



UMA ABORDAGEM COMPUTACIONAL PARA DETECÇÃO DE ESTILOS DE APRENDIZAGEM UTILIZANDO MODELOS OCULTOS DE MARKOV

COMPUTATIONAL APPROACH TO DETECT LEARNING STYLES USING HIDDEN MARKOV MODEL

- **Edson Batista de Sena** (UFVJM – eds.bsena@gmail.com)
- **Alessandro Vivas** (UFVJM – prof.alessandrovivas@gmail.com)
Luciana Assis (UFVJM – lupassis@gmail.com)
- **Cristiano Pitangui** (UFVJM – pitangui.cristiano@gmail.com)

Resumo:

Um dos grandes desafios dos dias atuais no desenvolvimento de tecnologias computacionais aplicadas ao processo educacional, é produzir soluções que sejam capazes de atender corretamente aos métodos de ensino e aprendizagem. Para que isso ocorra, é fundamental que os ambientes virtuais forneçam conteúdo adequado, objetos de aprendizagem atraentes, além de serem dinâmicos e altamente adaptáveis às necessidades dos estudantes, visando a melhoria contínua do processo educacional para professores, tutores e estudantes. Este trabalho apresenta uma abordagem computacional probabilística, que visa a detecção automática do estilo de aprendizagem, utilizando uma combinação do modelo proposto por Felder e Silverman para estilos de aprendizagem, o Felder and Silverman Learning Styles Model (FSLSM), com as técnicas de inferência probabilística dos modelos ocultos de Markov (HMM). Para a validação da abordagem, foram realizados experimentos em um simulador computacional capaz de reproduzir parcialmente o processo de interação do estudante com o ambiente virtual de aprendizagem, para a inferência do estilo de aprendizagem probabilístico foi utilizado o algoritmo de Viterbi. Ao final, os resultados dos experimentos são apresentados e demonstraram um elevado grau de precisão no processo de inferência do estilo de aprendizagem probabilístico.

Palavras-chave: Estilos de Aprendizagem. FSLSM. HMM. Ambientes Virtuais de Aprendizagem. Educação.

Abstract:

One of the great challenges of the present day in the development of computer technologies in educational process is to produce solutions that are able to respond properly to the teaching and learning methods. For this to occur, it is essential that virtual environments provide appropriate content, appealing learning objects, and are dynamic and highly adaptable to the needs of students, aimed at continuous improvement of the educational process for teachers, tutors and students. This paper presents a probabilistic computational approach, which aims at automatic detection of learning style, using a combination of the proposed by Felder and Silverman model for learning styles, the Felder and Silverman Learning Styles Model (FSLSM), with probabilistic inference techniques the





hidden Markov model (HMM). To validate the approach, experiments were performed on a computer simulator able to reproduce partially student interaction process with the virtual learning environment for the inference of probabilistic learning style was used the Viterbi algorithm. At the end, the results of the experiments are presented and demonstrated a high degree precision in the process of inference of probabilistic learning style.

Keywords: Learning Styles. FSLSM. HMM. Virtual Learning Environments. Education.

1. Introdução

Com os constantes avanços tecnológicos aplicados ao processo de ensino e aprendizagem, cresce também a demanda por plataformas de apoio às atividades acadêmicas que sejam dinâmicas, que se adequem às necessidades e particularidades individuais de cada estudante (SILVA, 2006).

Uma das principais dificuldades no desenvolvimento destas tecnologias, segundo Lopes (2009), é criar regras computacionais eficientes, que sejam capazes de inferir os estilos de aprendizagem a partir das ações individuais de cada estudante, durante a sua interação com o Ambiente Virtual de Aprendizagem (AVA).

Sendo assim, faz-se necessário que os produtos de softwares desenvolvidos, sejam atrativos e adaptáveis aos estilos de aprendizagem dos estudantes, para que eles consigam aproveitar ao máximo o ambiente e o conteúdo que lhe são apresentados.

O trabalho propõe uma abordagem computacional que utiliza a combinação do FSLSM em um modelo oculto de Markov (HMM), para a detecção automática de estilos de aprendizagem, levando em consideração as habilidades e tendências individuais de cada estudante durante as seções de aprendizagem.

