

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
INSTITUTO DE INFORMÁTICA
PROGRAMA DE PÓS-GRADUAÇÃO EM COMPUTAÇÃO

MARIA APARECIDA MARTINS SOUTO

**Diagnóstico *on-line* do Estilo Cognitivo de
Aprendizagem do Aluno em um Ambiente Adaptativo
de Ensino e Aprendizagem na Web:
uma Abordagem Empírica baseada na sua
Trajetória de Aprendizagem**

Tese apresentada como requisito parcial
para a obtenção do grau de doutor em
Ciência da Computação

Prof. Dr. José Palazzo Moreira de Oliveira
Orientador

Profa. Dra. Rosa Maria Vicari
Co-Orientadora

Porto Alegre, novembro de 2003

CIP – CATALOGAÇÃO NA PUBLICAÇÃO

Souto, Maria Aparecida Martins

Diagnóstico *On-Line* do Estilo Cognitivo de Aprendizagem do Aluno em Um Ambiente Adaptativo de Ensino e Aprendizagem na Web: uma Abordagem Empírica baseada na sua Trajetória de Aprendizagem / Maria Aparecida Martins Souto. – Porto Alegre: Programa de Pós-Graduação em Computação, 2003.

147 f.: il.

Tese (doutorado) – Universidade Federal do Rio Grande do Sul. Programa de Pós-Graduação em Computação, Porto Alegre, BR – RS, 2003. Orientador: José Palazzo Moreira de Oliveira; Co-Orientadora: Rosa Maria Vicari.

1. Modelagem do aluno na Web. 2. Sistemas hipermídia adaptativos. 3. Aquisição de conhecimento. I. Oliveira, José Palazzo Moreira de. II. Vicari, Rosa Maria. III. Título.

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL

Reitora: Profa. Wrana Panizzi

Pró-Reitor de Ensino: Prof. José Carlos Ferraz Hennemann

Pró-Reitora Adjunta de Pós-Graduação: Profa. Jocélia Grazia

Diretor do Instituto de Informática: Prof. Philippe Olivier Alexandre Navaux

Coordenador do PPGC: Prof. Carlos Alberto Heuser

Bibliotecária-Chefe do Instituto de Informática: Beatriz Regina Bastos Haro

Ao meu esposo, José Antônio, pelo apoio e incentivo o tempo todo.

Aos meus filhos, André e Marcelo, pelo grande amor e carinho que tenho por eles.

AGRADECIMENTOS

Agradeço ao meu orientador, Prof. Palazzo, pela amizade e incentivo durante todo o tempo e, especialmente, por me fazer acreditar que minhas idéias produziram uma Tese de Doutorado.

À Profa. Rosa Vicari, minha co-orientadora, pela disposição incansável para ler meus rascunhos e idéias, apesar de suas dificuldades em encontrar espaço na sua agenda, sempre muito ocupada pelas inúmeras responsabilidades que assume. Mesmo assim, recebi dela muitos *feedbacks* importantes.

À psicóloga Regina Verdin, pela grande amizade e companheirismo que nasceu entre nós ao longo destes últimos anos e, em especial, pelas suas valiosas contribuições técnicas ao longo desta jornada.

Aos Professores e colegas do Instituto de Informática da UFRGS: Magda Bercht, Mara Abel e Paulo Engel, que contribuíram com os seus conhecimentos e torceram para ver a conclusão deste trabalho.

Ao Prof. Wagner Teixeira da Silva, da UnB, por ter me auxiliado a encontrar um caminho, e por torcer pelo meu sucesso.

Às bolsistas do Projeto Tapejara, e hoje minhas amigas, Mariusa Warpechowsky, Renata Zanella, Francine Bica, pelas calourosas discussões sobre o Projeto e sobre os artigos que desenvolvemos juntas.

À doutoranda Daniela Musa, que prontamente me substituiu na aula de Introdução à Informática, para que eu pudesse preparar a defesa desta tese.

Ao Instituto de Informática e ao PPGC da UFRGS, por fornecer toda a infraestrutura necessária à realização deste trabalho, e pelos eventuais auxílios financeiros, que possibilitaram a minha participação em eventos importantes.

Aos meus queridos pais, *in memoriam*, que me ensinaram a valorizar o Saber.

A Deus, que tem me acompanhado durante toda a minha existência, e por sua generosidade em me presentear com esta oportunidade de crescimento pessoal e intelectual, que certamente se estenderão aos meus futuros alunos, nesta nobre e abnegada missão de ensinar.

SUMÁRIO

LISTA DE ABREVIATURAS E SIGLAS	7
LISTA DE FIGURAS	8
LISTA DE TABELAS	10
RESUMO	11
ABSTRACT	12
1 INTRODUÇÃO	13
1.1 Justificativa para a Escolha do Tema	13
1.2 Contexto deste Trabalho	14
1.3 Objetivos.....	17
1.4 Contribuições do Trabalho	17
1.5 Organização do Trabalho	19
2 REFERENCIAL TEÓRICO SOB O PONTO DE VISTA PSICOPEDAGÓGICO	20
2.1 Taxionomia de Objetivos Educacionais de Bloom no Domínio Cognitivo.....	20
2.2 Habilidades e Processos Cognitivos no Teste Ross.....	23
2.3 Estilos Cognitivos de Aprendizagem.....	25
2.4 Habilidades e Processos Cognitivos e os Estilos Cognitivos de Apre ndizagem.....	27
2.5 Trabalhos Relacionados	27
2.6 Considerações Finais	31
3 REFERENCIAL TEÓRICO SOB O PONTO DE VISTA COMPUTACIONAL.....	33
3.1 Sistemas Tutores Inteligentes.....	33
3.2 Sistemas Adaptativos de Aprendizagem na Web.....	36
3.3 Aprendizado de Máquina	38
3.4 Aprendizado de Máquina Indutivo por Exemplos	39
3.5 Aprendizado Supervisionado e Classificação	40
3.6 Descoberta de Conhecimento em Bases de Dados	42
3.7 Trabalhos Relacionados	48
3.8 Considerações Finais	51
4 A PESQUISA	53
4.1 Delineamento da Pesquisa	53
4.2 Caracterização dos Sujeitos da Amostra	53
4.3 Variáveis e suas Medidas	54
4.4 Questões de Pesquisa.....	56
5 O PROJETO TAPEJARA	57
5.1 Identificação das Classes de Estilos Cognitivos de Aprendizagem.....	58
5.1.1 Análise dos Dados Oriundos da Aplicação do Teste Ross	58
5.1.2 Conceituando as Classes de ECA Geradas.....	59

5.2	Projeto e Construção do Módulo de Ensino Experimental.....	61
5.2.1	Requisitos do Módulo de Treinamento Experimental.....	61
5.2.2	Plano Pedagógico do Módulo de Ensino Experimental.....	61
5.2.3	A interface do Módulo de Ensino Experimental.....	62
5.3	Aplicação do Módulo de Ensino Experimental.....	63
6	O PROCESSO DE DESCOBERTA DE CONHECIMENTO.....	65
6.1	Limpeza e Transformação de Dados	65
6.2	Pré-Processamento de Dados.....	67
6.3	Análise Exploratória de Dados e Formulação de Hipóteses.....	67
6.3.1	Levantamento Descritivo Inicial dos Dados da Amostra.....	67
6.3.2	Comportamento Navegacional dos ECAs.....	68
6.3.3	Tempos de Permanência dos ECA.....	74
6.3.4	Movimentos do Aprendiz no Módulo de Ensino Experimental.....	81
6.3.5	Resumo da Análise Exploratória	84
6.3.6	As Hipóteses Encontradas	85
6.4	Avaliação Qualitativa dos Resultados	86
6.5	Mineração de Dados e a Busca de um Modelo de Classificação	90
6.5.1	Análise Discriminante	91
6.5.2	Classificador Bayesianos Ingênuo	97
6.5.3	Árvores de Decisão.....	101
6.6	Considerações sobre o Uso das Técnicas de Classificação.....	105
7	CONCLUSÕES E TRABALHOS FUTUROS	107
7.1	Conclusões	107
7.2	Discussão das Contribuições.....	108
7.3	As Limitações do Contexto Estudado	110
7.4	Trabalhos Futuros	110
REFERÊNCIAS.....		113
ANEXO A	EXEMPLOS DE PÁGINAS WEB DO CURSO EXPERIMENTAL	
	TDMA	118
ANEXO B	EXEMPLO DE QUESTÕES DO TESTE ROSS	127
APÊNDICE A	QUESTIONÁRIO DE AVALIAÇÃO QUALITATIVA.....	131

