário de tal escala, os questionados especificam seu nível de proximidade com uma afirmação.

Uma variação da Escala de Likert foi usada para mesurar o nível de precisão na detecção do Estilo de Aprendizagem relacionado ao aluno. Como o foco é essa detecção, cada dimensão pode receber um valor de um a cinco, como já apresentado anteriormente.

Na dimensão de processamento os valores que podem ser obtidos são:

- 1 - Extremamente Passivo
- 2 - Médio Passivo
- 3 - Neutro
- 4 - Médio Ativo



5 - Extremamente Ativo

Na dimensão de percepção os valores que podem ser obtidos são:

- 1 - Extremamente Intuitivo
- 2 - Médio Intuitivo
- 3 - Neutro
- 4 - Médio Sensitivo
- 5 - Extremamente Sensitivo

Na compreensão os valores são:

- 1 - Extremamente Sequencial
- 2 - Médio Sequencial
- 3 - Neutro
- 4 - Médio Global
- 5 - Extremamente Global

Para calcular o nível de precisão, obtem-se o valor da EA encontrado pelo algoritmo e subtrai-se o valor da EA real, sendo o módulo desse valor o grau de distância de um EA para o outro, quanto maior a diferença, menor a proximidade. Na tabela 6 podemos ver um exemplo do grau de Proximidade.

Tabela 6 – Grau de Proximidade EA Real - EA Detectada

	Percepção	Processamento	Compreensão
EA Real	5	1	2
EA Detectado	4	1	4
$ EAR - EAD $	1	0	2

A menor diferença entre as dimensões é 0, ou seja um caso onde todas as 3 dimensões da EA detectadas obtiveram exatamente o mesmo valor que a EA Real, prevendo perfeitamente o comportamento do aluno. A maior distância seria a escolha dos exatos opostos de uma dimensão, sendo cada dimensão da EA detectada a mais distante da EA real. Sendo a diferença entre 5 e 1, ou seja 4 em todas as dimensões, sendo 12 a pior nota.

Sendo o modelo aplicado em 3 dimensões, com 4 sendo a pior nota, aplicados em 8 unidades acadêmicas para 30 alunos diferentes, a maior distância obtida nos testes é  $3 \times 4 \times 8 \times 30 = 2880$ .



## 5 RESULTADOS E DISCUSSÕES

A implementação do *MHV* com a abordagem apresentada no capítulo anterior foi avaliada e comparada com o Algoritmo Genético, usado por [Yannibelli, Godoy e Amandi \(2006\)](#) para a detecção de EA.

Foram realizados 30 testes independentes e intercaladas de cada abordagem (*MHV* e AG). Todos os testes possuíam um total de 30 alunos, gerando um total de 900 EA. O AG proposto por [Yannibelli, Godoy e Amandi \(2006\)](#), teve um total de 100.000 soluções com 1% de taxa de mutação, 100% de taxa de cruzamento e o método de seleção aplicado foi o torneio. O *MHV* também avaliou 100.000 soluções, fez uso do torneio como método de seleção e os parâmetros de temperatura e ciclo permanecem os padrões, detectados como ideais em [Oliveira \(2016\)](#).

Os resultados obtidos foram organizados e foi realizado uma análise estatística em cima dos mesmos, que são apresentados a seguir.

A Figura 17 apresenta, para cada abordagem, a média das distâncias entre o EA detectado e o EA real para as 900 detecções realizadas. Observa-se que a *MHV* incorreu numa menor quantidade de erros, 33, em relação ao AG, 237.




Figura 17 – Distância Total dos EA Detectados para os Reais (Fonte: Próprio Autor)

A Tabela 7 apresenta o valor mínimo, primeiro quartil, mediana, média, terceiro quartil, e valor máximo, considerando a distância, respectivamente para a *MHV* e o AG. Tais valores tornam ainda mais clara a diferença entre os resultados obtidos, visto que até 75% dos resultados (terceiro quartil), a *MHV* detecta exatamente o EA real dos aprendizes (diferença entre o EA detectado e EA real é igual a 0).

Ademais, o desvio padrão obtido pela *MHV* é de 0.56, e o do AG é de 1.2, o que deixa claro que a *MHV* possui menor variabilidade em seus resultados, apresentando-se, portanto,

Tabela 7 – Sumário dos resultados obtidos para a MHV e o AG

Abordagem	Min	Q1	Mediana	Mean	Q3	Max
MHV	0.00	0.00	0.00	0.1375	0	4
AG	0.00	0.00	1.00	0.9875	1	6

como uma técnica mais estável que o AG.

As Figuras 18 e 19 apresentam os histogramas relativos às distâncias entre os EAs detectados e o EAs reais para ambas as abordagens consideradas. A MHV possui uma frequência muito maior de zeros que o AG. Já o AG possui grande incidência de distâncias com valor 1, e mais de 100 incidências de valores de distâncias iguais ou superiores a 2.




Figura 18 – Histograma MHV (Fonte: Próprio Autor)




Figura 19 – Histograma AG (Fonte: Próprio Autor)

O *boxplot* apresentado na Figura 20 reflete a dispersão dos valores em torno da média, que, para a MHV, é praticamente 0, e, para o AG, aproxima-se de 1. Nos resultados obtidos pela MHV, pode-se observar que valores acima de 1 já são considerados *outliers*, enquanto no AG isso só acontece para valores iguais ou superiores a 3.

