

# Detecção e Correção Automática de Estilos de Aprendizagem em Sistemas Adaptativos para Educação

Fabiano Azevedo Dorça <sup>1</sup>  
Luciano Vieira Lima <sup>2</sup>  
Márcia Aparecida Fernandes <sup>1</sup>  
Carlos Roberto Lopes <sup>1</sup>

**Resumo:** Um dos aspectos mais importantes em sistemas adaptativos para educação é a capacidade de prover personalização de acordo com as necessidades específicas de cada estudante. Neste contexto, este trabalho apresenta uma abordagem promissora para detecção e correção automática de estilos de aprendizagem (EA) baseada em cadeias de Markov. A maioria dos trabalhos nesta área apresentam abordagens complexas e ineficientes em algum aspecto. A abordagem apresentada neste trabalho é baseada na combinação de estilos de aprendizagem (CEA) e na correção dinâmica das inconsistências no modelo do estudante (ME), levando em consideração o forte aspecto não-determinístico do processo de aprendizagem. Resultados promissores foram obtidos nos testes realizados com esta abordagem e são discutidos neste trabalho.

**Abstract:** One of the most important features of adaptive e-learning systems is the personalisation according to specific requirements of each individual student. In this paper, we introduce a promising approach for automatic detection and correction of student learning styles (LS) based on Markov Chains. Most of the work in this field presents complex and inefficient approaches. Our approach is based on learning styles combination (LSC) and dynamic correction of inconsistencies in the student model (SM), taking into account the non-deterministic aspect of the learning process. Promising results were obtained from tests, and some of them are discussed in this paper.

## 1 Introdução

A maioria dos sistemas de *e-learning* não consideram as características particulares dos estudantes e o mesmo conteúdo e estratégia pedagógica são comumente usadas para todos [1] [2] [3]. Porém, um movimento em direção à introdução de adaptatividade [4] [5] [6]

---

<sup>1</sup>Faculdade de Computação, UFU

{fabiano, marcia, crlopes@facom.ufu.br}

<sup>2</sup>Faculdade de Engenharia Elétrica, UFU

{vieira@ufu.br}

nestes sistemas pode ser observado nos últimos anos, com o objetivo de personalizar o processo de aprendizagem [7]. Ou seja, o objetivo é proporcionar mecanismos personalizados para que o estudante possa selecionar caminhos dentro dos mecanismos gerais disponibilizados pelo professor ou professor-tutor em ambientes informatizados para facilitação da sua aprendizagem. Nesta perspectiva, as principais características do estudante consideradas no processo de personalização são os objetivos de aprendizagem [8], o nível de conhecimento [9], os interesses [10], as preferências [11], os estereótipos [5], as preferências cognitivas [12] e os estilos de aprendizagem (EA)[13]. Porém, contrariando esta linha, sistemas amplamente conhecidos e utilizados, como Blackboard [14], WebCT [2] e Moodle [1] não oferecem nenhum nível de personalização.

Especificamente, estilos de aprendizagem [13] e seus efeitos no processo de aprendizagem são cuidadosamente examinados em [15]. Os estilos de aprendizagem e as correspondentes estratégias instrucionais têm sido intensamente estudadas no ambiente de ensino tradicional (presencial). Pesquisadores da área sugerem que relacionar estilos de aprendizagem dos estudantes com ações instrucionais apropriadas é um fator importante ao estímulo da aprendizagem, conforme alerta Coffield *et al* [15]. Um grande número de estudos atestam que a aprendizagem pelo estudante é facilitada se os métodos de ensino utilizados estiverem de acordo com os seus estilos de aprendizagem [16] [17] [18] [7] [13] [15] [19] [20] [21] [22] [23] [24] [25] [26]. Porém, Cristea e Stash [27] asseveram que ainda é baixa a quantidade de pesquisas envolvendo a aplicação de estilos de aprendizagem no novo espaço educacional introduzido pela *web*.

Isto posto, este trabalho propõe a utilização de Cadeias de Markov [28] na definição de um modelo probabilístico baseado na combinação de estilos de aprendizagem (CEA) [29] para detecção e correção automática das preferências do estudante. Esta proposta é contrária aos tradicionais processos determinísticos comumente implementados, e vem a possibilitar que sistemas adaptativos para educação existentes possam, de forma eficiente, automaticamente detectar os estilos de aprendizagem dos estudantes com alto índice de precisão. Em face do exposto, é preciso lembrar que a eficiência obtida por esta abordagem se deve em grande parte ao fato desta ser baseada em um processo estocástico, que se caracteriza principalmente pela representação da variabilidade e das incertezas inerentes ao processo de aprendizagem de cada estudante.

Considerando este aspecto, este trabalho propõe uma abordagem eficiente na detecção automática de estilos de aprendizagem, que apresenta resultados com alto nível de precisão (como apresentado na seção 5) e baixo custo computacional, principalmente se comparada a outras abordagens analisadas que utilizam regras complexas e técnicas de aprendizagem de máquina, apresentadas na seção 2. Em consonância com Coffield *et al* [15] e conforme pode ser observado nos resultados apresentados na seção 5, quando o modelo do estudante (ME) [30] está correto em relação aos EA's, o ganho de desempenho pelo estudante é notório

(conforme discutido na seção 5).

Esta abordagem foi testada utilizando-se técnicas de simulação computacional [31], que permitiu observar nitidamente o comportamento do modelo em diferentes contextos e situações. Em todos os testes ministrados obteve-se resultados promissores, que nos inspiram a implementar e utilizar este modelo em LMS's (Learning Management System) existentes.

As demais seções que compõem este artigo são descritas a seguir. A seção 2 analisa alguns dos principais trabalhos relacionados ao presente trabalho. A seção 3 apresenta de forma concisa e sucinta as teorias essenciais a este trabalho. A seção 4 descreve a abordagem proposta, assim como os principais detalhes de sua implementação. A seção 5 apresenta a experimentação da abordagem proposta e analisa os resultados obtidos em uma diversidade de testes realizados. Finalmente, a seção 6 traça algumas conclusões e discute os trabalhos futuros.

## 2 Trabalhos Relacionados

Sistemas tais como AHA! [32], KOD [33], LSAS [22], TANGOW [34], ARTHUR [35], CS388 [36], MAS-PLANG [37], INSPIRE [38], LS-Plan [39], Manic [40], dentre outros, tem o foco principal no fornecimento de uma experiência de aprendizagem que atenda aos estilos de aprendizagem dos estudantes. Para isto, utilizam questionários de auto-avaliação, tal como o Index of Learning Styles Questionnaire (ILS) [41], através dos quais inferem os estilos de aprendizagem dos estudantes, sem nenhum nível de automatização.

Em contrapartida, diversas abordagens para detecção automática de estilos de aprendizagem tem sido propostas, como pode-se observar em [13] [42] [43]. Em geral, estas abordagens utilizam sistemas de inferência determinísticos baseados em padrões comportamentais do estudante, tentando detectar seus estilos de aprendizagem através de suas ações no sistema. Uma crítica a estas abordagens é a dificuldade em se construir regras capazes de inferir eficientemente os EA's a partir das ações do estudante. Além disto, em muitos sistemas, tal como o AHA! [32], estas regras precisam ser definidas pelo tutor humano, o que sem dúvida cria um grande empecilho quanto à utilização deste tipo de abordagem.

Abordagens mais complexas podem ser observadas em [44] [45] [46] [47] [48] [49]. Estas abordagens utilizam técnicas de aprendizagem de máquina, especificamente através de Redes Bayesianas ou Redes Neurais. Uma crítica a estas abordagens é sua alta complexidade de implementação e grande consumo de recursos computacionais, de forma que a presença simultânea de vários estudantes pode comprometer, ou mesmo inviabilizar seu uso.