LISTA DE ABREVIATURAS E SIGLAS

AA	Analógico-Analítico
AD	Análise Discriminante
AIEA	Ambiente Inteligente de Ensino e Aprendizagem
AM	Aprendizagem de Máquina
AMPS	Advanced Mobile Phone Service
ASA	Analítico-Sintético-Avaliativo
BD	Banco de Dados
CAI	Computer Aided Instruction
CAPIT	Capitalisation And Punctuation Intelligent Tutor
CBI	Classificador Bayesiano Ingênuo
CG	Concreto-Genérico
CLARISSE	Clusters And Rules ISSuEd
DA	Dedutivo-Avaliativo
EADMC	Ensino a Distância Mediado por Computador
ECA	Estilo Cognitivo de Aprendizagem
EFT	Embeded Figure Test
ERB	Estação Rádio Base
IA	Inteligência Artificial
I-Help	Intelligent Help
INSPIRE	INtelligent System for Personalized Instruction in a Remote Environment
KDD	Knowledge Discovery from Database
MANIC	Multimedia Asynchronous Networked Individualized Courseware
MD	Mineração de Dados
MSLQ	Motivated Strategies for Learning Questionnaire
RN	Rede Neural
RS	Relacional-Sintético
SHA	Sistema Hipermídia Adaptativo
STI	Sistemas Tutores Inteligentes
TA	Trajetória de Aprendizagem
TDMA	Time Division Multiplex Access
URL	Uniform Resource Locator

LISTA DE FIGURAS

Figura 2.1: Habilidades e processos cognitivos avaliados no Teste Ross (MADEIRA et al., 2000)	23
Figura 3.1: Arquitetura tradicional de um STI (BURNS & CAPPS, 1988).....	34
Figura 4.1: Delineamento da pesquisa	53
Figura 5.1: Análise Fatorial: explicação da variância por habilidade cognitiva (MADEIRA et al., 2000)	58
Figura 5.2: A interface do módulo experimental TDMA	63
Figura 6.1: Freqüência relativa média de acesso aos ‘Recursos Didáticos’ – o eixo vertical representa o percentual médio correspondente ao uso dos recursos didáticos antes da primeira prova pelas classes de ECA. As linhas rotuladas representam o percentual médio da amostra.....	69
Figura 6.2: Freqüência relativa média de acesso às ‘Formas de Apresentação dos Conceitos’ – o eixo vertical representa o percentual médio de uso destas formas sobre o total de páginas de ‘Conceitos’ visitadas antes da primeira prova pelas classes de ECA. As linhas rotuladas representam o percentual médio da amostra para estas formas.	71
Figura 6.3: Freqüência relativa média de acesso às ‘Formas de Apresentação dos Exercícios’ – o eixo vertical representa o percentual médio de uso destas formas sobre o total de páginas de ‘Exercícios’ visitadas antes da primeira prova pelas classes de ECA. As linhas rotuladas representam o percentual médio da amostra para estas formas.	72
Figura 6.4: Freqüência relativa média de acesso às ‘Formas de Apresentação dos Exemplos’ – o eixo vertical representa o percentual médio de uso destas formas sobre o total de páginas de ‘Exemplos’ visitadas antes da primeira prova pelas classes de ECA. As linhas rotuladas representam o percentual médio da amostra para estas formas.	73
Figura 6.5: Tempo médio de permanência médio nos ‘Recursos Didáticos’ – o eixo vertical representa o percentual médio de permanência nos recursos didáticos, relativo ao tempo total de permanência no módulo de ensino experimental, incluindo a(s) avaliação(es) final(ais) antes da primeira prova pelas classes de ECA. As linhas rotuladas representam o percentual médio de permanência da amostra nestes recursos.....	75
Figura 6.6: Tempo médio de permanência nas ‘Formas de Apresentação dos Conceitos’ – o eixo vertical representa o percentual médio de permanência nestas formas sobre o tempo médio de permanência nas páginas de ‘Conceitos’ visitadas antes da primeira prova pelas classes de ECA. As linhas rotuladas representam o percentual médio de permanência da amostra nestas formas.	77

Figura 6.7: Tempo médio de permanência nas ‘Formas de Apresentação dos Exercícios’ – o eixo vertical representa o percentual médio de permanência nestas formas sobre o total do tempo de permanência nas páginas de ‘Exercícios’ visitadas antes da primeira prova pelas classes de ECA. As linhas rotuladas representam o percentual médio de permanência da amostra nestas formas.	78
Figura 6.8: Tempo médio de permanência nas ‘Formas de Apresentação dos Exemplos’. O eixo vertical representa o percentual médio de permanência nestas formas sobre o total do tempo de permanência nas páginas de ‘Exemplos’ visitadas antes da primeira prova pelas classes de ECA. As linhas rotuladas representam o percentual médio de permanência da amostra nestas formas.	80
Figura 6.9: Recurso didático modal, em cada movimento, pelos sujeitos das classes de ECA	82
Figura 6.10: Padrões de ações cognitivas dos Estilos Cognitivos até a primeira prova ..	83
Figura 6.11: Relacionamento entre as classes e as variáveis discriminantes	91
Figura 6.12: Discriminando as classes de ECA pelos Recursos Didáticos: coeficientes padrão das funções discriminantes canônicas	95
Figura 6.13: Discriminando as classes de ECA pelas formas de apresentação: Coeficientes padrão das funções discriminantes canônicas	96
Figura 6.14: Recursos Didáticos: coeficientes das funções de classificação	97
Figura 6.15: Formas de Apresentação: coeficientes das funções de classificação	97
Figura 6.16: Representação gráfica do CBI para classificar um novo caso a partir da análise de suas preferências pelos ‘recursos didáticos’	99
Figura 6.17: Árvore de Decisão gerada e os resultados obtidos quando consideramos apenas as preferências das classes de ECA pelos ‘recursos didáticos’	103
Figura 6.18: Árvore de Decisão gerada e os resultados obtidos considerando apenas as preferências das classes de ECA pelas ‘formas de apresentação’	104
Figura 7.1: O estilo cognitivo de aprendizagem no modelo do aluno	111
Figura 7.2: O modelo de uma <i>Trajetória de Aprendizagem</i> (TA)	112