A hipótese nula do teste estatístico utilizado (Shapiro-Wilk) é que a população está normalmente distribuída. Sendo assim, para  $p < 0.05$ , a hipótese nula é rejeitada, ou seja, os




Figura 20 – Boxplot comparativo dos dados (Fonte: Próprio Autor)

dados não possuem distribuição normal. Para a MHV, tem-se  $w=0.2666$  com  $p\text{-value} < 2.2e^{-16}$ , e para o AG, tem-se  $w=0.782$  com  $p\text{-value} < 2.2e^{-16}$ . Neste sentido, os testes de normalidade dos dois algoritmos possuem p-valor muito inferiores a 0.05, deixando claro a não-normalidade dos dados.

Uma vez que o conjunto de dados testados não são normalmente distribuídos, não são paramétricos, e são pareados, utilizou-se o teste de hipóteses de Wilcoxon com a finalidade de comparar as duas amostras para avaliar se as distribuições médias populacionais possuem diferenças relevantes. Os resultados são apresentados na figura 21

```
wilcoxon signed rank test
data: dataset$RESULTADOS.MHV and dataset$RESULTADOS.AG
V = 3565, p-value < 2.2e-16
alternative hypothesis: true location shift is not equal to 0
95 percent confidence interval:
 -1.500019 -1.499925
sample estimates:
(pseudo)median
 -1.499938
```

Figura 21 – Teste de Hipóteses - Wilcoxon (Fonte: Próprio Autor)

O resultado mostra que há diferença significativa, sendo os resultados obtidos pela MHV substancialmente melhores do que os obtidos pelo AG.



## CONCLUSÃO

A aplicação de sistemas tecnológicos em instituições de ensino podem gerar ganhos consideráveis para a educação, possibilitando ao aluno um conteúdo adaptável que o auxilie nos estudos, facilitando e otimizando o aprendizado.

Essa alteração de paradigma de ensino, de um modelo onde o mesmo conteúdo é ofertado a todos alunos, para um conteúdo adaptativo de acordo com o perfil cognitivo do aluno, pode melhorar a recepção do conteúdo, e assim conseqüentemente o resultado final. A adaptação do conteúdo suscita maior interesse por parte do estudante promove maior aprendizado, além de auxiliar na redução da evasão por desinteresse.

A implementação de um bom algoritmo para a modelagem automática e dinâmica de estilos de aprendizagem faz toda a diferença para uma detecção mais precisa, e como citado anteriormente a detecção correta e contínua é o que caracteriza um SAIE de qualidade.

Os níveis de precisão mensurados e a análise estatística, evidenciam os bons resultados e comprovam a relevância do presente trabalho, para a evolução das detecções de perfis cognitivos de estudantes para SAIE. Os resultados obtidos pela MHV mostram-se superiores em relação à abordagem considerada estado da arte, que utiliza um AG para a detecção de EA. A detecção é realizada de forma muito mais precisa na grande maioria dos resultados, constatando a efetividade do *MHV* para a detecção de EA como proposto.

O proposto foi alcançado, visto a técnica implementada ter melhor aderência do que o estado da arte na abordagem proposta. Conseqüentemente aprimorou-se a detecção dos traços cognitivos do estudante, possibilitando maior êxito na modelagem do mesmo, tornando factível o uso da mesma com adaptatividade mais assertiva em sistemas educacionais.

O uso de um bom algoritmo para a modelagem automática e dinâmica do perfil cognitivo do aluno é o que torna possível a detecção precisa. Por isso, aprimorar a precisão da detecção tem grande importância para a evolução das abordagens de sistemas adaptativos voltados para a educação. Assim, foi evidenciando a valiosidade do trabalho, para a evolução das detecções de perfis cognitivos de estudantes com o uso da abordagem proposta, melhorando os resultados consideravelmente. Além disso foram publicados os artigos ([OLIVEIRA et al., 2017](#)), ([OLIVEIRA et al., 2018a](#)) e ([OLIVEIRA et al., 2018b](#)) relacionados ao presente trabalho, mostrando a relevância do mesmo para a Educação e a Tecnologia.

Um possível futuro trabalho seria trabalhar a indicação de objetos de aprendizagem adequados a partir do EA detectado através das interações do estudante com o sistema.