Neste contexto, acredita-se que a abordagem estocástica apresentada neste trabalho é mais eficiente por diversas razões, dentre elas:

- levar em consideração que vários fatores influenciam no desempenho do estudante e não apenas os seus estilos de aprendizagem. Alguns destes fatores são delineados em [4] [5] [6] [7] [8] [9] [10] [11] [12], dificultando inferências determinísticas;
- abarcar o fato de que não se pode ter certeza de em que grau cada estilo de aprendizagem influencia no desempenho de um estudante, e se influencia da mesma forma em todos os estudantes [50];
- considerar que não se sabe como as preferências por estilos de aprendizagem de um estudante podem mudar ao longo do tempo e se esta mudança estará associada a outros fatores, como o domínio sendo estudado [51];
- levar em consideração que é impossível saber o quão correto é o resultado obtido em um questionário de auto-avaliação, e um sistema que use um processo de adaptação determinístico tende a levar mais tempo na detecção de inconsistências, já que não analisa o desempenho do estudante frente a outras combinações de estilos de aprendizagem que não aquela previamente obtida pelo questionário, o que dificulta a correção das preferências do estudante;
- considerar que não apenas a evolução das preferências por estilos de aprendizagem, mas vários outros aspectos do modelo do estudante, tal como o grau de conhecimento do domínio, evoluem de maneira não-determinística, reforçando a natureza estocástica do processo de aprendizagem;
- eliminar a necessidade de descobrir padrões de comportamento dos estudantes, como em [45], considerando que a obtenção de tais padrões é difícil e pode conter alto grau de incerteza;
- como consequência do item anterior, ser independente de LMS, por não depender explicitamente do acoplamento existentes entre os estilos de aprendizagem e as ações do estudante em um sistema específico como ocorre nas abordagens tradicionais, por exemplo, aquelas apresentadas em [45][13];
- por submeter o estudante a uma diversidade de CEA's, possibilitar-lhe evoluir seus estilos de aprendizagem, para que este possa se tornar melhor preparado para uma diversidade maior de circunstâncias, conforme defende Messick [52];
- levar em consideração a natureza dinâmica dos estilos de aprendizagem do estudante, cujas preferências podem mudar quando o conteúdo varia [44], evoluir naturalmente ao longo do processo de aprendizagem [52] ou por outras razões desconhecidas [43];
- eliminar a necessidade de se utilizar técnicas complexas de aprendizagem de máquina, que são difíceis de serem implementadas e demandam elevado poder computacional,

além de serem suscetíveis a complicações, conforme muito bem expõe Castilho *et al* [43];

A próxima seção apresenta as teorias e conceitos fundamentais relativos à abordagem apresentada neste trabalho.

## 3 Referencial Teórico

### 3.1 Taxonomia de Bloom

A Taxonomia de Bloom [53] [54] [55] [56] descreve objetivos educacionais como uma formulação explícita das mudanças que ocorrem nos estudantes mediante processos educacionais, através de um sistema de classificação de objetivos de aprendizagem e do desenvolvimento de capacidades e habilidades intelectuais. Além disto, permite expressar qualitativamente o nível de conhecimento do estudante em determinado conceito do domínio de forma qualitativa. É uma ferramenta de ensino e medição de conhecimento, que possui seis níveis: conhecimento, compreensão, aplicação, análise, síntese e avaliação. Algumas aplicações práticas desta taxonomia em sistemas educacionais são apresentadas por [57] e [58]. Algumas vantagens da utilização da Taxonomia de Bloom na modelagem do estudante, de acordo com [53] [54] [55] [56], são:

- cada nível da taxonomia fornece ações instrucionais apropriadas, o que permite a construção de sistemas adaptativos para educação que levem em consideração o nível cognitivo do estudante, considerando que os objetos de aprendizagem [59] usados sejam classificados de acordo com esta taxonomia;
- os níveis da taxonomia apresentam uma estrutura hierárquica, sendo organizados de acordo com o incremento da complexidade em cada nível, o que permite a definição clara de objetivos de aprendizagem no modelo do estudante;
- os níveis apresentam uma estrutura cumulativa onde um nível superior utiliza capacidades que foram adquiridas em um nível inferior, ou seja, o domínio de um nível é pré-requisito para adentrar o próximo, o que torna esta taxonomia uma excelente estratégia para medição de conhecimento e seu devido armazenamento do modelo do estudante.

Além disto, os objetivos de aprendizagem de cada conceito de um curso podem ser definido pelo tutor. Desta forma, um mesmo curso pode ser oferecido para diferentes públicos-alvo, adequando-se os objetivos de aprendizagem a cada público.

### 3.2 Estilos de Aprendizagem

Um modelo de estilos de aprendizagem classifica um estudante de acordo com a forma como este percebe e processa a informação. Muitos modelos de estilos de aprendizagem foram propostos, como por exemplo Kolb [60], Honey and Mumford [61], Entwistle [62], Pask [63] e Felder e Silverman (FSLSM) [64]. Cada um destes modelos descrevem diferentes aspectos de como estudantes preferem aprender.

Dentre os autores que tratam dessa questão destaca-se Coffield *et al* [15], que examina detalhadamente 13 dos mais conhecidos e influentes modelos estilos de aprendizagem, apresentando uma revisão sistemática destes modelos. Graf e Kinshuk [7] são unânimes ao afirmar que o FSLSM é um dos mais frequentemente utilizados modelos de estilos de aprendizagem na construção de sistemas adaptativos para educação por uma diversidade de razões. Em consonância com esta postura, Kuljis e Liu [65] e Carver *et al* [66] argumentam que o FSLSM é o modelo mais apropriado para implementação de sistemas adaptativos para educação.

Neste contexto, Graf e Kinshuk [7] [67] informam que o FSLSM utiliza o conceito de dimensões e, então, descreve estilos de aprendizagem em mais detalhes, baseado em uma escala de 4 dimensões. Conforme colocado por Felder e Silverman [64], são elas: ativo-reflexivo, sensitivo-intuitivo, visual-verbal, sequencial-global. Além disto, de acordo com Kinshuk *et al* [18] o FSLSM combina a maioria dos modelos de estilos de aprendizagem tais como o modelo de Kolb [60], Pask [63] e o indicador de Myers-Briggs [68].

De acordo com Felder e Silverman [64], estudantes ativos aprendem com maior facilidade tentando resolver um problema prático e preferem trabalhar em grupo, enquanto estudantes reflexivos preferem pensar sobre o problema e como resolvê-lo antes de tentar, e preferem trabalhar individualmente. Estudantes sensitivos preferem aprender através de material concreto, tal como exemplos, tendem a ser mais práticos e cuidadosos com detalhes, enquanto que estudantes intuitivos preferem material abstrato, tal como teorias e conceitos, e gostam de desafios, tendendo a ser mais inovativos do que estudantes sensitivos. Estudantes visuais se lembram melhor do que tenham visto, enquanto estudantes verbais preferem palavras, independentemente de serem escritas ou faladas. Finalmente, estudantes sequenciais aprendem em passos lineares, preferem seguir caminhos lineares pré-definidos, e serem guiados pelo processo de aprendizagem. Em contrapartida, estudantes globais aprendem em saltos largos e preferem mais liberdade no processo de aprendizagem.

Uma característica marcante do FSLSM, e fundamental para este trabalho, é que 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 quatro dimensões, medida em valores dentro do intervalo [-11..+11], conforme propõe Felder e Silverman [64]. Ao se utilizar escalas ao invés de tipos, os pesos das preferências podem ser descritos, possibilitando

distinguir-se entre preferências fortes, moderadas e leves, conforme atesta [18].

Outra característica fundamental do FLSM para este trabalho é que ele considera estilos de aprendizagem como tendências, ou seja, estudantes possuem uma tendência por um estilo de aprendizagem, mas podem, conforme alega Kinshuk *et al* [18], agir diferente em situações particulares, ou seja, de forma não-determinística. Ainda, Kinshuk *et al* [18] expõe que ao incorporar o conceito de tendências, a descrição dos estilos de aprendizagem considera exceções e situações extraordinárias, evidenciando mais uma vez o não-determinismo do comportamento e desempenho do estudante, que passa a ser visto como probabilístico ao invés de determinístico, cujas probabilidades são dadas pelos pesos das preferências em cada uma das quatro dimensões do FLSM, dentre outras variáveis.

### 3.3 Processos Estocásticos e Cadeias de Markov

Pode-se definir um processo estocástico como uma coleção de variáveis probabilísticas que descrevem o processo executado por um sistema em um período de tempo. Em termos formais, uma variável randômica  $X(t)$  representa o estado do sistema no tempo  $t$  [28] [69]. Ou seja, é um fenômeno que varia em algum grau de forma imprevisível, à medida que o tempo passa.

A imprevisibilidade, neste caso, significa que ao se observar sequências inteiras do processo em diversas ocasiões diferentes, mas sob condições idênticas, as sequências resultantes da execução do processo são, em geral, diferentes. Desta forma, a probabilidade aparece, mas não no sentido de que cada resultado de uma experiência aleatória determine um valor único. Ao invés disto, o resultado do processo estocástico é uma sequência ou série de valores, uma função, e não apenas um valor único.