LISTA DE TABELAS

Tabela 2.1: Resumo de trabalhos relacionados sob o ponto de vista da psicologia cognitiva	32
Tabela 3.1: Tabela atributo-valor	40
Tabela 4.1: Perfil dos sujeitos da amostra	54
Tabela 4.2: Indicadores do funcionamento dos ECA e suas medidas	55
Tabela 5.1: Classes de ECAs agrupadas por desempenho (4-5 superior, 3 médio, 1-2 inferior) (MADEIRA et al., 2000).....	59
Tabela 5.2: Os estilos cognitivos e as heurísticas psicopedagógicas.....	62
Tabela 5.3: Recursos didáticos e formas de apresentação no TDMA	62
Tabela 5.4: Distribuição dos sujeitos da amostra	63
Tabela 6.1: Categorização das faixas de frequência relativa e tempos de permanência nos 'Recursos Didáticos' e 'Formas de Apresentação' dos sujeitos da amostra.....	66
Tabela 6.2: Resultados descritivos da amostra ao realizar o módulo de ensino experimental	68
Tabela 6.3: Mapa resumo dos percentuais médios da frequência relativa dos recursos didáticos e formas de apresentação, pelas classes de ECA, em um ambiente de aprendizagem na Web.	84
Tabela 6.4: Mapa resumo dos percentuais médios de permanência nos recursos didáticos e formas de apresentação, pelas classes de ECA, em um ambiente de aprendizagem na Web.....	85
Tabela 6.5: Níveis de crença do especialista	87
Tabela 6.6: Resultados estatísticos gerados na AD	93
Tabela 6.7: Resultado da classificação na análise discriminante considerando apenas a preferência das classes de ECA pelos 'recursos didáticos'	94
Tabela 6.8: Resultado da classificação na análise discriminante considerando apenas a preferência das classes de ECA pelas 'formas de apresentação'	95
Tabela 6.9: Tabela de probabilidades a priori de ser de uma classe de ECA.....	99
Tabela 6.10:Tabela de probabilidades condicionais para o uso de 'Conceito'	100
Tabela 6.11:Tabela de probabilidades condicionais para o uso de 'Exercício'	100
Tabela 6.12:Tabela de probabilidades condicionais para o uso de 'Exemplo'	100
Tabela 6.13:Resultados da classificação através do CBI considerando apenas as preferências pelos 'recursos didáticos'	101
Tabela 6.14:Resultado da classificação através do CBI considerando apenas as preferências pelas 'formas de apresentação'	101
Tabela 6.15:Mapa-resumo do desempenho das técnicas de classificação analisadas ..	106

RESUMO

Uma das questões críticas relacionadas com um Ambiente Adaptativo de Ensino e Aprendizagem baseado na Web diz respeito à eficácia da aprendizagem do aluno remoto. Assim como diversos trabalhos de pesquisa na literatura, nosso estudo preocupou-se com a modelagem do *Estilo Cognitivo de Aprendizagem* (ECA) do aluno visando, em um futuro próximo, a adaptação dos conteúdos pedagógicos a esta importante característica individual do aluno. Esta tese descreve a metodologia utilizada para investigar como modelar o ECA do aluno remoto, baseado na observação e análise de seu comportamento em um ambiente de ensino e aprendizagem na Web. Em nosso estudo, o ECA representa o estágio de desenvolvimento cognitivo do aluno, de acordo com a taxonomia de Bloom. Nós acreditamos que os principais benefícios de adaptar a instrução ao ECA do aluno estão relacionados com a possibilidade de oportunizar a ampliação de suas habilidades cognitivas, assim como oportunizar a aprendizagem em profundidade sobre os conteúdos em estudo. A metodologia quase-experimental usada para a modelagem do ECA do aluno compreendeu duas fases distintas: (i) geração das classes de ECA a partir da aplicação de um teste psicológico em uma amostra da população-alvo; e (ii) desenvolvimento do módulo de ensino experimental e o estudo das *Trajetórias de Aprendizagem* (TA) padrão das classes de ECA, a partir da observação de seus comportamentos durante a execução de uma sessão de estudo na Web. Como resultado deste estudo, identificamos os principais indicadores, que melhor discriminaram as classes de ECA consideradas. Os resultados foram obtidos a partir da observação e análise das TAs na Web. Todo o conhecimento obtido a partir desta investigação deverá nos permitir automatizar o diagnóstico do ECA do aluno remoto. Este conhecimento também será utilizado como base para o desenvolvimento dos conteúdos a serem oferecidos ao aluno pelo Ambiente Adaptativo de Ensino e Aprendizagem baseado na Web.

Palavras-chave: Modelagem de Aluno na Web, Sistemas Hipermedia Adaptativos na Web, Aquisição de Conhecimento, Descoberta de Conhecimento em Banco de Dados, Estilo Cognitivo de Aprendizagem.

Learner's on-line Diagnostic of his/her Cognitive Style of Learning in a Web Learning Adaptive Environment: an Empirical Approach based on the Learning Trajectory

ABSTRACT

A critical issue related to an Adaptive Web-based Learning Environment is related to the effectiveness of the remote learner's apprenticeship. As many research works in the literature, our study is concerned about adjusting the instruction to the individual learner's characteristics. This thesis describes the methodology used to investigate how to model the learner's Cognitive Style of Learning (CSL) based on the observation and analysis of his/her behavior in a web-learning environment. In our study the CSL represents the learner's development cognitive stage according to Bloom's taxonomy. We do believe that the main benefits on adapting the instruction to the learner's CSL are to amplify his/her cognitive abilities and to develop the in-depth learning. The methodology encompasses two phases: (i) the generation of the CSL classes for the target population; and (ii) the study of CSL classes' learning trajectories in an experimental learning module. As a result we have identified the CSL classes' parameters that better discriminate them from the observation and analysis of their learning trajectory on the Web. All the knowledge obtained from this investigation will permit us to automate the learners' CSL diagnostic. It will also give us the background to develop web-training environment contents.

Keywords : Learner modeling on the Web, Adaptive Hypermedia Systems in the Web, Knowledge Acquisition, Knowledge Discovering in Databases, Cognitive Style of Learning.

1 INTRODUÇÃO

Neste Capítulo é apresentada uma descrição geral e sucinta desta tese, com o objetivo de fornecer ao leitor uma justificativa do tema escolhido, o contexto no qual se insere, os objetivos do estudo, as questões de pesquisa e, por fim, as principais contribuições do trabalho.

1.1 Justificativa para a Escolha do Tema

Hoje em dia, o ensino a distância via Web constitui-se em um importante desafio a ser investigado, especialmente quando se tem como objetivo a construção de um material pedagógico com qualidade e o acompanhamento *on-line* do processo de aprendizagem do aluno remoto, de modo efetivo e eficaz.

O primeiro grande desafio para o sucesso do Ensino a Distância Mediado por Computador (EADMC) depende fundamentalmente da conscientização de professores e alunos em relação aos seus papéis: o professor assumindo o papel de mediador e estimulador do processo de aprendizagem do aluno e o aluno assumindo o papel de agente ativo no seu processo de aprendizado.

O segundo grande desafio para o sucesso do EADMC refere-se ao projeto e implementação do ambiente computacional que irá facilitar a atuação dos principais agentes que nele agem, ou seja, professor e aluno.

O trabalho de investigação nesta área exige um esforço eminentemente multidisciplinar entre especialistas em Inteligência Artificial na Educação com psicólogos, pedagogos, especialistas no domínio (conteúdos), projetista de interface e navegação, analistas em Sistemas de Informação, etc. Em contrapartida, os benefícios obtidos a partir deste esforço são decisivos, tanto sob o ponto de vista da Instituição de Ensino ou Empresa, que cumprem este papel para com os seus alunos ou funcionários, quanto para o próprio aluno, em especial. Sob o ponto de vista da Instituição de Ensino, esta nova modalidade pode significar a redução do tempo e dos custos com o deslocamento e estadia de seus professores e alunos, locação do espaço físico, etc. Sob o ponto de vista do aluno, significa flexibilidade para escolher a hora e o lugar para a realização do seu treinamento e/ou aperfeiçoamento.