## REFERÊNCIAS

- ADORF, H.-M.; JOHNSTON, M. A discrete stochastic neural network algorithm for constraint satisfaction problems. In: **1990 IJCNN International Joint Conference on Neural Networks**. IEEE, 1990. Disponível em: <https://doi.org/10.1109/ijcnn.1990.137951>.
- AHMAD, N.; TASIR, Z.; KASIM, J.; SAHAT, H. Automatic detection of learning styles in learning management systems by using literature-based method. **Procedia - Social and Behavioral Sciences**, Elsevier BV, v. 103, p. 181–189, nov 2013. Disponível em: <https://doi.org/10.1016/j.sbspro.2013.10.324>.
- AHMAD, N. B. H.; SHAMSUDDIN, S. M. 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**. IEEE, 2010. Disponível em: <https://doi.org/10.1109/isda.2010.5687150>.
- ALKHURAJI, S.; CHEETHAM, B.; BAMASAK, O. Dynamic adaptive mechanism in learning management system based on learning styles. In: **2011 IEEE 11th International Conference on Advanced Learning Technologies**. IEEE, 2011. Disponível em: <https://doi.org/10.1109/icalt.2011.69>.
- AMIR, E. S.; SUMADYO, M.; SENSUSE, D. I.; SUCAHYO, Y. G.; SANTOSO, H. B. Automatic detection of learning styles in learning management system by using literature-based method and support vector machine. In: IEEE. **Advanced Computer Science and Information Systems (ICACSIS), 2016 International Conference on**. [S.l.], 2016. p. 141–144.
- ASSIS, L. P. de; PITANGUI, C.; ANDRADE, A. V. Experiências e Práticas Pedagógicas na América Latina. In: CRV (Ed.). **Diálogos e Interlocuções**. [S.l.: s.n.], 2016. cap. 8, p. 237. ISBN 978-85-444-1192-6.
- AVANTHAY, C.; HERTZ, A.; ZUFFEREY, N. A variable neighborhood search for graph coloring. **European Journal of Operational Research**, Elsevier BV, v. 151, n. 2, p. 379–388, dec 2003. Disponível em: [https://doi.org/10.1016/s0377-2217\(02\)00832-9](https://doi.org/10.1016/s0377-2217(02)00832-9).
- AVIGAD, J.; DONNELLY, K. Formalizing o notation in isabelle/hol. **Automated Reasoning**, Springer, p. 357–371, 2004.
- BACHARI, E. E.; ABELWAHED, E. H.; ADNANI, M. E. E-L EARNING PERSONALIZATION BASED ON D YNAMIC LEARNERS ' PREFERENCE. v. 3, n. 3, 2011.
- BALAKRISHNAN, V.; BOYD, S.; BALEMI, S. Branch and bound algorithm for computing the minimum stability degree of parameter-dependent linear systems. **International Journal of Robust and Nonlinear Control**, Wiley Online Library, v. 1, n. 4, p. 295–317, 1991.
- BERNARD, J.; CHANG, T.-W.; POPESCU, E.; GRAF, S. Learning style identifier: Improving the precision of learning style identification through computational intelligence algorithms. **Expert Systems with Applications**, Elsevier BV, v. 75, p. 94–108, jun 2017. Disponível em: <https://doi.org/10.1016/j.eswa.2017.01.021>.
- BERNERS-LEE ROBERT CAILLIAU, A. L. H. F. N. A. S. T. The world-wide web. **Communications of the ACM**, ACM, v. 37, n. 8, p. 76–82, 1994. Disponível em: <http://www.cs.bilkent.edu.tr/~tugrul/CS518/Papers/p76-berners-lee.pdf>.

BERTSIMAS, D.; TSITSIKLIS, J. Simulated annealing. **Statistical Science**, Institute of Mathematical Statistics, v. 8, n. 1, p. 10–15, feb 1993. Disponível em: <https://doi.org/10.1214/ss/1177011077>).

BIGGS, J. B. **Student Approaches to Learning and Studying. Research Monograph**. [S.l.]: ERIC, 1987.

BOSE, N. K.; LIANG, P. Neural network fundamentals with graphs, algorithms and applications, mcgraw-hill series in electrical and computer engineering. McGraw-Hill USA, 1996.

BOTSIOS, S.; GEORGIU, D.; SAFOURIS, N. Contributions to Adaptive Educational Hypermedia Systems via on-line Learning Style Estimation. v. 11, p. 322–339, 2008.

BOYD, S.; MATTINGLEY, J. Branch and bound methods. **Notes for EE364b, Stanford University**, p. 2006–07, 2007.

BRUSILOVSKY, P. Methods and techniques of adaptive hypermedia. **User Modeling and User-Adapted Interaction**, Springer Nature, v. 6, n. 2-3, p. 87–129, jul 1996. Disponível em: <https://doi.org/10.1007/bf00143964>).

CABADA, R. Z.; Barrón Estrada, M. L.; Reyes García, C. A. EDUCA: A web 2.0 authoring tool for developing adaptive and intelligent tutoring systems using a Kohonen network. **Expert Systems with Applications**, v. 38, n. 8, p. 9522–9529, 2011. ISSN 09574174.

CABADA, R. Z.; LUCÍA, M.; ESTRADA, B.; CABADA, R. Z.; GARCÍA, A. R.; ASTROFÍSICA, I. N. D.; INAOE, E.; ENRIQUE, L.; NO, E.; TONANZINTLA, M. 2009 Latin American Web Congress A Fuzzy-Neural Network for Classifying Learning Styles in a Web 2.0 and Mobile Learning Environment. 2009.

CARMONA, C.; CASTILLO, G.; MILLÁN, E. Designing a Dynamic Bayesian Network for Modeling Students' Learning Styles. **2008 Eighth IEEE International Conference on Advanced Learning Technologies**, p. 346–350, 2008. Disponível em: <http://ieeexplore.ieee.org/document/4561705/>).

CARNEIRO, T.; JÚNIOR, F. H. de C.; ARRUDA, N. G. P. B.; PINHEIRO, A. B. Um levantamento na literatura sobre a resolução de problemas de otimização combinatória através do uso de aceleradores gráficos. In: **Proceedings of the XXXV Ibero-Latin American Congress on Computational Methods in Engineering (CILAMCE), Fortaleza-CE, Brasil**. [S.l.: s.n.], 2014.

CARRANO, F. M. *et al.* **Frank M. Carrano, et al., Data Abstraction and Problem Solving With C++**. [S.l.]: Addison-Wesley, 1998.