Nas definições de Rabiner (1989), um HMM consiste em um processo duplamente estocástico, onde um processo oculto e não observável recebe símbolos sequenciais de um outro processo que observa e monitora o comportamento do ambiente ao qual foi inserido.

Um dos principais problemas descritos na literatura relacionada, consiste em desenvolver plataformas de ensino e apoio às atividades acadêmicas, que sejam dinâmicas, autônomas e eficientes, que sejam capazes de adequar às necessidades e particularidades individuais de cada estudante, além de criar regras de inferência dos estilos de aprendizagem a partir das ações individuais de cada estudante durante a sua interação com o AVA.

O objetivo principal deste trabalho é apresentar uma abordagem computacional, que seja capaz de identificar as características individuais e cognitivas de aprendizagem do estudante, e realizar a inferência do estilo de aprendizagem probabilístico, utilizando modelos ocultos de Markov combinados com a estrutura dos estilos de aprendizagem proposta no FSLSM.





2. Fundamentação teórica

Nas definições de Felder et al (2005) os estilos de aprendizagem são processos cognitivos e psicológicos que influenciam a forma que os estudantes percebem, interagem e correspondem aos ambientes de aprendizagem. Já nas considerações de Honey et al (1992), os mesmos são descritos como métodos e modelos que definem a forma de assimilar e compreender os objetos de aprendizagem escolhidos pelo estudante durante o processo de ensino.

Com base em outros modelos e estudos, Felder e Silverman (1988), desenvolveram um modelo estruturado, que foi inicialmente direcionado aos estudantes de engenharia, composto por quatro dimensões: percepção, que se subdivide em sensitivo e indutivo; entrada, que pode ser visual e verbal; processamento, onde o estudante pode ser ativo ou reflexivo; e a dimensão organização, que classifica o aluno como sequencial ou global, este modelo ficou definido com Felder-Silverman Learning Style Model (FSLSM).

Por ser um modelo de estilos de aprendizagem mais aplicado em pesquisas relacionadas ao campo das ciências exatas, o FSLSM destaca-se por sua aplicação frequente nos modelos computacionais para detecção automática de estilos de aprendizagem, porém existem outros que também são frequentemente utilizados em pesquisas da área, é o caso das estruturas propostas por Kolb (1984), Honey e Mumford (1992) e Myers (1985).

Apesar do grande número de pesquisas relacionadas ao processo de detecção automática de estilos de aprendizagem realizadas nos últimos anos, de acordo com Al-Azawel e Badii (2014), a integração do processo aos atuais ambientes virtuais de aprendizagem, ocorre de maneira incipiente e prematura, necessitando de pesquisas mais aprofundadas sobre o tema, explorando as técnicas probabilísticas em combinação com estudos das áreas da psicologia e cognitiva.

Mesmo com as limitações apresentadas, Amandi et al (2014), descrevem grandes benefícios que podem ser alcançados com a automatização do processo de detecção dos estilos de aprendizagem e a sua incorporação aos ambientes de aprendizagem, dentre elas destaca-se a possibilidade da dedicação exclusiva do estudante ao processo de aprendizagem, uma vez que não terá que se preocupar em responder questionários ou entrevistas, e usufruindo de um ambiente virtual que se adapta às suas preferências automaticamente.

Dentre as diversas técnicas utilizadas para o propósito, o uso de modelos ocultos de Markov (HMM - Hidden Markov Models), vem ganhando espaço nas recentes pesquisas. Esta técnica de aprendizado de máquina, que utiliza em sua estrutura modelos probabilísticos no processo de inferência, é frequentemente utilizada em pesquisas relacionadas à biotecnologia, reconhecimento de voz, previsões meteorológicas, entre outras aplicações.

Rabiner (1989), define um modelo oculto de Markov como uma variação do formalismo clássico das cadeias de Markov, duplamente estocástico que apresenta as





tradicionais distribuições de probabilidades, juntamente com uma distribuição baseada na “observação e comportamento” do ambiente em que foi inserido.