Complementarmente, os recursos tecnológicos disponibilizados hoje pela Internet proporcionam um novo estímulo à pesquisa que vem sendo realizada na área das Ciências Cognitivas, especificamente com relação às subáreas da Inteligência Artificial na Educação e da Psicologia Cognitiva. Esta nova tecnologia tem facilitado enormemente a distribuição da informação e a comunicação entre professores e alunos e entre os próprios alunos. Entretanto, se pensarmos em um ambiente inteligente de ensino e aprendizagem, individualizado e assíncrono na Web, nos deparamos com

importantes desafios, tanto sob o ponto de vista psicopedagógico, quanto sob o ponto de vista dos sistemas inteligentes de ensino e do ambiente computacional como um todo.

Sob o ponto de vista psicopedagógico, algumas questões precisam ser analisadas com critério, tais como:

- Identificação do paradigma de ensino e aprendizagem a ser seguido.
- Identificação dos fatores que realmente influenciam na eficácia da aprendizagem nesses ambientes.
- Como fornecer cobertura pedagógica à extensa variedade de perfis cognitivos dos alunos e as dificuldades que serão enfrentadas por eles, especialmente a distância, adaptando estratégias de ensino adequadas em cada caso?
- Como lidar com a falta de *feedback on-line* para o professor, o qual fica sem saber sobre o estágio de compreensão do aluno, e este, por sua vez, tende a ficar isolado e potencialmente poderá sentir-se perdido e desencorajado?
- Como planejar e desenvolver material pedagógico em ambientes educacionais hipermídia, que atendam as demandas de aprendizagem dos alunos?

Sob o ponto de vista do ambiente computacional, também existem importantes questões que precisam ser analisadas, entre as quais mencionamos:

- Como dispor de meios eficientes e eficazes para compreender (ou inferir), de forma on-line, as necessidades do aluno-aprendiz em cada momento?
- Como modelar aquelas características do aluno-aprendiz, que afetam o modo como ele interage com um particular ambiente de aprendizagem?
- Como planejar e construir os agentes artificiais que irão realizar o acompanhamento *on-line* dos passos do aluno, executar o seu diagnóstico cognitivo e propor-lhes estratégias e táticas pedagógicas, adequadas às necessidades atuais de aprendizagem deste aluno?

O projeto e desenvolvimento de sistemas inteligentes de ensino e aprendizagem são fundamentais. O professor continua existindo e tem sua importância aumentada, mas não como um mero transmissor de conhecimento, e sim como um orientador, um facilitador e um avaliador do processo de aprendizado. Ao assumir estes papéis, o professor certamente terá sua carga de trabalho aumentada, o que justifica a necessidade de agentes pedagógicos inteligentes que o auxiliem nesta tarefa.

A proposta deste estudo visa contribuir para a solução de parte destes desafios, através do estudo e investigação sobre a modelagem, em computador, de características cognitivas individuais do aluno. A modelagem cognitiva do aluno, por sua vez, visa a modelagem de agentes inteligentes que possam auxiliar o professor na árdua tarefa de acompanhar o processo de aprendizagem de seus alunos, individualmente, auxiliando-os quando necessário.

1.2 Contexto deste Trabalho

Os softwares educacionais comerciais normalmente exploram os atrativos de um ambiente hipermídia, tais como a utilização de imagens, animações, áudio, etc., mas acabam descuidando dos aspectos relacionados às demandas psicopedagógicas, adequadas a cada perfil cognitivo do aprendiz *on-line*, tanto na fase do planejamento e construção dos conteúdos pedagógicos, quanto durante o processo de aprendizagem propriamente dito. Abordagens deste tipo podem comprometer a eficácia da

aprendizagem, fazendo com que o processo em si se torne cansativo, repetitivo e desestimulante para o aprendiz.

Com o objetivo de superar estas deficiências, diversos pesquisadores, especialmente aqueles focados nas ciências cognitivas, têm direcionado suas investigações no sentido de identificar que características cognitivas individuais realmente influenciam, de forma positiva, no processo de aprendizagem do aprendiz remoto na Internet. Entre estes pesquisadores, citamos: (Dufresne & Turcotte, 1997), (Ford & Chen, 2000), (Macgregor, 1999), (Martinez & Bunderson, 2000), (Mcmanus, 2000). Por exemplo, (Martinez & Bunderson, 2000) investigaram como os indivíduos gerenciam sua aprendizagem em um ambiente de aprendizagem interativo na Web, projetado para suportar diferentes orientações de aprendizagem; (Mcmanus, 2000) investigou como determinar a combinação adequada entre os diferentes níveis de *não-linearidade* de um ambiente hipermídia na Web e os diferentes níveis de *auto-regulação* do aprendiz. Para este autor, os aprendizes auto-regulados controlam ativamente a sua aprendizagem, o ambiente e as interações entre eles.

O projeto Tapejara – Sistemas Inteligente de Ensino na Internet – em cujo contexto se insere esta tese, teve como meta buscar uma solução que contribuísse para minimizar o comprometimento psicopedagógico destes sistemas. Este projeto foi constituído com a parceria entre duas universidades – UFRGS (Instituto de Informática) e UNISINOS (Faculdade de Psicologia) – e com a companhia de telecomunicações CRT Telecom. O projeto teve apoio do CNPq – ProTem-CC, no período de novembro de 1999 a outubro de 2001.

A proposta do projeto Tapejara tinha três importantes objetivos: (i) objetivo *psicopedagógico*; (ii) objetivo *computacional*; e (iii) objetivo de atender às *demandas de treinamento* dos funcionários da empresa parceira no projeto. Com relação ao objetivo *psicopedagógico*, a idéia foi modelar o *estilo cognitivo de aprendizagem* do aluno e orientar o seu processo de aprendizagem de acordo com esta sua característica cognitiva.

Por que adaptar o ensino ao *estilo cognitivo* do aluno?

Quais são os benefícios psicopedagógico para o aluno?

Conforme estudos recentes encontrados na literatura (Riding & Rayner, 2000, Riding & Cheema, 1991; Schmeck, 1988, entre outros), o *estilo cognitivo* de um indivíduo descreve a sua forma individual, preferida e habitual, com que ele organiza e representa novas informações, enquanto ele executa uma tarefa de aprendizagem. Portanto, o pressuposto básico no Tapejara era de que, ao se apresentarem novas informações ao aprendiz, organizadas e representadas da forma como ele normalmente as organiza e as representa mentalmente, aumentaria a probabilidade de que este aprendiz, fácil e rapidamente, organizasse o seu pensamento e raciocinasse sobre as novas informações que lhe fossem apresentadas. Conseqüentemente, os benefícios psicopedagógico para o aluno estariam relacionados com: facilitar o desenvolvimento de uma tarefa de aprendizagem e aumentar a probabilidade de que o processo de aprendizagem seja mais eficiente e eficaz, melhorando o desempenho do mesmo.

Com relação ao objetivo *computacional*, a questão era: como implementar o objetivo psicopedagógico em um modelo computacional, de modo a realizar a adaptação do ensino (estratégias e táticas pedagógicas) ao estilo cognitivo de aprendizagem do aluno, de forma automática, através de um agente computacional, em um Ambiente Inteligente de Ensino e Aprendizagem na Internet?

Finalmente, quanto ao objetivo da empresa parceira no projeto, o desafio era projetar e desenvolver os conteúdos de um Curso de Telecomunicações na Web, que disponibilizasse ao aluno os recursos pedagógicos necessários para individualizar a sua apresentação, de forma adequada às características de cada estilo cognitivo considerada.