CASTELLS, M. A sociedade em rede. **Paz e Terra**, Paz e Terra, v. 1, 1999. Disponível em: [periodicos.ufpb.br/ojs/index.php/ies/article/viewFile/337/259](http://periodicos.ufpb.br/ojs/index.php/ies/article/viewFile/337/259)).

CHANG, Y. C.; KAO, W. Y.; CHU, C. P.; CHIU, C. H. A learning style classification mechanism for e-learning. **Computers and Education**, Elsevier Ltd, v. 53, n. 2, p. 273–285, 2009. ISSN 03601315. Disponível em: <http://dx.doi.org/10.1016/j.compedu.2009.02.008>).

COELHO, F.; NETO, J. P. **Teoria da computação, contabilidade e complexidade**. [S.l.]: Escolar Editora, 2010.

COFFIELD, F.; MOSELEY, D.; HALL, E.; ECCLESTONE, K. *et al.* **Learning styles and pedagogy in post-16 learning: A systematic and critical review**. [S.l.]: Learning and Skills Research Centre London, 2004.

COHEN-ALMAGOR, R. Internet history. **International Journal of Technoethics**, IGI Global, v. 2, n. 2, p. 45–64, 2011. Disponível em: <https://doi.org/10.4018/jte.2011040104>.

COPPIN, B. **Artificial intelligence illuminated**. [S.l.]: Jones & Bartlett Learning, 2004.

CORDENONSI, A. Z.; MÜLLER, F. M.; BASTOS, F. d. P. de; ARAÚJO, F. V.; ELENUSA, T. O lobo e o caixeiro viajante. In: **Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE)**. [S.l.: s.n.], 2007. v. 1, n. 1, p. 71–81.

CROCKETT, K.; LATHAM, A.; MCLEAN, D.; BANDAR, Z.; O'SHEA, J. On predicting learning styles in conversational intelligent tutoring systems using fuzzy classification trees. In: **2011 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE 2011)**. IEEE, 2011. Disponível em: <https://doi.org/10.1109/fuzzy.2011.6007514>.

CROCKETT, K.; LATHAM, A.; MCLEAN, D.; O'SHEA, J. A fuzzy model for predicting learning styles using behavioral cues in an conversational intelligent tutoring system. In: **IEEE Fuzzy Systems (FUZZ), 2013 IEEE International Conference on**. [S.l.], 2013. p. 1–8.

CROCKETT, K.; LATHAM, A.; WHITTON, N. Author 's Accepted Manuscript On Predicting Learning Styles in Conversational Trees Reference : Predicting Learning Styles in Conversational Intelligent Tutoring Systems using On Predicting Learning Styles in Conversational Intelligent Tutoring Systems using Fuzzy Decision Trees. **Journal of Human Computer Studies**, Elsevier, 2016. ISSN 1071-5819. Disponível em: <http://dx.doi.org/10.1016/j.ijhcs.2016.08.005>.

DOMINGOS, C. S. M. 50 anos da crise dos mísseis: horror nuclear em tempos presentes. *Historia*, Rio Grande, 2013.

DORÇA, F.; LIMA, L. A New Approach to Discover Students Learning Styles in Adaptive Educational Systems. **Revista Brasileira de Informática na Educação**, v. 21, n. 1, p. 15, 2013. ISSN 1414-5685. Disponível em: <http://ceie-sbc.tempsite.ws/pub/index.php/sbie/article/view/1577>.

DORÇA, F.; QUEIROZ, B.; FERNANDES, M. A.; LOPES, C. R. Um sistema inteligente multi-agente para educação a distância. In: **XXII Congresso da Sociedade Brasileira de Computação**. [S.l.: s.n.], 2002.

DORÇA, F. A.; LIMA, L. V.; FERNANDES, M. A.; LOPES, C. R. Detecção e correção automática de estilos de aprendizagem em sistemas adaptativos para educação. **Revista de Informática Teórica e Aplicada**, v. 18, n. 2, p. 178–204, 2011.

DORÇA, F. A.; LIMA, L. V.; FERNANDES, M. A.; LOPES, C. R. A new approach to discover students learning styles in adaptive educational systems. **Revista Brasileira de Informática na Educação**, Comissão Especial de Informatica na Educacao, v. 21, n. 01, aug 2013. Disponível em: <https://doi.org/10.5753/rbie.2013.21.01.76>.

DORIGO, M.; BIRATTARI, M.; STUTZLE, T. Ant colony optimization. **IEEE computational intelligence magazine**, IEEE, v. 1, n. 4, p. 28–39, 2006.

DORÇA, F. A. Fabiano azevedo dorça 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 a educação a distância. **Universidade Federal de Uberlândia**, Tese de Doutorado em Engenharia Elétrica, p. 208, 2012. Disponível em: <https://www.mendeley.com/viewer/?fileId=078099a5-2b5d-28ab-58ea-8e4188338db4&documentId=bdec393-6788-3617-8217-7fba7ed03ac8>).

EBERHART, R.; KENNEDY, J. A new optimizer using particle swarm theory. In: **MHS'95. Proceedings of the Sixth International Symposium on Micro Machine and Human Science**. IEEE, 1995. Disponível em: <https://doi.org/10.1109/mhs.1995.494215>).

ELGHOUGH, N.; SEGHROUCHENI, Y. Z.; MOHAJIR, B. E. E.; ACHHAB, M. A. *et al.* Als\_corr [lp]: An adaptive learning system based on the learning styles of felder-silverman and a bayesian network. In: IEEE. **Information Science and Technology (CiSt), 2016 4th IEEE International Colloquium on**. [S.l.], 2016. p. 494–499.