Uma proposta para utilizar HMM no processo de detecção automática de estilos de aprendizagem em ambientes virtuais de aprendizagem é descrita em Nguyen (2014), na qual foi utilizado uma combinação dos modelos de Felder e Siverman (1988) e Honey e Munford (1992), onde o HMM foi construído levando em consideração as dimensões e características específicas de cada modelo para definir os estados ocultos e os observáveis. Ao final foi utilizado o algoritmo de Viterbi para realizar a inferência do estilo de aprendizagem probabilístico. A proposta concluiu que o modelo é consideravelmente viável para ser implementado no processo de detecção automática de estilos de aprendizagem.

3. Procedimentos metodológicos

A presente pesquisa foi realizada sob a modalidade de simulação computacional, na qual realizou-se a modelagem probabilística dos estilos de aprendizagem, utilizando uma estrutura que combina um modelo oculto de Markov (HMM) com as dimensões, características e particularidades do FSLSM.

No contexto da organização proposta pelos autores do FSLSM, buscou-se construir uma estrutura computacional capaz de explorar as características fundamentais do mesmo, que, em uma análise mais criteriosa, mostra-se capaz descrever e caracterizar as preferências cognitivas do estudante. Sendo representado pelos modelos ocultos de Markov, onde os estados ocultos representam as dimensões do modelo e os estados observáveis representam as características específicas de cada dimensão.

O objetivo da modelagem é gerar os parâmetros (distribuições de probabilidades) das matrizes de transição e emissão de estados. Onde os valores iniciais são obtidos a partir da suposta interação do estudante com o AVA.

A Figura 1, representa a estruturação das dimensões do FSLSM em quatro HMMs, demonstrando os estados observáveis e os estados ocultos do modelo, que apresentam-se capazes de gerar as matrizes de transição de estados e emissão de sinais observáveis para o modelo.



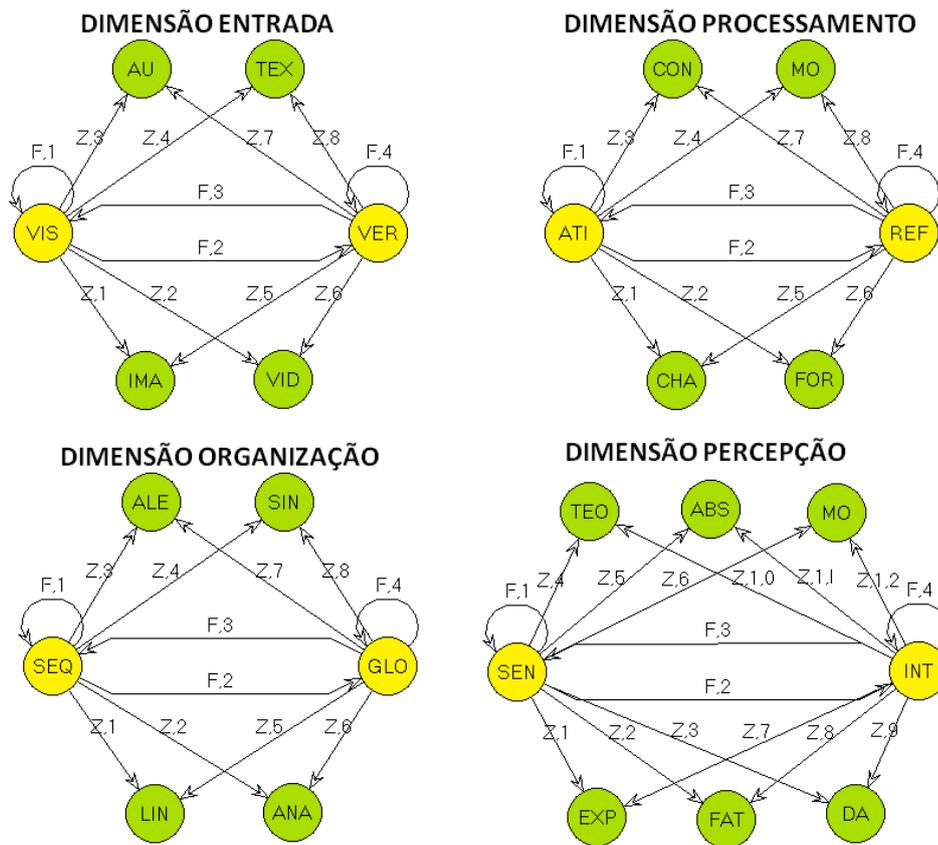


Figura 1. Modelo oculto de Markov, representando as quatro dimensões do FLSM.
Fonte: Autoria Própria

Na dimensão entrada, observa-se que os estudantes são classificados em visual e verbal, os visuais tem aptidão por objetos de aprendizagem que sejam diagramas, filmes, imagens e demonstrações. Já os verbais, são atraídos por objetos de aprendizagem que sejam textos, áudios e manuscritos.