Chama-se cadeias de Markov [69] um processo estocástico com as seguintes propriedades:

- Cada resultado pertence a um conjunto finito de estados  $(a_1, a_2, a_3, \dots, a_n)$ , chamado espaço de estados do sistema. Se o estado resultante da  $n$ -ésima tentativa é  $a_i$ , então, o sistema se encontra no estado  $a_i$  no instante  $n$ .
- O resultado de um ensaio depende apenas do resultado do ensaio imediatamente anterior. Desta forma, a cada par de estados  $(a_i, a_j)$  está associada a probabilidade  $P_{X_n/X_{n-1}}$  de ocorrer  $a_i$  no instante  $n$  imediatamente após ter ocorrido  $a_j$  no instante  $n-1$ .

Os valores atribuídos a  $P_{X_n/X_{n-1}}$  correspondem à probabilidade de transição entre estados e formam uma matriz de transição de estados  $P$ . Assim, a cada estado  $a_i$  corresponde

a  $i$ -ésima linha  $(p_{i1}, p_{i2}, \dots, p_{ij})$  da matriz de transição de estados  $P$ . Esta linha representa as probabilidades de ocorrência de  $a_i$  no instante  $n$  a partir do estado  $a_j$ , ocorrido no instante anterior,  $n-1$ .

## 4 Desenvolvimento e Detalhes de Implementação

Esta seção apresenta o desenvolvimento da abordagem proposta, considerando inicialmente o modelo do estudante utilizado e, em seguida, detalhando o processo estocástico de detecção e correção automática de estilos de aprendizagem.

### 4.1 Modelo do Estudante

O modelo do estudante (ME) é utilizado para avaliar o nível de conhecimento do estudante e para que se possa fazer inferências a respeito de suas características, concepções e estratégias de raciocínio empregadas para atingir o nível de conhecimento atual [30]. Além disto, o ME permite mudar vários aspectos do sistema, em resposta a características específicas do estudante [70]. Estas características representam o conhecimento e as preferências que o sistema assume que o estudante possui.

O ME [70] utilizado neste trabalho é baseado na integração da Taxonomia de Bloom para níveis cognitivos com o FSLSM para estilos de aprendizagem, conforme ilustra a Tabela 1. Desta maneira, o ME definido nesta abordagem considera de forma eficiente estilos de aprendizagem, objetivos de aprendizagem e nível de conhecimento do estudante.

Tabela 1: Modelo Estudante

Estilos de Aprendizagem							
Processamento		Percepção		Entrada		Organização	
Ativo	Reflexivo	Sensitivo	Intuitivo	Visual	Verbal	Sequencial	Global
35,0	65,0	17,0	83,0	89,0	11,0	84,0	16,0
Estado Cognitivo e Objetivos de Aprendizagem							
$EC = \{\langle C1, IND \rangle \dots \langle C80, IND \rangle\}$							
$OA = \{\langle C1, 5 \rangle \dots \langle C80, 5 \rangle\}$							

Conforme observa-se na Tabela 1, considera-se os estilos de aprendizagem de acordo com o FSLSM em suas 4 dimensões e o nível de conhecimento do estudante e objetivos de aprendizagem de acordo com a Taxonomia de Bloom. A abordagem utilizada na modelagem do estudante é a de sobreposição, de forma que o modelo do estudante é visto como um subconjunto da base de conhecimento do sistema [71]. Esta abordagem se mostrou aderente ao tipo de solução proposta neste trabalho para o problema da detecção automática de estilos



de aprendizagem devido à sua objetividade e transparência na representação do conhecimento do estudante, e desta forma mostrando eficiência e facilidade de implementação. De qualquer forma, o uso de outras abordagens na modelagem do estudante não resulta em problema algum para a solução proposta neste trabalho, podendo esta ser implantada em LMS's que utilizam outras abordagens.

A preferência por cada estilo de aprendizagem é armazenada no ME como um valor real dentro do intervalo [0..100] ao invés de valores inteiros no intervalo [-11..+11]. Além disto, o resultado da soma dos valores das preferências dentro de uma dimensão é necessariamente 100. Esta conversão foi necessária para que fosse possível a implementação do modelo de adaptação estocástico através de cadeias de Markov no que tange à construção das matrizes de transição de estados, conforme exposto na próxima subseção. Vale ressaltar que esta é apenas uma mudança de escala e não tem impacto algum no funcionamento do FSLSM.

## 4.2 Detecção e Correção Automática dos Estilos de Aprendizagem


De acordo com [29], uma CEA (combinação de estilos de aprendizagem) é uma tupla formada por 4 estilos de aprendizagem, cada um pertencente a uma dimensão do FSLSM. Desta forma, existem 16 ( $2^4$ ) possíveis CEA's, conforme apresentado a seguir (considere S = Sensitivo; I = Intuitivo; Vi = Visual; Ve = Verbal; A = Ativo; R = Reflexivo; Seq = Sequencial; G = Global):

$$CEA's = \{(S,Vi,A,Seq), (S,Vi,A,G), (S,Vi,R,Seq), (S,Vi,R,G), (S,Ve,A,Seq), (S,Ve,A,G), (S,Ve,R,Seq), (S,Ve,R,G), (I,Vi,A,Seq), (I,Vi,A,G), (I,Vi,R,Seq), (I,Vi,R,G), (I,Ve,A,Seq), (I,Ve,A,G), (I,Ve,R,Seq), (I,Ve,R,G)\}$$


Isto posto, propõe-se neste trabalho que a cada seção de aprendizagem do curso o estudante seja submetido a um conjunto de objetos de aprendizagem que atendam a uma CEA específica, gerada estocasticamente de acordo com os valores dos estilos de aprendizagem armazenados no ME. Ou seja, a CEA é uma combinação de 4 variáveis probabilísticas, definidas pelas 4 dimensões do FSLSM, e cada variável possui 2 valores possíveis, e cada valor representa um estilo de aprendizagem, cuja probabilidade é dada pelo grau de preferência armazenado no ME.

Então, o processo de composição da CEA é modelado através de 4 cadeias de Markov concorrentes. As cadeias de Markov e respectivas matrizes de transição de estados referentes ao ME apresentado na Tabela 1 são apresentadas na Figura 1. Cada estado de uma cadeia de Markov representa um estilo de aprendizagem dentro de uma dimensão do FSLSM. Na subfigura 1a, o estado 1 representa o estilo Ativo e 2 representa o estilo Reflexivo. Na subfigura 1b, o estado 1 representa o estilo Sensitivo e 2 representa o estilo Intuitivo. Na subfigura 1c, o estado 1 representa o estilo Visual e 2 representa o estilo Verbal. Na subfigura 1d, o estado 1 representa o estilo Sequencial e 2 representa o estilo Global. As transições entre os esta-

dos representam as probabilidades de ocorrência do estilo de aprendizagem na composição estocástica de uma CEA.



(a) Dimensão Processamento: (1) Ativo (2) Reflexivo (b) Dimensão Percepção: (1) Sensitivo (2) Intuitivo



(c) Dimensão Entrada: (1) Visual (2) Verbal (d) Dimensão Organização: (1) Sequencial (2) Global

Figura 1: Cadeias de Markov durante o processo de composição de uma CEA para o estudante representado pela Tabela 1

Note que a cada estado  $a_i$  corresponde a  $i$ -ésima linha  $(p_{i1}, p_{i2}, \dots, p_{ij})$  da matriz de transição de estados, que representa as probabilidades de ocorrência de  $a_i$  ( $X_n$ ) no instante  $n$  a partir do estado  $a_j$  no instante  $n-1$ . Por exemplo, para a dimensão Processamento, se a CEA atual é composta pelo estado 1 (Ativo), então, tem-se 35% de probabilidade da próxima CEA continuar em Ativo, e 65% de probabilidade da nova CEA ser composta por Reflexivo (estado

2). Se a CEA atual é Reflexivo, então tem-se 65% de probabilidade da nova CEA continuar composta pelo estilo Reflexivo, e 35% de probabilidade de se tornar Ativo. Estas matrizes de probabilidade são alteradas constantemente ao longo do processo de ensino-aprendizagem à medida que o sistema corrige as preferências no ME. Desta forma, este processo é muito particular a cada estudante, já que cada um possui diferentes preferências armazenadas no ME. Ou seja, para cada estudante, existem 4 matrizes de transição de estados distintas dadas por seu ME.