FELDER, R. M.; BRENT, R. Understanding student differences. **Journal of Engineering Education**, Wiley-Blackwell, v. 94, n. 1, p. 57–72, jan 2005. Disponível em: <https://doi.org/10.1002/j.2168-9830.2005.tb00829.x>).

FELDER, R. M.; SILVERMAN, L. K. *et al.* Learning and teaching styles in engineering education. **Engineering education**, v. 78, n. 7, p. 674–681, 1988.

FELDMAN, J.; MONTESERIN, A.; AMANDI, A. Automatic detection of learning styles: state of the art. **Artificial Intelligence Review**, Springer Nature, v. 44, n. 2, p. 157–186, may 2014. Disponível em: <https://doi.org/10.1007/s10462-014-9422-6>).

FERNANDEZ, F. M. H.; PONNUSAMY, R. Ontology-based modeling student learning behaviour analysis in digital library domain knowledge using markov chain and guha. In: IEEE. **Advanced Computing (ICoAC), 2015 Seventh International Conference on**. [S.l.], 2015. p. 1–6.

FLEMING, N. D.; MILLS, C. Not another inventory, rather a catalyst for reflection. 1992.

GARCÍA, P.; AMANDI, A.; SCHIAFFINO, S.; CAMPO, M. Evaluating bayesian networks' precision for detecting students' learning styles. **Computers & Education**, Elsevier BV, v. 49, n. 3, p. 794–808, nov 2007. Disponível em: <https://doi.org/10.1016/j.compedu.2005.11.017>).

GARCÍA, P.; SCHIAFFINO, S.; AMANDI, A. An enhanced Bayesian model to detect students' learning styles in Web-based courses. p. 305–315, 2008.

GARDNER, H. **Multiple Intelligences: New Horizons in Theory and Practice**. Basic Books, 2008. ISBN 9780786721870. Disponível em: <https://books.google.com.br/books?id=8K54fg6YU4EC>).

GAVIDIA, J. J. Z.; ANDRADE, L. C. V. d. Sistemas tutores inteligentes. **Trabalho de Conclusão da Disciplina de IA, Universidade Federal do Rio de Janeiro. Rio de Janeiro–RJ: UFRJ**, 2003.

GENDREAU, M.; POTVIN, J.-Y. Metaheuristics in combinatorial optimization. **Annals of Operations Research**, Springer Nature, v. 140, n. 1, p. 189–213, nov 2005. Disponível em: <https://doi.org/10.1007/s10479-005-3971-7>).

GERMANAKOS, P.; TSIANOS, N.; LEKKAS, Z.; MOURLAS, C.; SAMARAS, G. Capturing essential intrinsic user behaviour values for the design of comprehensive web-based personalized environments. **Computers in Human Behavior**, Elsevier BV, v. 24, n. 4, p. 1434–1451, jul 2008. Disponível em: <https://doi.org/10.1016/j.chb.2007.07.010>.

GILKS, W. R.; RICHARDSON, S.; SPIEGELHALTER, D. **Markov chain Monte Carlo in practice**. [S.l.]: CRC press, 1995.

GLOVER, F. Tabu search—part i. **ORSA Journal on Computing**, Institute for Operations Research and the Management Sciences (INFORMS), v. 1, n. 3, p. 190–206, aug 1989. Disponível em: <https://doi.org/10.1287/ijoc.1.3.190>.

GLOVER, F.; LAGUNA, M.; MARTI, R. Scatter search. In: **Natural Computing Series**. Springer Berlin Heidelberg, 2003. p. 519–537. Disponível em: [https://doi.org/10.1007/978-3-642-18965-4\\_20](https://doi.org/10.1007/978-3-642-18965-4_20).

GRAF, S.; KINSHUK. Using cognitive traits for improving the detection of learning styles. In: **2010 Workshops on Database and Expert Systems Applications**. IEEE, 2010. Disponível em: <https://doi.org/10.1109/dexa.2010.35>.

GRAF, S.; KINSHUK; LIU, T.-C. Identifying learning styles in learning management systems by using indications from students' behaviour. In: **2008 Eighth IEEE International Conference on Advanced Learning Technologies**. IEEE, 2008. Disponível em: <https://doi.org/10.1109/icalt.2008.84>.

GRAF, S.; LIU, T.-c. Supporting Teachers in Identifying Students ' Learning Styles in Learning Management Systems : An Automatic Student Modelling Approach. v. 12, p. 3–14, 2009.

HAMTINI, T.; ATEIA, H. A proposed dynamic technique for detecting learning style using literature based approach. **2015 IEEE Jordan Conference on Applied Electrical Engineering and Computing Technologies, AEECT 2015**, 2015.

HEROD, L. Learning styles and strategies. **Adult Learning & Literacy**, p. 310–800, 2004.

HERTZ, A.; WIDMER, M. Guidelines for the use of meta-heuristics in combinatorial optimization. **European Journal of Operational Research**, Elsevier BV, v. 151, n. 2, p. 247–252, dec 2003. Disponível em: [https://doi.org/10.1016/s0377-2217\(02\)00823-8](https://doi.org/10.1016/s0377-2217(02)00823-8).

HIDAYAT, A.; UTOMO, V. G. Automatic detection of learning style in adaptive online module system. In: **2016 International Conference on Informatics and Computing (ICIC)**. IEEE, 2016. Disponível em: <https://doi.org/10.1109/iac.2016.7905696>.