Considerando que o foco desta tese está centrado na modelagem computacional do *Estilo Cognitivo de Aprendizagem* do aluno, primeiramente é necessário que se conceitue *Estilo Cognitivo de Aprendizagem* (ECA). No contexto do Projeto Tapejara, e por consequência desta tese, o construto *Estilo Cognitivo de Aprendizagem* baseia-se na taxonomia de Bloom (Bloom et al., 1972), para o *domínio cognitivo*. As dimensões ou classes de ECA consideradas foram formadas a partir de um subgrupo de sujeitos da população-alvo, cujo desempenho predominante nas *habilidades cognitivas* superiores (i.é., *análise, síntese e avaliação*) e nos *processos cognitivos* subjacentes (i.é., *raciocínio analógico, raciocínio dedutivo, premissas ausentes, relações abstratas, síntese seqüencial, estratégias de questionamento, análise de informação relevante e irrelevante e análise de atributos*), propostos por Bloom, e avaliados através do Teste Ross (Ross & Ross, 1997), resultaram semelhantes na análise de *cluster*. A metodologia de identificação das classes de ECA está descrita em detalhe no Capítulo 5.

Subjacente ao construto¹ ECA, a equipe de psicólogos do Tapejara definiu um segundo construto psicopedagógico, qual seja, as *Trajetórias de Aprendizagem* (TA). Este construto foi definido visando capturar e representar um padrão de ações cognitivas que pudesse ser concretamente observado através de um conjunto de variáveis, indicadoras do comportamento do estilo cognitivo durante um processo de aprendizagem na Web (Madeira et al., 2000). A idéia por trás disso é que esses padrões de ações cognitivas refletissem os diferentes estágios nas habilidades e processos cognitivos propostos por Bloom.

Portanto, a modelagem do ECA do aluno remoto passa pela análise de sua *Trajetória de Aprendizagem*, uma vez que ela representa o comportamento observável das ações características do *estilo cognitivo* a ela associado.

O projeto e desenvolvimento do modelo computacional para realizar o diagnóstico do *estilo cognitivo* do aluno *on-line* constituem-se na grande questão de pesquisa desta tese. Esta tarefa é especialmente complexa por pelo menos três grandes motivos:

1. O domínio de conhecimento a ser modelado (comportamento dos ECAs durante um processo de ensino e aprendizagem na Web) ainda está sob investigação por parte de psicólogos e pedagogos;
2. Como consequência do fato de ainda não estar disponível o modelo de comportamento das classes de ECA em um ambiente de ensino e aprendizagem na Web, é fundamental que se investigue sobre os padrões de comportamento dessas classes, o que por si só não é uma tarefa trivial;
3. Os resultados da investigação sobre o comportamento das classes de ECA nos permitirão apenas a manipular com hipóteses (ou simplesmente estimativas) que certamente estarão associadas aos padrões de comportamento encontrados para cada classe de ECA durante o estudo.

¹ O termo construto refere-se a uma idéia ou noção psicológica. A inteligência, e a extroversão são exemplos de construtos psicológicos (Riding & Rayner, 2000).

1.3 Objetivos

Neste estudo foram definidos os seguintes objetivos:

- **Objetivo Geral**

Desenvolver um modelo computacional para a realização do diagnóstico do Estilo Cognitivo de Aprendizagem do aluno, a partir da observação da sua Trajetória de Aprendizagem, em um Ambiente Inteligente de Ensino e Aprendizagem na Internet. Isto significa investigar e gerar um modelo de classificação do ECA do aluno remoto, a partir da identificação dos principais atributos associados a cada uma das classes de ECA.

- **Objetivo Secundário**

O resultado do diagnóstico cognitivo, juntamente com outras informações a respeito do estado atual de aprendizagem do aluno, poderá ser utilizado por um agente pedagógico computacional, de modo que ele possa decidir sobre a estratégia ou tática pedagógica mais adequada a ser sugerida ao aluno naquele momento.

- **Objetivos específicos**

- Determinar o conjunto de indicadores de aprendizagem associados às trajetórias de aprendizagem, que é possível de ser extraído a partir do arquivo de *log* gerado durante o experimento realizado.
- Analisar o comportamento dos ECAs através do estudo e comparação dos indicadores de aprendizagem a eles associados.
- Identificar as trajetórias de aprendizagem padrão para cada classe de *estilo cognitivo de aprendizagem* considerada no estudo, ou seja, identificar os indicadores que melhor discriminam as classes de ECA.
- Investigar as possíveis técnicas computacionais que podem ser usadas para realizar o diagnóstico on-line do ECA do aluno.
- Investigar as possíveis técnicas computacionais capazes de gerar um modelo de diagnóstico a partir dos dados.

1.4 Contribuições do Trabalho

Uma das principais contribuições deste trabalho refere-se ao processo de descoberta de conhecimento sobre as *Trajetórias de Aprendizagem* típicas de cada uma das classes de ECA consideradas. Este processo iniciou pelo estudo e compreensão dos fundamentos psicopedagógicos que sustenta, teoricamente, o construto de Estilo Cognitivo de Aprendizagem; passou pela coleta, limpeza e transformação de dados do arquivo de *log*, gerado durante a realização do experimento com uma amostra da população-alvo; seguiu através da análise exploratória das TAs; e culminou com a indução dos atributos que definem os padrões de comportamento das classes de ECA para a população-alvo considerada, ou seja, induzimos o modelo de diagnóstico do ECA do aluno (ou modelo de classificação) a partir da observação de sua TA durante um processo de ensino e aprendizagem na Web. O modelo obtido respondeu a uma de nossas questões de pesquisa, qual seja: “*que parâmetros melhor discriminam as TAs padrão das classes de ECA consideradas?*”.

O modelo de diagnóstico induzido, por sua vez, nos permitiu delinear o novo modelo do aluno, o qual integra o *Estilo Cognitivo de Aprendizagem* do aluno. Este novo modelo do aluno nos permitiu responder a outra questão de pesquisa que

estávamos perseguindo: “*como automatizar o diagnóstico do ECA do aluno remoto na Web?*”.

Por fim, considerando que não tínhamos nenhum conhecimento *a priori* a respeito do comportamento das classes de ECA durante a execução de um processo de aprendizagem na Web, iniciamos nossa investigação através de uma análise exploratória e manual dos dados oriundos do arquivo de *log*. Este estudo nos levou à compreensão do conhecimento necessário para modelar o ECA do aluno remoto. Entretanto, uma análise manual do comportamento do aluno na Web consome muito tempo e fica limitada aos dados disponíveis naquele instante. Visando evitar estas restrições, encontramos na área de aprendizado de máquina técnicas que têm sido usadas com sucesso em muitas aplicações, especialmente aquelas que se baseiam no paradigma de aprendizagem indutiva por exemplos. Esta pode ser a solução que responde nossa terceira questão de pesquisa, qual seja: “*como automatizar a aquisição do conhecimento necessário para diagnosticar o ECA do aluno remoto, a partir da observação da sua TA na Web?*”.

Conforme descrevemos na seqüência desta tese, nosso trabalho se diferencia daqueles pesquisados na literatura, especialmente no que diz respeito às dimensões dos estilos cognitivos de aprendizagem utilizados, as quais se baseiam na taxonomia de objetivos educacionais de Bloom, assim como em relação à modelagem das classes de ECA consideradas, as quais se baseiam no comportamento *real* do aluno durante a execução de um processo de aprendizagem na Web.