Os valores das preferências armazenadas no ME são modificadas sempre que o sistema detectar problemas de aprendizagem pelo estudante, ou seja, quando o seu desempenho for considerado insatisfatório na avaliação de uma seção de aprendizagem. Isto ocorre quando o desempenho do estudante não atinge um limiar, que pode ser particular a cada LMS, ou até mesmo a um curso específico dentro de um LSM. Para decidir quais preferências devem ser alteradas no ME, foi implementado um conjunto de regras de produção, do tipo *se...então*, que levam em consideração os estilos de aprendizagem armazenados no ME e a CEA considerada durante a seção de aprendizagem. Estas regras são executadas para cada uma das 4 dimensões do FSLSM sempre que o estudante obtém um desempenho insatisfatório. Se nenhuma regra for satisfeita para determinada dimensão, o ME não é alterado nesta dimensão. Considerando que cada dimensão do FSLSM possui dois estilos de aprendizagem, tratados aqui por A e B, implementou-se as seguintes regras:

R1:SE  $(ME[di]_A \geq ME[di]_B) \wedge (CEA[di] = "A")$  ENTÃO

.... $ME[di]_A = ME[di]_A - K_c$

.... $ME[di]_B = ME[di]_B + K_c$

R2:SE  $(ME[di]_B \geq ME[di]_A) \wedge (CEA[di] = "B")$  ENTÃO

.... $ME[di]_B = ME[di]_B - K_c$

.... $ME[di]_A = ME[di]_A + K_c$

R3:SE  $(ME[di]_A \geq ME[di]_B) \wedge (CEA[di] = "B")$  ENTÃO

.... $ME[di]_B = ME[di]_B - K_c$

.... $ME[di]_A = ME[di]_A + K_c$

R4:SE  $(ME[di]_B \geq ME[di]_A) \wedge (CEA[di] = "A")$  ENTÃO

.... $ME[di]_A = ME[di]_A - K_c$

.... $ME[di]_B = ME[di]_B + K_c$

tal que:

- $ME[di]_A$  representa o valor armazenado no ME na dimensão i para o estilo de aprendizagem A, com  $i = 1..4$ .
- $ME[di]_B$  representa o valor armazenado no ME na dimensão i para o estilo de aprendizagem B, com  $i = 1..4$ .

- CEA[di] representa o estilo de aprendizagem que constitui a CEA em relação à dimensão  $i$ , com  $i = 1..4$ .
- $K_c$  é um coeficiente calculado, que leva em consideração o valor da distância entre os EA's da dimensão e o desempenho obtido pelo estudante e determina o valor da correção das preferências no ME.

Esta abordagem para alteração dos EA's do estudante é inspirada naquelas encontradas em sistemas adaptativos como Reinforcement learning [72] e Simulated Annealing [73]. Uma diversidade de aspectos podem envolver a avaliação de desempenho do estudante, tais como quantidade de acertos, tempo de resposta, tempo despendido em uma página, número de retrocessos da barra de rolagem, quantidade de acessos a ferramentas de comunicação e trabalho em grupo, dentre outros [74] [75]. A construção de um modelo que leve em consideração todos estes aspectos e que permita ao sistema fazer inferências, com segurança, sobre os problemas de aprendizagem do estudante é uma questão complexa, e diversas abordagens têm sido propostas com este intuito, a exemplo de [74] [75].

Desta forma, com o intuito de se testar o modelo proposto neste trabalho isolando toda esta complexidade, desenvolveu-se uma função que permitisse simular o desempenho do estudante. Com este intuito, foi construído um modelo probabilístico, expresso por um conjunto de distribuições de probabilidade que levam em consideração alguns parâmetros, definidos com base em estudos na literatura disponível sobre o impacto de estilos de aprendizagem no desempenho do estudante, conforme discute [16] [17] [18] [7] [13] [15] [19] [20] [21] [22] [23] [24] [25] [26]. O detalhamento desta função não é o foco deste trabalho, devendo ser detalhadamente descrito em trabalhos futuros. A próxima seção apresenta uma série de experimentos realizados com o modelo proposto, e os resultados obtidos.

## 5 Testes e Análise dos Resultados Obtidos

A verificação do modelo proposto consistiu em repetir 20 vezes cada um de uma série de testes, considerando-se uma situação diferente em cada um deles. A repetição de um teste por um certo número de vezes foi importante para que se pudesse observar o comportamento do processo em diversas ocasiões diferentes, mas sob condições idênticas. Com isto, foi possível notar que as sequências resultantes em um mesmo teste foram diferentes. Desta forma, observou-se o não-determinismo inerente ao processo de aprendizagem, sendo este um fenômeno que varia em algum grau, de forma imprevisível, caracterizado por uma sequência ou série de valores, e não apenas um único valor final. Mas, a similaridade dos valores finais obtidos (ME corrigido) em cada repetição do processo atesta a convergência do processo, e permite comprovar a eficiência e eficácia do modelo, e consequentemente validar a abordagem proposta. Ou seja, este processo possibilitou observar como diferentes estudan-

tes podem reagir de forma diferente ao mesmo tratamento e como o processo converge em direção à solução desejada: o ME coerente com a realidade.

Quatro destes testes e os seus resultados são apresentados nesta seção. Em todos eles foi considerado um conjunto de 30 conceitos a serem aprendidos pelo estudante. Considerou-se o nível cognitivo inicial do estudante, em todos os conceitos, equivalente ao primeiro nível da Taxonomia de Bloom. Além disto, considerou-se como objetivos de aprendizagem o nível máximo de conhecimento em todos os conceitos. A execução de um teste é finalizada quando o estudante atinge todos os objetivos de aprendizagem especificados no ME para todos os conceitos.

O processo de teste é iterativo e os níveis cognitivos do estudante em um conceito são atualizados de acordo com os resultados de seu desempenho a cada iteração do processo. Como consequência, este nível pode progredir, estagnar ou regredir (necessidade de revisão em um conceito). Desta forma, quanto maior a dificuldade do estudante em progredir no nível cognitivo, maior a quantidade de iterações necessárias para que o processo seja finalizado, devido a estagnações e retrocessos no nível cognitivo.

Em todos os testes apresenta-se gráficos em que o eixo Y mostra o valor das preferências pertencentes a uma dimensão do FSLSM armazenadas no ME, e o eixo X apresenta o número de iterações necessárias para finalizar o processo de teste. Isto permite visualizar claramente o processo de detecção e correção automática dos EA's armazenados no ME, para cada uma das dimensões do FSLSM.

Nos testes apresentados a seguir, a  $CEA_{real}$  representa as preferências reais do estudante, e que efetivamente afetam o resultado de seu desempenho no processo de avaliação. O peso das preferências (PP) modelam o peso de cada uma das preferências da  $CEA_{real}$ . Considera-se aqui pesos Forte, Moderado e Leve para cada uma das preferências do estudante, de acordo com [76] [17] [18]. Estes pesos influenciam no resultado do desempenho do estudante, de modo que contrariar uma preferência forte tende a causar um impacto negativo maior do que contrariar uma preferência moderada. Por sua vez, contrariar uma preferência moderada tende a causar um impacto maior do que contrariar uma preferência leve.

## 5.1 Primeiro Teste

Considera-se neste teste um estudante com ME apresentado na Tabela 2. As preferências reais do estudante são dadas por:

$$CEA_{real} = \{Reflexivo, Sensitivo, Visual, Global\}$$


$$PP = \{Forte, Forte, Moderada, Leve\}$$

Como pode-se observar na Tabela 2, o ME é inconsistente com a  $CEA_{real}$  nas dimensões Processamento e Percepção. A Figura 2 apresenta graficamente o processo de correção


Tabela 2: Modelo do Estudante (Primeiro Teste)

Estilos de Aprendizagem							
Processamento		Percepção		Entrada		Organização	
Ativo	Reflexivo	Sensitivo	Intuitivo	Visual	Verbal	Sequencial	Global
70,0	30,0	35,0	65,0	60,0	40,0	45,0	55,0
Estado Cognitivo e Objetivos de Aprendizagem							
$EC = \{\langle C1, IND \rangle \dots \langle C30, IND \rangle\}$							
$OA = \{\langle C1, 5 \rangle \dots \langle C30, 5 \rangle\}$							


automática dos EA's armazenados neste ME em uma das repetições deste teste. Em todas elas observou-se resultados finais similarmente satisfatórios, resultando em um ME correto em 100% das vezes.