HMEDNA, B.; MEZOUARY, A. E.; BAZ, O.; MAMMASS, D. A Machine Learning Approach to Identify and Track Learning Styles in MOOCs. 2016.

HOLLAND, J. H. Genetic algorithms. **Scientific american**, JSTOR, v. 267, n. 1, p. 66–73, 1992.

HONEY, P.; MUMFORD, A. **Learning styles questionnaire**. [S.l.]: Organization Design and Development, Incorporated, 1989.

KAPLAN, A. M.; HAENLEIN, M. Users of the world, unite! The challenges and opportunities of Social Media. **Business Horizons**, v. 53, n. 1, p. 59–68, 2010.



KASER, T.; KLINGLER, S.; SCHWING, A. G.; GROSS, M. Dynamic bayesian networks for student modeling. **IEEE Transactions on Learning Technologies**, Institute of Electrical and Electronics Engineers (IEEE), v. 10, n. 4, p. 450–462, oct 2017. Disponível em: <https://doi.org/10.1109/tlt.2017.2689017>.

KEARNS, M.; MANSOUR, Y. On the boosting ability of top-down decision tree learning algorithms. In: **Proceedings of the twenty-eighth annual ACM symposium on Theory of computing - STOC '96**. ACM Press, 1996. Disponível em: <https://doi.org/10.1145/237814.237994>.

KEEFE, J. W. Learning style: An overview. **Student learning styles: Diagnosing and prescribing programs**, v. 1, p. 1–17, 1979.

KENNEDY, J.; EBERHART, R. A discrete binary version of the particle swarm algorithm. In: **1997 IEEE International Conference on Systems, Man, and Cybernetics. Computational Cybernetics and Simulation**. IEEE, 1997. Disponível em: <https://doi.org/10.1109/icsmc.1997.637339>.

KHALID, M. N. A.; YUSOF, U. K.; XIANG, L. G. Model student selection using fuzzy logic reasoning approach. In: IEEE. **Advanced Informatics: Concepts, Theory And Application (ICAICTA), 2016 International Conference On**. [S.l.], 2016. p. 1–6.

KHANESAR, M. A.; TESHNEHLAB, M.; SHOOREHDELI, M. A. A novel binary particle swarm optimization. In: **2007 Mediterranean Conference on Control & Automation**. IEEE, 2007. Disponível em: <https://doi.org/10.1109/med.2007.4433821>.

KOLB, D. A. Learning styles and disciplinary differences. **The modern American college**, v. 1, p. 232–255, 1981.

KOLEKAR, S. V. Learning Style Recognition using Artificial Neural Network for Adaptive User Interface in E-learning. 2010.

KONONENKO, I. Id3, sequential bayes, naive bayes and bayesian neural networks. In: **Proc. 4th European Working Session on Learning**. [S.l.: s.n.], 1989. p. 91–98.

LATHAM, A.; CROCKETT, K.; MCLEAN, D.; EDMONDS, B. Computers & Education A conversational intelligent tutoring system to automatically predict learning styles. **Computers & Education**, Elsevier Ltd, v. 59, n. 1, p. 95–109, 2012. ISSN 0360-1315. Disponível em: <http://dx.doi.org/10.1016/j.compedu.2011.11.001>.

LEJBMAN, D. A. G. vel. Um estudo abrangente sobre metaheurística, incluindo um histórico. Universidade de São Paulo Instituto de Matematica e Estatística Departamento de Ciencias da Computação, 2009.

LESCANO, G.; COSTAGUTA, R.; AMANDI, A.; UNCPBA, I. Genetic Algorithm for Automatic Group Formation Considering Student ' s Learning Styles. 2016.

LITTMAN, M.; BOYAN, J. A distributed reinforcement learning scheme for network routing. In: PSYCHOLOGY PRESS. **Proceedings of the international workshop on applications of neural networks to telecommunications**. [S.l.], 1993. p. 45–51.

LIU, M. Personalized Learning System based on Solomon Learning Style. p. 820–823, 2008.