A abordagem adotada em nossa investigação ainda nos permitiu contribuir em relação aos novos projetos de Sistemas Educacionais a Distância via Web sob os seguintes aspectos:

- Visar o crescimento cognitivo do aluno, uma vez que o diagnóstico do ECA do aluno visa rastrear o nível de suas habilidades e processos cognitivos segundo a taxonomia de Bloom. A maioria dos sistemas educacional encontrado na literatura, que se propõe a adaptar os conteúdos pedagógicos ao estilo cognitivo ou de aprendizagem do aluno, o faz visando facilitar o processo de aprendizagem deste, e mantê-lo estimulado e encorajado a perseguir o sucesso da aprendizagem. O nosso trabalho, por sua vez, também tem a intenção de perseguir o sucesso, mas com a diferença de que, neste, o aluno deve ser *estimulado* e *encorajado* a desenvolver suas habilidades cognitivas, tão necessárias ao longo de sua vida escolar e futura.
- Secundariamente, para modelar o ECA do aluno, é necessário que os conteúdos pedagógicos a serem disponibilizados no ambiente de ensino sejam organizados e desenvolvidos de modo a *oportunizar* e *estimular* o crescimento de suas habilidades cognitivas.
- Realizar o diagnóstico do aluno remoto a partir da análise de seu comportamento *real*, usando uma abordagem de avaliação *não-intrusiva*. Sobre este aspecto, a maioria dos sistemas educacional encontrado na literatura utiliza, intensivamente, métodos explícitos de avaliação do aluno, através do uso de questionários, aplicação de testes, etc., para fazer a identificação do perfil cognitivo do aluno.

1.5 Organização do Trabalho

Esta tese está organizada da seguinte forma. O Capítulo 2 apresenta uma revisão da literatura sobre os fundamentos psicopedagógicos que deram origem às classes de ECA consideradas nesta tese. Além disso, o Capítulo também conceitua os construtos psicopedagógicos utilizados ao longo do trabalho, assim como apresenta uma revisão bibliográfica recente de trabalhos relacionados.

O Capítulo 3 apresenta uma revisão sucinta sobre os fundamentos computacionais, relacionados às subáreas da IA tais como: Sistemas Tutores Inteligentes (STI), Sistemas Adaptativos de Aprendizagem na Web, Aprendizado de Máquina (AM) indutivo por exemplos e Descoberta de Conhecimento em Bases de Dados, usados como aporte computacional, teórico e metodológico. O estudo realizado nestas subáreas da IA enfocou os aspectos relacionados, especialmente, com a modelagem de características do usuário e/ou aluno e com a modelagem dos padrões de navegação na Web. Este Capítulo também apresenta uma revisão bibliográfica recente de trabalhos relacionados.

O Capítulo 4 descreve o delineamento da pesquisa quase-experimental realizada, a caracterização da amostra de dados, as variáveis dependente/independentes e suas métricas e as questões de pesquisa que foram perseguidas ao longo do trabalho.

O Capítulo 5 descreve como foram geradas as classes de ECA consideradas neste trabalho, o módulo de ensino experimental e as condições sob as quais este módulo de ensino foi aplicado à amostra de sujeitos, já rotulados segundo a classe de ECA à qual eles pertenciam.

O Capítulo 6 descreve o trabalho realizado durante o processo de descoberta de conhecimento sobre as *Trajetórias de Aprendizagem* padrão, para cada uma das classes de ECA consideradas, assim como apresenta os resultados encontrados a partir das análises realizadas sobre o comportamento das classes de ECA durante a execução de uma sessão de estudo via Web.

Finalmente, o Capítulo 7 discute os resultados obtidos a partir das questões de pesquisa inicialmente postas. Comenta as limitações do contexto sobre o qual foi realizado o experimento e, finalmente, apresenta as diversas possibilidades de trabalhos futuros.

2 REFERENCIAL TEÓRICO SOB O PONTO DE VISTA PSICOPEDAGÓGICO

Este Capítulo apresenta uma revisão da literatura sobre os fundamentos psicopedagógicos que deram origem às classes de ECA consideradas nesta tese. Além disso, o Capítulo também conceitua os construtos psicopedagógicos utilizados ao longo do trabalho, assim como apresenta uma revisão bibliográfica recente de trabalhos relacionados.

2.1 Taxionomia de Objetivos Educacionais de Bloom no Domínio Cognitivo

Neste trabalho, o estudo e a compreensão da “Taxionomia de objetivos educacionais de Bloom no domínio cognitivo” (BLOOM et al., 1972) teve especial destaque. Isto se deveu ao fato de que, as dimensões dos *estilos cognitivos de aprendizagem* utilizados em nossa investigação, foram geradas com base nas habilidades cognitivas superiores (i.e. *análise, síntese e avaliação*), categorizadas por Bloom e avaliadas através do Teste Ross (ROSS; ROSS, 1997), o qual é descrito na próxima seção deste trabalho.

Conforme Anderson et al. (2001), o trabalho de Bloom foi pela primeira vez publicado em 1956 e, desde a sua primeira publicação, esse trabalho tem fornecido uma base sólida no desenvolvimento de currículos (*o que ensinar*) e nos projetos de testes (*o que medir*) em escolas do mundo inteiro. Isto evidencia a sua importância na área da educação.

O termo “taxionomia”, no dicionário da língua portuguesa (Ferreira, 1986), significa “Ciência da Classificação” (i.e., classificação dos seres na Biologia, classificação das palavras, na gramática, etc.). Na classificação de Bloom, o objeto de classificação correspondeu aos *objetivos educacionais*, os quais referem-se “as mudanças que ocorrem nos indivíduos, resultantes de experiências educacionais”, ou seja, o *comportamento esperado* do aluno. Estas mudanças estão assentadas em diferentes bases, tais como: o comportamento do professor, os métodos de ensino e o comportamento esperado do aluno. Especificamente, no domínio cognitivo, abordado neste trabalho, são considerados somente os comportamentos relacionados aos *atos mentais* ou de *pensamento* do indivíduo.

Taxionomia e Classificação são termos comumente interpretados como sinônimos. Na verdade, estes termos não são sinônimos. Segundo Bloom, uma taxionomia deve ser construída de tal forma que a ordem dos termos corresponda a certa ordem real entre os fenômenos representados por estes termos. A validade de uma taxionomia depende da demonstração de sua compatibilidade com as conclusões resultantes de dados de pesquisa no campo que busca ordenar. Desta forma, “*às taxionomias seguem certos*

princípios estruturais que ultrapassam em complexidade as normas de um sistema de classificação” (BLOOM et al., 1972, p. 15).

A taxionomia de Bloom apresenta uma ordem hierárquica de classes que favorece a categorização dos diversos objetivos educacionais. A construção das classes foi definida de modo que os objetivos categorizáveis de uma classe compreendesse e se baseasse em comportamentos incluídos nas classes precedentes do esquema. Cada classe tem subclasses. Este relacionamento está baseado no pressuposto de que as classes e subclasses constituem um contínuo, do mais simples para o mais complexo e do concreto para o abstrato” (BLOOM et al., 1972, p. 15).

Sob o ponto de vista psicopedagógico, um *objetivo educacional* compreende uma formulação explícita das mudanças que se espera, ocorram nos alunos durante um processo educacional. Esta formulação deve descrever o *comportamento pretendido* (ou *habilidade cognitiva*), assim como deve indicar o conteúdo ou o *objeto do comportamento*.

Com base no acima exposto, a estrutura da taxionomia de objetivos educacionais foi constituída visando incluir seis classes de *habilidades cognitivas* pretendidas, quais sejam:

- 1.00 CONHECIMENTO
- 2.00 COMPREENSÃO
- 3.00 APLICAÇÃO
- 4.00 ANÁLISE
- 5.00 SÍNTESE
- 6.00 AVALIAÇÃO

A seguir apresentamos um resumo descritivo destas seis classes e suas subclasses, com alguns exemplos de objetivos educacionais (em destaque no texto) apresentados por Bloom.