Para a dimensão processamento, onde os estudantes são classificados em ativos ou reflexivos, observa-se que os estudantes com tendências para ativo, tem preferência por experiências de aprendizagem em grupo, de forma coletiva, participando de chats, fóruns e pontos de encontro virtuais. Já os com tendências para reflexivo, optam por atividades individuais, preferindo a interação com o conteúdo formal e a criação de modelos.

A dimensão organização, tem como objetivo observar a forma com que o estudante interage com o ambiente virtual, e pode classificá-los em sequenciais ou globais, percebe-se que os estudantes com tendências para progredirem no ambiente de forma sequencial, tem preferência por avançar linearmente no conteúdo, além de optarem geralmente por conteúdos mais analíticos. Já os com tendências à interação global, optam por acessarem o ambiente aleatoriamente, e preferindo conteúdo sintético, bem resumido.



Na dimensão percepção, o objetivo é observar as preferências do estudante quanto ao tipo do objeto de aprendizagem, e são classificados em sensitivos ou intuitivos, os estudantes com tendências a serem sensitivos, preferem objetos relacionados às experiências reais, fatos ou dados. Já os com tendências à serem intuitivos, optam por objetos teóricos, modelos e abstrações.

O processo de inferência probabilística foi realizado pelo algoritmo de Viterbi, que nas definições de Forney (1973) se trata de um modelo computacional recursivo e dinâmico capaz de solucionar em sua maioria, os problemas de estimativa de transição e sequência de estados em modelos ocultos de Markov de tempo discreto. Tendo como principal objetivo, encontrar a sequência de estados ocultos que melhor representa o HMM que foi gerado.

Para a validação, a abordagem proposta foi estruturada em um simulador capaz de reproduzir o comportamento não determinístico do estudante perante as seções de aprendizagem a fim de alimentar as matrizes de emissão e transição e posteriormente realizar a inferência do estilo de aprendizagem probabilístico, utilizando o algoritmo de Viterbi.

4. Análise e apresentação dos resultados

Avaliando de forma conjunta os resultados obtidos na simulação, percebe-se que os mesmos são consideravelmente satisfatórios, obtendo uma alta taxa de acerto durante a inferência do estilo de aprendizagem probabilístico ao longo do processo de simulação. Como pode-se observar na Tabela 1 e na Figura 2 abaixo:

Tabela 1. Mapa de apuração experimentos.

| DIMENSÃO PERCEPÇÃO | | | | | | | | | | | | |
|------------------------|-----|-----|------|-----|-------|-------|---------|-------|-------|-------|-------|------|
| SEM | EXP | FAT | DAD | TEO | ABS | MOD | SEN-R | INT-R | EA-R | SEN-P | INT-P | EA-P |
| 1483097 | 0% | 17% | 34% | 41% | 5% | 3% | 51% | 49% | SEN | 44% | 56% | INT |
| 2395547 | 24% | 33% | 32% | 11% | 1% | 0% | 89% | 12% | SEN | 97% | 3% | SEN |
| 5727653 | 21% | 34% | 32% | 12% | 1% | 0% | 87% | 13% | SEN | 95% | 5% | SEN |
| 4796188 | 20% | 45% | 26% | 8% | 1% | 0% | 91% | 9% | SEN | 96% | 4% | SEN |
| 9130638 | 0% | 0% | 3% | 14% | 45% | 38% | 3% | 97% | INT | 0% | 100% | INT |
| DIMENSÃO PROCESSAMENTO | | | | | | | | | | | | |
| SEM | CHA | FOR | CON. | MOD | ATI-R | REF-R | EA-R | ATI-P | REF-P | EA-P | | |
| 704618 | 18% | 32% | 41% | 9% | 50% | 50% | ATI-REF | 47% | 53% | REF | | |
| 791402 | 1% | 14% | 42% | 42% | 15% | 84% | REF | 10% | 90% | REF | | |
| 553936 | 36% | 41% | 20% | 4% | 77% | 24% | ATI | 87% | 13% | ATI | | |
| 775544 | 42% | 41% | 16% | 1% | 83% | 17% | ATI | 88% | 12% | ATI | | |
| 628812 | 42% | 43% | 14% | 0% | 85% | 14% | ATI | 91% | 9% | ATI | | |