- LOPES, H. S.; RODRIGUES, L. C. de A.; STEINER, M. T. A. (Ed.). **Meta-Heurísticas em Pesquisa Operacional**. Omnipax, 2013. Disponível em: <https://doi.org/10.7436/2013.mhpo.0>.
- LOPES, L. R. H.; STEINER, M. **Meta-Heurísticas em Pesquisa Operacional**. Omnipax, 2013. Disponível em: <https://doi.org/10.7436/2013.mhpo.0>.
- LOURENÇO, H. R.; MARTIN, O. C.; STUTZLE, T. Iterated local search. **International series in operations research and management science**, Springer, p. 321–354, 2003.
- MACKERACHER, D. **Making sense of adult learning**. [S.l.]: University of Toronto Press, 2004.
- MARTÍ, R.; LAGUNA, M.; GLOVER, F. Principles of scatter search. **European Journal of Operational Research**, Elsevier BV, v. 169, n. 2, p. 359–372, mar 2006. Disponível em: <https://doi.org/10.1016/j.ejor.2004.08.004>.
- MCCAULLEY, M. H. The myers-briggs type indicator: A measure for individuals and groups. **Measurement and Evaluation in Counseling and Development**, American Counseling Assn, 1990.
- MITCHELL, M. Genetic algorithms: An overview. **Complexity**, Wiley-Blackwell, v. 1, n. 1, p. 31–39, sep 1995. Disponível em: <https://doi.org/10.1002/cplx.6130010108>.
- MLADENOVIC, N.; HANSEN, P. Variable neighborhood search. **Computers & Operations Research**, Elsevier BV, v. 24, n. 11, p. 1097–1100, nov 1997. Disponível em: [https://doi.org/10.1016/s0305-0548\(97\)00031-2](https://doi.org/10.1016/s0305-0548(97)00031-2).
- MOKHTAR, R.; ABDULLAH, S. N. H. S.; ZIN, N. A. M. Classifying modality learning styles based on production-fuzzy rules. In: IEEE. **Pattern Analysis and Intelligent Robotics (ICPAIR), 2011 International Conference on**. [S.l.], 2011. v. 1, p. 154–159.
- MOURA, F. F.; FRANCO, L. M.; MELO, S. L.; FERNANDES, M. A. Development of Learning Styles and Multiple Intelligences through Particle Swarm Optimization. **Systems, Man, and Cybernetics (SMC), 2013 IEEE International Conference on**, p. 835–840, 2013. ISSN 1062-922X.
- NEDUNGADI, P. Predicting Students ' Performance on Intelligent Tutoring System - Personalized Clustered BKT. 2014.
- NENKOV, N.; DIMITROV, G.; DYACHENKO, Y.; KOEVA, K. Artificial intelligence technologies for personnel learning management systems. In: **2016 IEEE 8th International Conference on Intelligent Systems (IS)**. IEEE, 2016. Disponível em: <https://doi.org/10.1109/is.2016.7737420>.
- OLIVEIRA, H. L. de. **MHV Uma Metaheurística baseada no comportamento da Vitis Vinifera**. 1–58 p., 2016.
- OLIVEIRA, H. L. de; ANDRADE, A.; ASSIS, L.; PITANGUI, C.; CARVALHO, L. Lana de. Uma nova meta-heurística inspirada no comportamento da vitis vinifera. In: . [s.n.], 2017. p. 14. Disponível em: [https://www.researchgate.net/profile/Alessandro\\_Andrade/publication/321757881\\_UMA\\_NOVA\\_META-HEURISTICA\\_INSPIRADA\\_NO\\_COMPORTEMENTO\\_DA\\_VITIS\\_VINIFERA/links/5a304eef458515a13d85495d/UMA-NOVA-META-HEURISTICA-INSPIRADA-NO-COMPORTEMENTO-DA-VITIS-VINIFERA.pdf](https://www.researchgate.net/profile/Alessandro_Andrade/publication/321757881_UMA_NOVA_META-HEURISTICA_INSPIRADA_NO_COMPORTEMENTO_DA_VITIS_VINIFERA/links/5a304eef458515a13d85495d/UMA-NOVA-META-HEURISTICA-INSPIRADA-NO-COMPORTEMENTO-DA-VITIS-VINIFERA.pdf).

OLIVEIRA, H. L. de; ANDRADE, A.; ASSIS, L.; PITANGUI, C.; ALMEIDA, A. Machado França de; DORÇA, F. Detecção automática e dinâmica de estilos de aprendizagem para sistemas adaptativos inteligentes para a educação utilizando a meta-heurística vitis vinífera. In: . [S.l.: s.n.], 2018. p. 1323.

OLIVEIRA, H. L. de; ANDRADE, A.; ASSIS, L.; PITANGUI, C.; CARVALHO, L. Lana de Mhv - uma nova meta-heurística inspirada no comportamento da vitis vinífera. In: \_\_\_\_\_. Editora Poisson, 2018. v. 1, p. 76–88. Disponível em: <https://www.poisson.com.br/livros/producao/foco1/>.

ORNELAS, C.; ROCHA, L.; MATA, L.; TULER, E.; ZIVIANI, N. Problemas NP-Completo e Algoritmos. In: **Projetos de Algoritmos**. [S.l.: s.n.], 2006. cap. 9.

ÖZPOLAT, E.; AKAR, G. B. Automatic detection of learning styles for an e-learning system. **Computers & Education**, Elsevier BV, v. 53, n. 2, p. 355–367, sep 2009. Disponível em: <https://doi.org/10.1016/j.compedu.2009.02.018>.

PASSINO, K. M.; YURKOVICH, S.; REINFRANK, M. **Fuzzy control**. [S.l.]: Addison-wesley Reading, MA, 1998. v. 20.

PELIKAN, M.; GOLDBERG, D. E.; CANTÚ-PAZ, E. Boa: The bayesian optimization algorithm. In: **Proceedings of the 1st Annual Conference on Genetic and Evolutionary Computation - Volume 1**. San Francisco, CA, USA: Morgan Kaufmann Publishers Inc., 1999. (GECCO'99), p. 525–532. ISBN 1-55860-611-4. Disponível em: <http://dl.acm.org/citation.cfm?id=2933923.2933973>.

POPESCU, E. A unified learning style model for technology-enhanced learning. **International Journal of Distance Education Technologies**, IGI Global, v. 8, n. 3, p. 65–81, 2010. Disponível em: <https://doi.org/10.4018/jdet.2010070105>.

REDDY, D. L. S.; PHANIKUMAR, D. V. V. S.; BATCHANABOYINA, M. R.; RAVINDRABABU, B. Learning styles vs suitable courses. **Proceedings of the 2013 IEEE International Conference in MOOC, Innovation and Technology in Education, MITE 2013**, p. 152–157, 2013.