(a) Processamento



(b) Percepção



(c) Entrada



(d) Organização

Figura 2: Evolução dos EA's armazenados no ME durante o primeiro teste

Observa-se na Figura 2 que foi necessário uma quantidade mais elevada de iterações, se comparado aos próximos testes, o que traduz um desempenho pior do estudante frente a duas preferências fortes incorretas no ME.

## 5.2 Segundo Teste

Considera-se neste teste um estudante com ME apresentado na Tabela 3. As preferências reais do estudante são dadas por:

$$CEA_{real} = \{Ativo, Intuitivo, Verbal, Sequencial\}$$

$$PP = \{Leve, Forte, Moderada, Leve\}$$

Tabela 3: Modelo do Estudante (Segundo Teste)

Estilos de Aprendizagem							
Processamento		Percepção		Entrada		Organização	
Ativo	Reflexivo	Sensitivo	Intuitivo	Visual	Verbal	Sequencial	Global
55,0	45,0	35,0	65,0	60,0	40,0	45,0	55,0
Estado Cognitivo e Objetivos de Aprendizagem							
$EC = \{\langle C1, IND \rangle \dots \langle C30, IND \rangle\}$							
$OA = \{\langle C1, 5 \rangle \dots \langle C30, 5 \rangle\}$							

No ME apresentado na Tabela 3, notam-se inconsistências nas dimensões Entrada e Organização do FSLSM. A Figura 3 apresenta graficamente o processo de correção automática dos EA's armazenados neste ME em uma das repetições deste teste. Em todas elas observou-se resultados finais similarmente satisfatórios, resultando em um ME correto em 100% das vezes.

Neste ponto é importante notar a redução na quantidade de iterações deste teste em relação ao primeiro. A quantidade de iterações maior no primeiro teste ocorre em decorrência de preferências fortes estarem incorretas no ME, gerando CEA's que constantemente contrariam pelo menos uma preferência forte do estudante, o que tende a causar maior impacto em seu desempenho. Em contrapartida, no segundo teste, CEA's que contrariam preferência moderada e/ou leve causam menor perturbação no desempenho.

## 5.3 Terceiro Teste

A seguir, considera-se o caso em que o estudante não respondeu o questionário de auto-avaliação, impedindo que o sistema inferisse suas preferências inicialmente. Desta forma, o ME apresenta preferências nulas em todas as dimensões do FSLSM, conforme pode-se observar na Tabela 4. As preferências reais do estudante são dadas por:

$$CEA_{real} = \{Reflexivo, Intuitivo, Visual, Sequencial\}$$

$$PP = \{Leve, Forte, Moderada, Leve\}$$

A Figura 4 apresenta graficamente o processo de detecção automática dos EA's do estudante em uma das observações realizadas durante este teste. Em todas as repetições deste

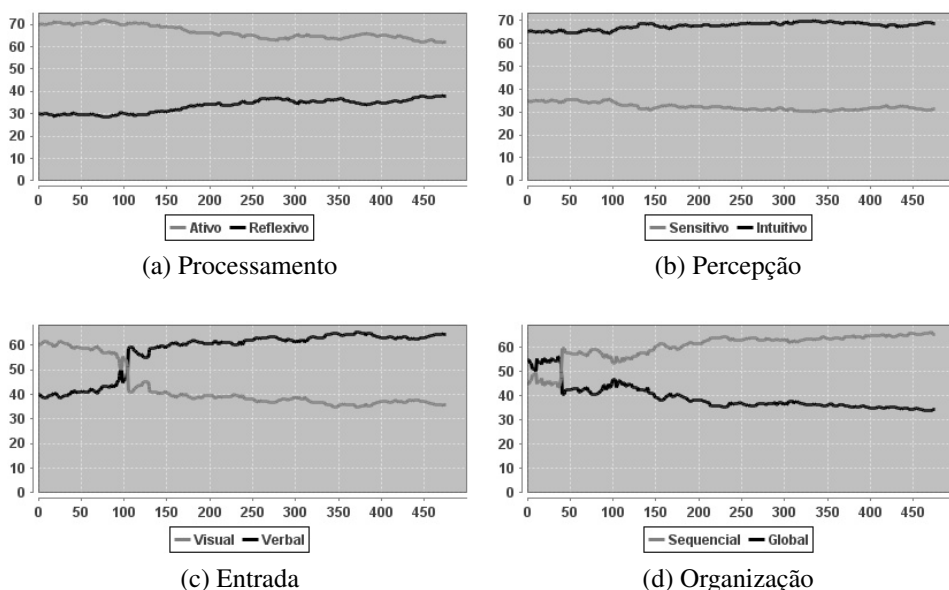


Figura 3: Evolução dos EA's armazenados no ME durante o segundo teste

Tabela 4: Modelo do Estudante (Terceiro Teste)

Estilos de Aprendizagem							
Processamento		Percepção		Entrada		Organização	
Ativo	Reflexivo	Sensitivo	Intuitivo	Visual	Verbal	Sequencial	Global
50,0	50,0	50,0	50,0	50,0	50,0	50,0	50,0
Estado Cognitivo e Objetivos de Aprendizagem							
$EC = \{\langle C1, IND \rangle \dots \langle C30, IND \rangle\}$ $OA = \{\langle C1, 5 \rangle \dots \langle C30, 5 \rangle\}$							

teste observou-se resultado final similarmente satisfatório, resultando em um ME correto em 100% das vezes.

Percebe-se pela Figura 4 que um menor número de iterações foi necessário neste teste em relação ao primeiro, apresentado pela Figura 2. Isto permite concluir que em determinados casos, inconsistências obtidas em um questionário de auto-avaliação podem trazer prejuízos maiores do que a não aplicação do mesmo, principalmente quando preferências fortes



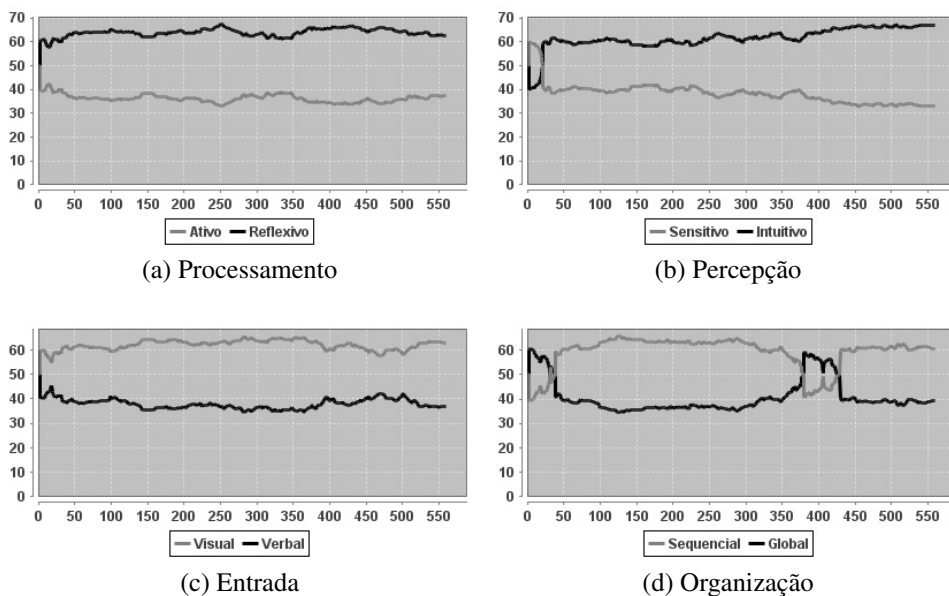


Figura 4: Evolução dos EA's armazenados no ME durante o terceiro teste

são incorretamente armazenadas no ME. Ou seja, em certas situações, a detecção automática dos EA's é preferível à sua correção, principalmente quando estas são preferências fortes. Desta forma, é necessário alto nível de seriedade, comprometimento e veracidade por parte dos estudantes no preenchimento de questionários de auto-avaliação para inferência de EA's. Já o segundo teste, apresentado na Figura 3, apresentou, na maioria das vezes, um número de iterações menor em relação a este, já que apenas preferências moderadas e leves estavam incorretas.