A classe **1.0 - CONHECIMENTO** enfatiza principalmente o processo psicológico de evocar, lembrar. Esta classe compreende três subclasses (**1.10**, **1.20** e **1.30**):

1.10 Conhecimento de específicos

1.11 Conhecimento de terminologia

“Definir termos técnicos, fornecendo seus atributos, propriedades e relações”.

1.12 Conhecimento de fatos específicos

“A evocação de fatos principais a respeito de determinadas culturas”.

1.20 Conhecimento de maneiras e meios de tratar com específicos

1.21 Conhecimento de convenções

“Conscientizar os alunos da forma e uso corretos no falar e no escrever”.

1.22 Conhecimento de tendências e seqüências

“Conhecimento das tendências básicas subjacentes ao desenvolvimento dos programas de assistência pública”.

1.23 Conhecimento de classificações e categorias

“Tornar-se familiarizado com uma série de tipos de literatura”.

1.24 Conhecimento de critérios

“Conhecimento de critérios para a avaliação de atividades recreativas”.

1.25 Conhecimento de metodologia

“Conhecimento de métodos científicos para avaliar conceitos de saúde”.

1.30 Conhecimento dos universais e abstrações num certo campo

1.31 Conhecimento de princípios e generalizações

“A evocação das principais generalizações sobre determinadas culturas”.

1.32 Conhecimento de teorias e estruturas

“A evocação das principais teorias a respeito de determinadas culturas”.

A classe **2.0 - COMPREENSÃO** representa o nível mais baixo do entendimento. Esta classe compreende três subclasses (**2.10**, **2.20** e **2.30**):

2.10 Translação

“A capacidade para compreender enunciações não literais (metáforas, simbolismo, ironia, exagero)”.

2.20 Interpretação

“A capacidade para captar a idéia da obra como um todo em qualquer nível de generalidade desejado”.

2.30 Extrapolação

“Habilidade para predizer a continuação de tendências”.

A classe **3.0 - APLICAÇÃO** enfatiza o uso de abstrações em situações particulares e concretas. Esta classe não tem subclasses.

“Aplicação dos termos ou conceitos científicos usados em um trabalho aos fenômenos discutidos em outros trabalhos”.

A classe **4.0 - ANÁLISE** enfatiza o desdobramento de uma comunicação em seus elementos ou partes constituintes, de modo que a hierarquia relativa de idéias é tornada clara e/ou as relações entre as idéias expressas são tornadas explícitas. Esta classe compreende três subclasses (**4.10**, **4.20** e **4.30**):

4.10 Análise de elementos

“A capacidade para reconhecer suposições não enunciadas”.

4.20 Análise de relações

“Habilidade para compreender as inter-relações das idéias em um trecho”.

4.30 Análise dos princípios organizacionais

“A capacidade para reconhecer forma e padrão em obras literárias e artísticas como um meio de compreender o seu significado”.

A classe **5.0 - SÍNTESE** enfatiza a combinação de elementos e partes, de modo a formar um todo. Esta classe compreende três subclasses (**5.10**, **5.20** e **5.30**):

5.10 Produção de uma comunicação singular

“Capacidade para relatar uma experiência pessoal com eficácia”.

5.20 Produção de um plano ou indicação de um conjunto de operações

“Capacidade para propor maneiras de testar hipóteses”.

5.30 Derivação de um conjunto de relações abstratas

“Capacidade para fazer descobertas e generalizações matemáticas”.

Finalmente, a classe **6.0 - AVALIAÇÃO** enfoca julgamentos a respeito do valor do material e dos métodos para certos propósitos. Esta classe compreende duas subclasses (6.10 e 6.20):

6.10 Julgamentos em termos de evidência interna

“A capacidade para indicar incongruências lógicas em argumentos”.

6.11 Julgamentos em termos de critérios externos

“A comparação das principais teorias, generalizações e fatos a cerca de culturas egípcias”.

2.2 Habilidades e Processos Cognitivos no Teste Ross

O Teste Ross (ROSS; ROSS, 1997) está apoiado na Taxonomia de Bloom para o domínio cognitivo e avalia, especificamente, os processos cognitivos correspondentes aos: *Raciocínio Analógico, Raciocínio Dedutivo, Premissas Ausentes, Relações Abstratas, Síntese Seqüencial, Estratégias de Questionamento, Análise de Informação Relevante e Irrelevante e Análise de Atributos*, os quais são subjacentes às habilidades cognitivas superiores de *Análise, Síntese e Avaliação* (Figura 2.1).

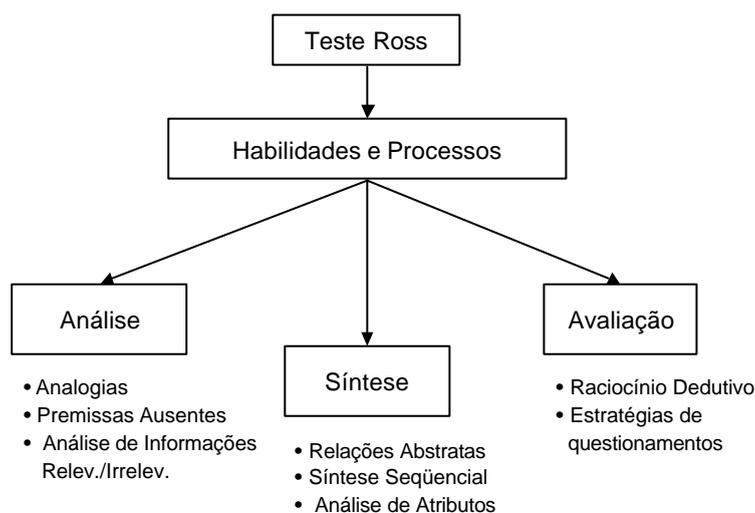


Figura 2.1: Habilidades e processos cognitivos avaliados no Teste Ross (MADEIRA et al., 2000)

No Teste Ross, as seis categorias principais de objetivos educacionais propostas por Bloom foram interpretadas como *habilidades cognitivas*, correspondentes aos diversos estágios de desenvolvimento cognitivo de um indivíduo em idade escolar. Estas habilidades cognitivas correspondem a: *conhecimento, compreensão, aplicação, análise, síntese e avaliação*. Reforçando a idéia taxionômica, no Teste Ross as habilidades intelectuais mencionadas aparecem na maioria dos processos de aprendizagem. Cada nível contém o aprendizado de todos os níveis anteriores (são cumulativos). Os quatro primeiros níveis refletem o aprendizado *conceitual e prático*. Os níveis ditos superiores, avaliados no Teste Ross, correspondem aos níveis de *maior complexidade e abstração mental*. Estes níveis, especialmente os dois últimos, exigem do aluno um trabalho criativo, que inclua a sua contribuição individual.

Sobre a habilidade de *Análise*, Ross a interpretou da seguinte forma: “As habilidades envolvidas na *Análise* sugerem uma ampliação da compreensão da finalidade do material, a evocação e generalização. A hierarquia relativa de idéias é tornada clara e/ou as relações entre idéias expressas são tornadas explícitas. O objetivo é esclarecer a comunicação, indicar como a comunicação é organizada e a maneira pela qual consegue transmitir seus efeitos, assim como, sua base de disposição” (ROSS; ROSS, 1997, p. 5).