RICH, E.; KNIGHT, K. Artificial intelligence. **McGraw-Hill, New**, 1991.

RUSSELL, S.; NORVIG, P.; INTELLIGENCE, A. A modern approach. **Artificial Intelligence. Prentice-Hall, Egnlewood Cliffs**, v. 25, p. 27, 1995.

SANGINETO, E.; CAPUANO, N.; GAETA, M.; MICARELLI, A. Adaptive course generation through learning styles representation. **Universal Access in the Information Society**, Springer Nature, v. 7, n. 1-2, p. 1–23, oct 2007. Disponível em: <https://doi.org/10.1007/s10209-007-0101-0>.

SCHIAFFINO, S.; GARCIA, P.; AMANDI, A. Computers & Education eTeacher : Providing personalized assistance to e-learning students. v. 51, p. 1744–1754, 2008.

SCOTT, E.; RODRÍGUEZ, G.; SORIA, Á.; CAMPO, M. Computers in Human Behavior Are learning styles useful indicators to discover how students use Scrum for the first time ? **COMPUTERS IN HUMAN BEHAVIOR**, Elsevier Ltd, v. 36, p. 56–64, 2014. ISSN 0747-5632. Disponível em: <http://dx.doi.org/10.1016/j.chb.2014.03.027>.



SENA, E.; VIVAS, A.; ASSIS, L.; PITANGUI, C. Proposta de uma abordagem computacional para detecção automática de estilos de aprendizagem utilizando modelos ocultos de markov e FSLSM. In: **Anais do XXVII Simpósio Brasileiro de Informática na Educação (SBIE 2016)**. Sociedade Brasileira de Computação - SBC, 2016. Disponível em: <https://doi.org/10.5753/cbie.sbie.2016.1126>.

SEVARAC, Z.; DEVEDZIC, V.; JOVANOVIĆ, J. Expert Systems with Applications Adaptive neuro-fuzzy pedagogical recommender. **Expert Systems With Applications**, Elsevier Ltd, v. 39, n. 10, p. 9797–9806, 2012. ISSN 0957-4174. Disponível em: <http://dx.doi.org/10.1016/j.eswa.2012.02.174>.

SILVA, D. H.; DORÇA, F. A. 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**, v. 22, n. 02, p. 1, 2014. ISSN 1414-5685. Disponível em: <http://www.br-ie.org/pub/index.php/rbie/article/view/2374>.

SINGH, M.; VALTORTA, M. An algorithm for the construction of bayesian network structures from data. In: MORGAN KAUFMANN PUBLISHERS INC. **Proceedings of the Ninth international conference on Uncertainty in artificial intelligence**. [S.l.], 1993. p. 259–265.

SOFFNER, R. K.; BARBOSA, A. L. Tecnologia educacional e o enfoque sociocomunitário. **Revista de Ciências da Educação**, 2011.

SOLOMAN, B. A.; FELDER, R. M. Index of learning styles questionnaire. **Retrieved March**, v. 26, p. 2003, 1999.

SOMA, J.; SHANKER, Y. **History Of Artificial Intelligence (AI)**. [S.l.], 2016. 3 p. Disponível em: <http://www.law.du.edu/documents/privacy-foundation/history-of-artificial-intelligence.pdf>.

SPROCK, A. S. Fuzzy Learning Styles Questionnaire Based in Felder and Silverman Model. 2016.

TALBI, E.-G.; BASSEUR, M.; NEBRO, A. J.; ALBA, E. Multi-objective optimization using metaheuristics: non-standard algorithms. **International Transactions in Operational Research**, Wiley Online Library, v. 19, n. 1-2, p. 283–305, 2012.

TRUONG, H. M. Integrating learning styles and adaptive e-learning system: Current developments, problems and opportunities. **Computers in Human Behavior**, Elsevier BV, v. 55, p. 1185–1193, feb 2016. Disponível em: <https://doi.org/10.1016/j.chb.2015.02.014>.

VIOLA, S. R.; GRAF, S.; LEO, T. *et al.* Analysis of felder-silverman index of learning styles by a data-driven statistical approach. In: IEEE. **Multimedia, 2006. ISM'06. Eighth IEEE International Symposium on**. [S.l.], 2006. p. 959–964.

WEN, D.; GRAF, S.; LAN, C. H.; ANDERSON, T.; DICKSON, K. Supporting web-based learning through adaptive assessment. p. 45–78, 2007.

YAGIURA, M.; IBARAKI, T.; GLOVER, F. A path relinking approach with ejection chains for the generalized assignment problem. **European Journal of Operational Research**, Elsevier BV, v. 169, n. 2, p. 548–569, mar 2006. Disponível em: <https://doi.org/10.1016/j.ejor.2004.08.015>.

YANG, J.; HUANG, Z. X.; GAO, Y. X.; LIU, H. T. on a Pattern Recognition Technique. v. 1382, n. c, p. 1–13, 2014.

YANNIBELLI, V.; GODOY, D.; AMANDI, A. A genetic algorithm approach to recognise students' learning styles. **Interactive Learning Environments**, Informa UK Limited, v. 14, n. 1, p. 55–78, apr 2006. Disponível em: <https://doi.org/10.1080/10494820600733565>.

ZUBEN, F. J. V. **Introdução à Inteligência Artificial**. 2013. 1–48 p.