É interessante notar neste teste, através da observação da Figura 4, que as preferências nas dimensões Processamento e Entrada foram inferidas corretamente logo no início do processo. Na dimensão Percepção, a preferência do estudante foi inicialmente inferida incorretamente, mas foi logo corrigida. Na dimensão Organização, a preferência do estudante foi também inferida incorretamente no início, sendo corrigida em seguida. Porém, mais a frente no processo (após iteração 350) a preferência é alterada novamente, e em seguida corrigida e estabilizada. Esta confusão, se deve ao fato desta ser uma preferência leve, e é mais difícil de se detectar uma preferência leve do que uma preferência moderada ou forte. Este fato fica nítido através deste teste.

#### 5.4 Quarto Teste

Apresenta-se a seguir um teste que utiliza o ME final obtido no terceiro teste. O intuito é observar como o sistema se comporta quando todas as preferências no ME são corretas e como elas evoluiriam se fossem reutilizadas em um novo curso. A  $CEA_{real}$  e PP são as mesmas consideradas no experimento anterior. A Tabela 5 apresenta o modelo inicial do estudante utilizado neste experimento.

Tabela 5: Modelo do Estudante (Quarto Teste)

Estilos de Aprendizagem							
Processamento		Percepção		Entrada		Organização	
Ativo	Reflexivo	Sensitivo	Intuitivo	Visual	Verbal	Sequencial	Global
36,8	63,2	32,2	67,8	63,4	36,6	60,7	39,3
Estado Cognitivo e Objetivos de Aprendizagem							
$EC = \{\langle C1, IND \rangle \dots \langle C30, IND \rangle\}$ $OA = \{\langle C1, 5 \rangle \dots \langle C30, 5 \rangle\}$							

A Figura 5 possibilita visualizar a evolução dos EA's armazenados no ME durante uma das repetições deste teste. Analisando-se a Figura 5, observa-se uma redução considerável na quantidade de iterações necessárias ao curso em relação aos três testes anteriores. Neste ponto fica claro que o fato de se ter o ME correto em relação aos EA's do estudante causa um impacto consideravelmente positivo em seu desempenho, conforme verificado por [16] [17] [18] [7] [13] [15] [19] [20] [21] [22] [23] [24] [25] [26]. Esta é, sem dúvida, a maior contribuição deste trabalho: garantir que os EA's armazenados no ME sejam o mais coerente possível com os EA's do estudante, contribuindo, assim, para a maximização de seu desempenho. Em todas as repetições deste experimento observou-se resultado similarmente satisfatório.

É importante observar que preferências fortes ficaram com um peso mais acentuado se comparada àquelas moderadas, que por sua vez ficaram mais acentuadas em relação às leves, ficando clara a eficiência da abordagem proposta no que tange ao nível de precisão e refinamento dos resultados obtidos.

Finalmente, acredita-se que os resultados obtidos nos testes validam a abordagem proposta neste trabalho, estando então apta a ser implementada e utilizada em um LMS existente e com estudantes reais. A próxima seção tece algumas conclusões e aponta alguns trabalhos futuros.

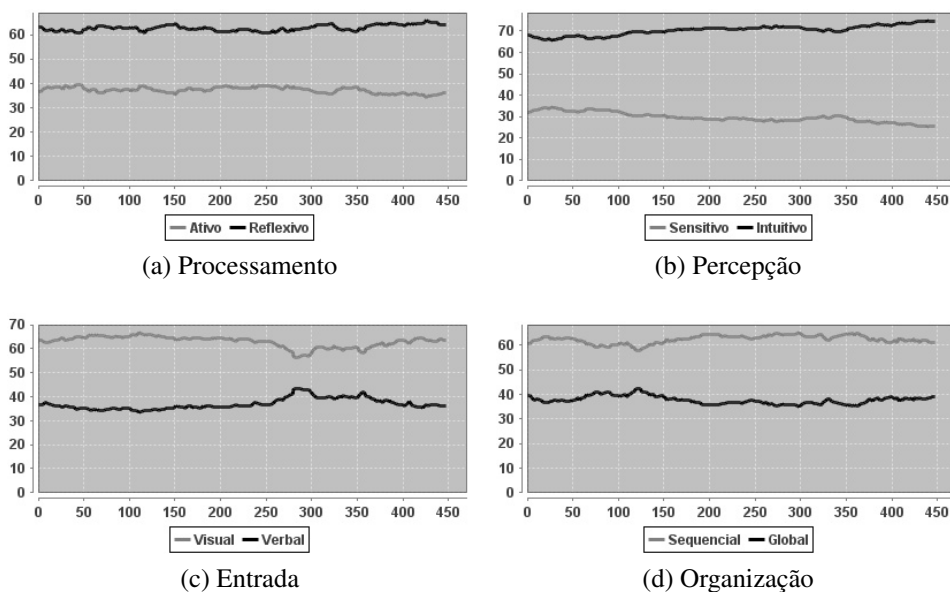


Figura 5: Evolução dos EA's armazenados no ME durante o quarto teste

## 6 Conclusão

Sistemas adaptativos para educação se apresentam como uma abordagem promissora para melhoria da eficiência do processo de ensino-aprendizagem auxiliado por computador. Um fator indispensável nestes sistemas é a identificação precisa, dinâmica e contínua dos estilos de aprendizagem do estudante, de modo a atender da melhor forma as suas necessidades individuais. Neste contexto, um desafio na construção de sistemas capazes de fornecer adaptatividade baseada em estilos de aprendizagem é a construção de modelos eficientes na detecção e correção automática das preferências do estudante.

Levando em consideração este cenário, este trabalho apresenta uma abordagem estocástica apoiada em cadeias de Markov e baseada na combinação de estilos de aprendizagem para detecção e correção automática de preferências do estudante. Neste contexto, tem-se uma coleção de 4 variáveis probabilísticas, representando cada uma das dimensões do FLSM presentes no modelo do estudante, sendo, então, este modelo representado por uma máquina de estados em que as transições são estocásticas. Desta forma o modelo pode ser representado mais adequadamente através de cadeias de Markov variantes no tempo, nas

quais as probabilidades de transição variam à medida que correções são realizadas no ME, alterando o mecanismo de funcionamento da cadeia e conseqüentemente, afetando a formação da CEA.

Como os estilos de aprendizagem sofrem alterações ao longo do tempo, nota-se claramente que este processo é de natureza não-determinística. Provavelmente por esta razão, as cadeias de Markov se mostraram ferramentas tão aderentes à construção deste modelo de apoio ao fornecimento de adaptatividade baseada na combinação de estilos de aprendizagem, como pode-se concluir através da análise dos resultados apresentados na seção 5.

A abordagem proposta se mostrou eficiente e eficaz na detecção e correção automática, dinâmica e contínua dos estilos de aprendizagem do estudante, através de um processo não-determinístico e evolucionário, que atua ao longo de todo o processo de ensino-aprendizagem.

A validação do modelo proposto através de técnicas de simulação computacional foi fundamental, já que a implantação de projetos de *e-learning* requerem quantias consideráveis de recursos financeiros, humanos e de tempo [77]. Desta forma, é de fundamental importância que se possa avaliar a performance de um modelo antes de implantá-lo efetivamente em um LSM, devido à complexidade desta tarefa e da quantidade de recursos exigidos. Esta questão é ainda mais crítica quando se considera que a demanda por sistemas de *e-learning* é cada vez maior, e o número de estudantes que dependem destes sistemas cresce rapidamente [77].

O próximo passo deste trabalho é realizar a integração do modelo apresentado a um LMS existente, o que possibilitaria a realização de testes com estudantes reais. Para isto, o modelo apresentado neste trabalho será inicialmente acoplado ao SIMEduc [78] [79], que foi desenvolvido pelos autores deste trabalho, e que portanto, possuem conhecimento detalhado de sua arquitetura e funcionamento. Outro anseio é pela otimização de uma constante K utilizada no cálculo do  $K_c$  (citado na seção 4) através de um método de inteligência computacional [80] apropriado, tal como algoritmos genéticos [81]. Neste contexto, encontrar o valor ótimo da constante K significa otimizar ainda mais os resultados apresentados neste trabalho, tornando este modelo ainda mais eficiente.

## Referências

- [1] Moodle, <http://www.moodle.org/>, 2010.
- [2] WebCT, <http://www.webct.com/>, 2010.
- [3] J. Amorim, V. Armentano, M. Miskulin, and R. Miskulin, "Uso do teleduc como um recurso complementar no ensino presencial," *Revista Brasileira de Aprendizagem Aberta e Distância*, vol. 4, no. 1, pp. 1–10, 2005.