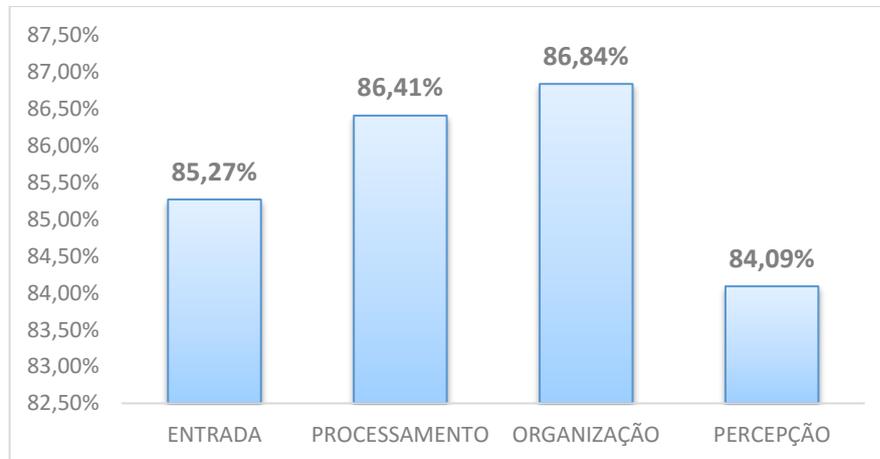


| DIMENSÃO ORGANIZAÇÃO | | | | | | | | | | |
|----------------------|------|------|------|-------|-------|-------|------|-------|-------|---------|
| SEM | LIN. | ANA. | ALE. | SINT. | SEQ-R | GLO-R | EA-R | SEQ-P | GLO-P | EA-P |
| 7274227 | 18% | 34% | 32% | 16% | 52% | 48% | SEQ | 88% | 12% | SEQ |
| 7697947 | 14% | 50% | 29% | 7% | 64% | 36% | SEQ | 86% | 14% | SEQ |
| 5049851 | 7% | 32% | 38% | 24% | 39% | 62% | GLO | 18% | 82% | GLO |
| 3976229 | 12% | 37% | 45% | 7% | 49% | 52% | GLO | 50% | 50% | SEQ-GLO |
| 7450413 | 12% | 30% | 41% | 17% | 42% | 58% | GLO | 10% | 90% | GLO |

| DIMENSÃO ENTRADA | | | | | | | | | | |
|------------------|-----|-----|-----|-----|-------|-------|------|-------|-------|------|
| SEM | IMG | VID | TEX | AUD | VIS-R | VER-R | EA-R | VIS-P | VER-P | EA-P |
| 906148 | 17% | 47% | 30% | 5% | 64% | 35% | VIS | 91% | 9% | VIS |
| 916514 | 25% | 37% | 32% | 7% | 62% | 39% | VIS | 92% | 8% | VIS |
| 405842 | 8% | 41% | 45% | 7% | 49% | 52% | VER | 54% | 46% | VIS |
| 329813 | 8% | 34% | 41% | 17% | 42% | 58% | VER | 12% | 88% | VER |
| 496079 | 21% | 47% | 24% | 8% | 68% | 32% | VIS | 86% | 14% | VIS |

Fonte: Autoria Própria

Figura 2. Gráfico apresentando a média de acertos de inferência do estilo de aprendizagem probabilístico.



Fonte: Autoria Própria

Ao final dos experimentos, importantes resultados foram obtidos, para tal, considerou-se como parâmetro de avaliação os estilos de aprendizados reais (que foram obtidos da simulação do processo de interação do estudante com o AVA) e os estilos de aprendizagem probabilísticos (obtidos através do processo de inferência, utilizando as matrizes de distribuição de probabilidades e o algoritmo de Viterbi) obtendo-se uma média de acertos superior à 80%, como pode ser observado nas seções posteriores.



5. Considerações finais

Em consonância com alguns trabalhos relacionados, conforme disponível em Al-Azawei et al (2013), que apontam o FLSM como um dos modelos mais adequados para o processo, conseguiu-se explorar ao longo deste, sob diversas óticas, as características estruturais do modelo proposto por Felder e Silverman (1988), de forma que foi possível perceber que as quatro dimensões definidas por ele, apresentam-se amplamente capazes de identificar o comportamento do estudante ao longo das seções de aprendizagem.

Outro ponto importante a ser destacado, consiste no uso de modelos ocultos de Markov em processos de inferência probabilística, que demonstrou ser eficiente quando a estrutura do modelo consegue absorver de forma clara e consistente os requisitos, especificações e características do objeto a ser modelado.

Os trabalhos futuros caminham em algumas direções: a adaptação da abordagem para sistemas hipermídia adaptativos para a educação, a implementação de métodos avaliativos e de correção automática dos estilos de aprendizagem, além da validação do modelo em experimentos com alunos reais em ambientes virtuais de aprendizagem.

6. Referências bibliográficas

AL-AZAWEI, Almed; BADII, Atta. State Of The Art Of Learning Styles-Based Adaptive Educational Hypermedia Systems (LS-BAEHSS). International Journal of Computer Science & Information Technology (IJCSIT) Vol 6, No 3, June 2014. Disponível em: <http://airccse.org/journal/jcsit/6314ijcsit01.pdf> Acesso em: 22/02/2015

AMANDI, Analía, FELDMAN, Juan, MONTESERIN, Ariel. Automatic detection of learning styles: state of the art. Artificial Intelligence Review. 2014. Disponível em: https://www.researchgate.net/publication/272040719_Automatic_detection_of_learning_styles_state_of_the_art.pdf Acesso em: 22/02/2016

FELDER, Richard M.; BRENT, Rebecca. Understanding student differences. Journal of Engineering Education, 2005.

FELDER, Richard M.; SILVERMAN, Linda.; University, N.C.S. Learning and Teaching Styles In Engineering Education. North Carolina State University, 1988.

HONEY, Peter; MUMFORD, Alan. The Manual of Learning styles. Peter Honey Publications; 3rd Edition, 1992.

KOLB, David, BOYATZIS, Richard E., MAINEMELIS, Charalampos. Experimental Learning: Experience as the source of learning and development. Prentice-Hall Englewood, NJ, 1984.





SIED
SIMPÓSIO INTERNACIONAL DE EDUCAÇÃO A DISTÂNCIA



EnPED
ENCONTRO DE PESQUISADORES EM EDUCAÇÃO A DISTÂNCIA

2016

8 a 27
de setembro

LOPES, Robson da Silva. Planejamento instrucional adaptativo usando Workflow e planejamento genético. 2009. 140 f. Dissertação (Mestrado)-Universidade Federal de Uberlândia, Uberlândia, 2009.

MYERS, Isabel Briggs. MCCAULLEY, Mary H. Manual: A guide to the development and use of the Myers-Briggs Type Indicator. Consulting Psychologists Press. Palo Alto, CA, 1985.

NGUYEN, Loc. A New Approach for Modeling and Discovering Learning Styles by using Hidden Markov Model. Global Journal of Human Social Science Linguistics & Education. Volume 13 Issue 4 Version 1.0. 2013

RABINER, L, R.. A tutorial on hidden markov models and selected applications in speech recognition. Proceedings of the IEEE, 77(2):257–286, 1989.

SILVA, Denise Mendes. O impacto dos estilos de aprendizagem no ensino de contabilidade na FEARP/USP [dissertação]. Ribeirão Preto: Universidade de São Paulo, Faculdade de Economia, Administração e Contabilidade de Ribeirão Preto; 2006. Disponível em: <http://www.teses.usp.br/teses/disponiveis/96/96133/tde-24012007-152550/publico/DeniseMendesdaSilva.pdf> Acesso em: 29/03/2015

Formação,
Tecnologias e
Cultura Digital

Realização



Horizonte
Grupo de Estudos e Pesquisas sobre Inovação em
Educação, Tecnologias e Linguagens



SEAD

ufesd