- [4] P. Brusilovsky, J. Eklund, and E. Schwarz, “Web-based education for all: A tool for developing adaptive courseware,” in *Seventh International WWW Conference*, pp. 291–300, Elsevier Science B.V., apr 1998.
- [5] M. R. Zakaria and T. J. Brailsford, “User Modelling and Adaptive Educational Hypermedia Frameworks for Education,” *New Review of Hypermedia and Multimedia*, vol. 1, no. 8, pp. 83–97, 2002.
- [6] H. Wu, E. De Kort, and P. De Bra, “Design issues for general-purpose adaptive hypermedia systems,” in *Proceedings of the 12th ACM Conference on Hypertext and Hypermedia*, pp. 141–150, ACM, 2001.
- [7] S. Graf and Kinshuk, “Advanced Adaptivity in Learning Management Systems by Considering Learning Styles,” in *Proceedings of the 2009 IEEE/WIC/ACM International Joint Conference on Web Intelligence and Intelligent Agent Technology-Volume 03*, pp. 235–238, IEEE Computer Society, 2009.
- [8] R. Clifford, “Adaptive hypermedia for music instruction,” *7th International Technological Directions in Music Learning Conference, TDML ejournal*, aug 2004.
- [9] P. De Bra and L. Calvi, “AHA! An open adaptive hypermedia architecture,” *New Review of Hypermedia and Multimedia*, vol. 4, no. 1, pp. 115–139, 1998.
- [10] P. Brusilovsky, E. Schwarz, and G. Weber, “A tool for developing adaptive electronic textbooks on WWW,” in *Proceedings of WebNet*, vol. 96, pp. 64–69, 1996.
- [11] K. Hook, A. Rudstrom, and A. Waern, “Edited adaptive hypermedia: Combining human and machine intelligence to achieve filtered information,” in *8th ACM International Hypertext Conference (Hypertext’97), Flexible Hypertext Workshop*, ACM, 1997.
- [12] S. Chen and R. Macredie, “Cognitive styles and hypermedia navigation: Development of a learning model,” *Journal of the American Society for Information Science and Technology*, vol. 53, pp. 3–15, jan 2002.
- [13] S. Graf and T. Liu, “Identifying Learning Styles in Learning Management Systems by Using Indications from Students’ Behaviour,” in *Advanced Learning Technologies, 2008. ICALT’08. Eighth IEEE International Conference on*, pp. 482–486, IEEE, 2008.
- [14] Blackboard, <http://www.blackboard.com/>, 2010.
- [15] F. Coffield, D. Moseley, E. Hall, and K. Ecclestone, *Learning styles and pedagogy in post-16 learning: A systematic and critical review*. National Centre for Vocational Education Research (NCVER), 2009.

- [16] M. Haider, A. Sinha, and B. Chaudhary, “An Investigation of relationship between learning styles and performance of learners,” *International Journal of Engineering Science and Technology*, vol. 2, no. 7, pp. 2813–2819, 2010.
- [17] L. T.-C. K. Graf, S., “Interactions Between Student’s Learning Styles, Achievement and Behaviour in Mismatched Courses,” in *Proceedings of the International Conference on Cognition and Exploratory Learning in Digital Age (CELDA 2008)*, pp. 223–230, IADIS International Conference, 2008.
- [18] Kinshuk, T. Liu, and S. Graf, “Coping with Mismatched Courses: Students’ behaviour and performance in courses mismatched to their learning styles,” *Educational Technology Research and Development*, vol. 57, no. 6, pp. 739–752, 2009.
- [19] E. Alfonseca, R. Carro, E. Martín, A. Ortigosa, and P. Paredes, “The impact of learning styles on student grouping for collaborative learning: a case study,” *User Modeling and User-Adapted Interaction*, vol. 16, no. 3, pp. 377–401, 2006.
- [20] S. Graf and T. Lin, “Analysing the Relationship between Learning Styles and Cognitive Traits,” in *Advanced Learning Technologies, 2007. ICALT 2007. Seventh IEEE International Conference on*, pp. 235–239, IEEE, 2007.
- [21] S. Graf and K. Kinshuk, “Providing Adaptive Courses in Learning Management Systems with Respect to Learning Styles,” in *Proceedings of World Conference on E-Learning in Corporate, Government, Healthcare, and Higher Education 2007*, pp. 2576–2583, 2007.
- [22] N. Bajraktarevic, W. Hall, and P. Fullick, “Incorporating learning styles in hypermedia environment: Empirical evaluation,” in *Proceedings of the workshop on adaptive hypermedia and adaptive web-based systems*, pp. 41–52, 2003.
- [23] E. Sangineto, N. Capuano, M. Gaeta, and A. Micarelli, “Adaptive course generation through learning styles representation,” *Universal Access in the Information Society*, vol. 7, no. 1, pp. 1–23, 2008.
- [24] R. E. Terry, J. N. Harb, P. Hurt, and K. Williamson, *Teaching through the cycle: application of learning style theory to engineering education at Brigham Young University*. Brigham Young University Press, 1995.
- [25] C. Friedel and R. Rudd, “Creative thinking and learning styles in undergraduate agriculture students,” *Journal of Agricultural Education*, vol. 47, no. 4, p. 102, 2006.
- [26] E. Vasilyeva, M. Pechenizkiy, and S. Puuronen, “The Challenge of Feedback Personalization to Learning Styles in a Web-Based Learning System,” in *Advanced Learning Technologies, 2006. Sixth International Conference on*, pp. 1143–1144, IEEE, 2006.

- [27] A. Cristea and N. Stash, “AWELS: adaptive Web-based education and learning styles,” 2006.
- [28] D. Pollard, *Convergence of stochastic processes*. Springer, 1984.
- [29] A. L. Franzoni and S. Assar, “Student learning styles adaptation method based on teaching strategies and electronic media,” *Educational Technology & Society*, vol. 12, no. 4, pp. 15–29, 2009.
- [30] O. Model, M. El-Khouly, and S. El-Seoud, “On line student model,” *International Journal of Computing & Information Sciences*, vol. 4, no. 1, 2006.
- [31] A. Biermann and D. Ramm, *Great ideas in computer science with Java*. The MIT Press, 2001.
- [32] P. De Bra, D. Smits, and N. Stash, “Creating and delivering adaptive courses with AHA!,” *Innovative Approaches for Learning and Knowledge Sharing*, pp. 21–33, 2006.
- [33] N. Manouselis and D. Sampson, “Dynamic knowledge route selection for personalized learning environments using multiple criteria analysis,” in *Proceedings of the 20th IASTED International Multi-Conference on Applied Informatics*, ACTA Press, 2002.
- [34] P. Paredes and P. Rodriguez, “A mixed approach to modelling learning styles in adaptive educational hypermedia,” *Advanced Technology for Learning*, vol. 1, no. 4, pp. 210–215, 2004.
- [35] J. Gilbert and C. Han, “Adapting instruction in search of [ ] a significant difference’\* 1,” *Journal of Network and Computer applications*, vol. 22, no. 3, pp. 149–160, 1999.
- [36] C. Carver Jr, R. Howard, and W. Lane, “Enhancing student learning through hypermedia courseware and incorporation of student learning styles,” *Education, IEEE Transactions on*, vol. 42, no. 1, pp. 33–38, 2002.
- [37] C. Peña, J. Marzo, J. de la Rosa, and R. Fabregat, “Un sistema de tutoría inteligente adaptativo considerando estilos de aprendizaje,” *Universitat de Girona, España*, 2002.
- [38] M. Grigoriadou, K. Papanikolaou, H. Kornilakis, and G. Magoulas, “INSPIRE: an intelligent system for personalized instruction in a remote environment,” in *Proceedings of Third workshop on Adaptive Hypertext and Hypermedia, July*, vol. 14, pp. 13–24, Citeseer, 2001.
- [39] C. Limongelli, F. Sciarone, M. Temperini, and G. Vaste, “Adaptive learning with the LS-plan system: a field evaluation,” *IEEE Transactions on Learning Technologies*, pp. 203–215, 2009.

- [40] M. Stern and B. Woolf, "Adaptive content in an online lecture system," in *Adaptive hypermedia and adaptive Web-based systems*, pp. 227–238, Springer, 2000.
- [41] B. Soloman and R. Felder, "Index of learning styles questionnaire," *Retrieved May*, vol. 11, 2006.
- [42] S. Graf and K. Kinshuk, "Using Cognitive Traits for Improving the Detection of Learning Styles," in *Database and Expert Systems Applications (DEXA), 2010 Workshop on*, pp. 74–78, IEEE, 2010.
- [43] G. Castillo, J. Gama, and A. Breda, "An Adaptive Predictive Model for Student Modeling," *Advances in Web-based education: Personalized learning environments*, pp. 70–92, 2005.
- [44] D. Kelly and B. Tangney, "'First Aid for You': getting to know your learning style using machine learning," in *Advanced Learning Technologies, 2005. ICALT 2005. Fifth IEEE International Conference on*, pp. 1–3, IEEE, 2005.
- [45] P. García, A. Amandi, S. Schiaffino, and M. Campo, "Evaluating Bayesian networks' precision for detecting students' learning styles," *Computers & Education*, vol. 49, no. 3, pp. 794–808, 2007.
- [46] C. Carmona, G. Castillo, *et al.*, "Designing a Dynamic Bayesian Network for Modeling Students Learning Styles," in *Eighth IEEE International Conference on Advanced Learning Technologies*, pp. 346–350, IEEE, 2008.
- [47] R. Cabada, M. Estrada, and C. Garcia, "A Fuzzy-Neural Network for Classifying Learning Styles in a Web 2.0 and Mobile Learning Environment," in *Web Congress, 2009. LE-WEB'09. Latin American*, pp. 177–182, IEEE, 2009.
- [48] R. Zatarain-Cabada, M. Barrón-Estrada, L. Zepeda-Sánchez, G. Sandoval, J. Osorio-Velazquez, and J. Urias-Barrientos, "A Kohonen Network for Modeling Students' Learning Styles in Web 2.0 Collaborative Learning Systems," *MICAI 2009: Advances in Artificial Intelligence*, pp. 512–520, 2009.
- [49] R. Zatarain, L. Barrón-Estrada, C. Reyes-García, and O. Reyes-Galaviz, "Applying Intelligent Systems for Modeling Students' Learning Styles Used for Mobile and Web-Based Systems," *Soft Computing for Intelligent Control and Mobile Robotics*, pp. 3–22, 2010.
- [50] S. Botsios, D. Georgiou, and N. Safouris, "Contributions to adaptive educational hypermedia systems via on-line learning style estimation," *Educational Technology & Society*, vol. 12, no. 4, pp. 322–339, 2008.



- [51] C. Jones, C. Reichard, and K. Mokhtari, “Are Students Learning Styles Discipline Specific?,” *Community College Journal of Research and Practice*, vol. 27, no. 5, pp. 363–375, 2003.
- [52] S. Messick, “Personal styles and educational options,” *Individuality in learning*, pp. 327–368, 1976.
- [53] R. Marzano and J. Kendall, *The new taxonomy of educational objectives*. Corwin Pr, 2007.
- [54] B. Bloom and D. Krathwohl, “Taxonomy of educational objectives: The classification of educational goals. Handbook I: Cognitive domain,” pp. 64–81, 1956.
- [55] C. Starr, B. Manaris, and R. Stalvey, “Bloom’s taxonomy revisited: specifying assessable learning objectives in computer science,” *ACM SIGCSE Bulletin*, vol. 40, no. 1, pp. 261–265, 2008.
- [56] D. Krathwohl, “A revision of Bloom’s taxonomy: An overview,” *Theory into practice*, vol. 41, no. 4, pp. 212–218, 2002.
- [57] W. Chang and M. Chung, “Automatic applying Bloom’s taxonomy to classify and analysis the cognition level of English question items,” in *Pervasive Computing (JCPC), 2009 Joint Conferences on*, pp. 727–734, IEEE, 2010.
- [58] T. Highley and A. Edlin, “Discrete Mathematics assessment using learning objectives based on Bloom’s taxonomy,” in *Frontiers in Education Conference, 2009. FIE’09. 39th IEEE*, pp. 1–6, IEEE, 2009.
- [59] IEEE, *LOM (Learning Object Metadata)*. IEEE Learning Technology Standards Committee, <http://ltsc.ieee.org/wg12/index.html>, 2010.
- [60] D. Kolb *et al.*, *Experiential learning: Experience as the source of learning and development*. Prentice-Hall Englewood Cliffs, NJ, 1984.
- [61] P. Honey and A. Mumford, “The manual of learning styles,” 1992.
- [62] N. Entwistle, *Styles of learning and teaching*. Wiley Chichester, 1981.
- [63] G. Pask, “Styles and strategies of learning,” *British journal of educational psychology*, 1976.
- [64] R. Felder and L. Silverman, “Learning and teaching styles in engineering education,” *Engineering education*, vol. 78, no. 7, pp. 674–681, 1988.

- [65] J. Kuljis and F. Liu, “A comparison of learning style theories on the suitability for elearning,” in *Proceedings of the IASTED conference on web technologies, applications, and services*, pp. 191–197, 2005.
- [66] C. Carver, R. Howard, and W. Lane, “Addressing different learning styles through course hypermedia,” *IEEE Transactions on Education*, vol. 42, no. 1, pp. 33–38, 1999.
- [67] S. Graf and C. Kinshuk, “A Flexible Mechanism for Providing Adaptivity Based on Learning Styles in Learning Management Systems,” in *2010 10th IEEE International Conference on Advanced Learning Technologies*, pp. 30–34, IEEE, 2010.
- [68] I. Briggs-Myers, “The Myers-Briggs Type Indicator,” *Princeton, NJ, Educational Testing Service*, 1957.
- [69] A. Papoulis, S. Pillai, and S. Unnikrishna, *Probability, random variables, and stochastic processes*, vol. 73660116. McGraw-Hill New York, 2002.
- [70] A. C. Martins, L. Faria, C. Vaz de Carvalho, and E. Carrapatoso, “User Modeling in Adaptive Hypermedia Educational Systems,” *Educational Technology & Society*, vol. 11, no. 1, pp. 194–207, 2008.
- [71] P. Brusilovsky and E. Millan, “User models for adaptive hypermedia and adaptive educational systems,” *The adaptive web*, pp. 3–53, 2007.
- [72] L. Kaelbling, M. Littman, and A. Moore, “Reinforcement learning: A survey,” *Arxiv preprint cs/9605103*, 1996.
- [73] S. Kirkpatrick, C. Gelatt, and M. Vecchi, “Optimization by simulated annealing,” *science*, vol. 220, no. 4598, p. 671, 1983.
- [74] R. S. Lopes, F. A. Dorça, M. A. Fernandes, and C. R. Lopes, “Um sistema de avaliação em EAD baseado em lógica Fuzzy,” in *Simpósio Brasileiro de Informática na Educação*, pp. 30–34, SBC, 2008.
- [75] F. A. Dorça, C. R. Lopes, M. A. Fernandes, and R. S. Lopes, “Adaptativity Supported by Neural Networks in Web-based Educational Systems,” *Journal of Education, Informatics and Cybernetics*, vol. 1, 2009.
- [76] R. Felder and J. Spurlin, “Applications, reliability and validity of the index of learning styles,” *International Journal of Engineering Education*, vol. 21, no. 1, pp. 103–112, 2005.
- [77] S. Graf, C. Lan, T. Liu, *et al.*, “Investigations about the Effects and Effectiveness of Adaptivity for Students with Different Learning Styles,” in *2009 Ninth IEEE International Conference on Advanced Learning Technologies*, pp. 415–419, IEEE, 2009.

- [78] F. A. Dorça, B. Q. Pinto, C. R. Lopes, and M. A. Fernandes, “Um Sistema Inteligente Multiagente Para Educação à Distância,” in *XXII Congresso da Sociedade Brasileira de Computação*, Sociedade Brasileira de Computação, 2002.
- [79] F. A. Dorça, B. Q. Pinto, M. A. Fernandes, and C. R. Lopes, “A Multiagent Architecture for Distance Education Systems,” in *3rd IEEE International Conference on Advanced Learning Technologies, ICALT03.*, IEEE Computer Society, 2003.
- [80] A. Konar, *Computational intelligence [ie intelligence]: principles, techniques, and applications*. Springer Verlag, 2005.
- [81] D. Goldberg, *Genetic algorithms in search, optimization, and machine learning*. Addison-wesley, 1989.