Sobre a habilidade de *Síntese*, Ross a interpretou da seguinte forma: “Os argumentos a favor da capacidade de *Síntese* são numerosos, enfatizam a expressão pessoal como contrária à participação passiva e a liberdade de ação e pensamento em contraposição à dependência” (ROSS; ROSS, 1997, p. 5). Observa-se uma união de elementos e partes, de modo a formar um todo, numa estrutura não percebida claramente antes.

Sobre a habilidade de *Avaliação*, Ross a interpretou da seguinte forma: “Na taxionomia do domínio cognitivo a *Avaliação* é considerada um estágio final do complexo processo que envolve certa combinação dos elementos anteriores, embora não seja o último estágio do pensamento ou solução de problemas. Envolve o processo de julgamento acerca do valor de idéias, trabalhos, soluções, métodos, etc., realizados com um determinado propósito” (ROSS; ROSS, 1997, p. 5).

O Teste Ross está dividido em oito seções, correspondentes aos processos cognitivos, subjacentes a cada uma das habilidades avaliadas. Na seção I – *Analogias* – são medidas as habilidades do indivíduo para perceber relações análogas entre pares de palavras e são avaliadas, especificamente, a “eficiência na compreensão de inter-relações entre várias idéias”. Na seção II – *Raciocínio Dedutivo* – são medidas as habilidades para análise de informações em lógica, especificamente “a habilidade para identificar falácias lógicas em argumentos”. Na seção III – *Premissas Ausentes* – são medidas as habilidades para identificação da premissa necessária para completar um silogismo lógico, quando são dadas somente uma premissa e uma conclusão. Avalia especificamente “a habilidade para distinguir uma conclusão com afirmações que podem sustentá-la”.

Na seção IV – *Relações Abstratas* – é mensurada a habilidade para estudar dados e sintetizá-los em um sistema lógico consistente, para organizá-los e formar uma estrutura conceitual, estabelecendo relações entre o que existe de comum nos conceitos apresentados. Na seção V – *Síntese Sequencial* – é mensurada a habilidade de organização de idéias em uma comunicação coerente. Na seção VI – *Estratégias de Questionamento* - esta seção contém um conjunto de itens onde um item é pré-selecionado. Mensura a habilidade de avaliar métodos de obtenção de dados para julgar a eficiência do método na produção de melhores informações para identificar o item pré-selecionado.

Na seção VII – *Análise de Informações Relevantes/Irrelevantes* – é avaliada a habilidade do indivíduo para analisar dados e identificar informações com crítica ou a falta da mesma. “É a capacidade de verificar a coerência de hipóteses com certas informações e suposições, e habilidade para distinguir informações relevantes das irrelevantes”. Finalmente, na seção VIII – *Análise de Atributos* – é mensurada a habilidade de analisar figuras, determinar criticamente elementos dentro das figuras, formular uma hipótese a cerca dos atributos que são necessários para um membro do conjunto e usar a hipótese na elaboração do processo de decisão para identificar membros de um conjunto de um grupo de novas figuras. Essa seção refere-se a um subgrupo da *Síntese* e inclui “habilidade para formular apropriadamente hipóteses

baseadas em uma análise de fatores envolvidos, e para modificar estas hipóteses à luz de novos fatores e considerações”.

O Teste Ross tem o intento de compreender o indivíduo de uma maneira mais ampla, pois os itens do teste requerem do estudante a realização de uma variedade de trabalhos para que através dos dados avaliados seja possível um espelhamento de suas habilidades cognitivas. Deve-se notar, entretanto, que o Teste Ross foi cuidadosamente elaborado para concentrar sua principal ênfase nas habilidades dos indivíduos para tratar com abstrações a partir de uma base verbal. A habilidade para elaborar conceitos a partir de abstrações com elementos verbais sem perder a afinidade com a realidade é um componente maior dos processos cognitivos superiores.

O Teste Ross dos processos cognitivos pode ser usado para um ou mais propósitos como os que seguem (ROSS; ROSS, 1997):

1. Selecionar aprendizes de forma classificatória para a inclusão em um “Programa Especial”, cujos requisitos cognitivos incluam um trabalho acadêmico avançado;
2. Estabelecer a efetividade de um Programa de Desenvolvimento Cognitivo em qualquer tipo de organização. Neste caso, o Teste Ross pode ser utilizado para enfatizar o pensamento crítico, métodos de inquirição, resolução de problemas e pensamento lógico, ou o desenvolvimento de um pensamento complexo eficiente;
3. Permitir o acesso ao estágio em que se encontra o desenvolvimento dos Processos Cognitivo superiores dos indivíduos. Neste caso, o Teste Ross pode identificar uma área de deficiência para um indivíduo em um ou mais dos Processos Cognitivos (*Análise, Síntese e Avaliação*).

No Projeto Tapejara, o propósito para a aplicação do Teste Ross correspondeu à geração das classes de estilos cognitivos utilizadas neste estudo, i.e., as classes correspondentes aos níveis de desempenho dos sujeitos avaliados nas habilidades cognitivas superiores e processos cognitivos subjacentes e predominantes.

2.3 Estilos Cognitivos de Aprendizagem

Um dos grandes riscos do ensino a distância diz respeito ao fato do aluno ficar isolado e potencialmente tender a se sentir perdido, desmotivado e desencorajado. Por outro lado, quanto ao professor (ou instrutor), o grande risco diz respeito à falta de acompanhamento e feedback *on-line* sobre o processo de aprendizagem do aluno, fazendo com que este professor fique alheio ao estágio de compreensão do aluno. Aliado a estes fatores, Riding & Rayner (2000) argumentam sobre a necessidade, hoje em dia, por mais pesquisa e desenvolvimento no campo das *diferenças individuais, estilos de aprendizagem e pedagogia*.

Segundo Sternberg & Zhang (2001), tradicionalmente, psicólogos e educadores têm acreditado que o sucesso e o fracasso das pessoas são atribuídos principalmente as suas *diferenças individuais* no que diz respeito as suas capacidades físicas e mentais para fazer algo. Renzulli & Dai (2001) argumentam que a *aprendizagem ativa* sob o ponto de vista do paradigma do processamento de informação, defendido hoje em dia por psicólogos e educadores, passa pelas *diferenças individuais* no que diz respeito ao modo como as pessoas abordam e processam o material de aprendizagem.

Renzulli & Dai (2001) referem às *diferenças individuais* como: *conhecimento prévio, compreensão, valores, atitudes, estilo* e a *motivação* resultante. Estes autores também concordam que é mais provável incentivar a *aprendizagem ativa* quando o

plano pedagógico leva em consideração as *características individuais* que têm relação direta com o modo como os alunos aprendem e o quão bem eles aprendem sob condições específicas de aprendizagem.

Foi sob este enfoque que se desenvolveu o Projeto Tapejara e, conseqüentemente, este trabalho de doutorado. O principal pressuposto era de que, melhorando a *ergonomia cognitiva*, ou seja, promovendo a adaptação máxima das metodologias educacionais às demandas psicopedagógicas do aluno (especificamente no que se refere às suas características de aprendizagem), aumentaria a probabilidade de uma melhor eficácia nos processos de aprendizagem (MADEIRA et al., 2002).

Neste sentido, a principal meta no contexto do Projeto Tapejara era projetar e desenvolver um modelo computacional que permitisse a adaptação da instrução ao *Estilo Cognitivo de Aprendizagem* do aluno remoto, de forma automática. O resultado esperado era não somente melhorar a eficácia dos processos de aprendizagem dos alunos, mas também permitir um melhor acompanhamento das atividades dos alunos mediante a inserção de agentes artificiais que auxiliassem o professor na árdua tarefa de dar assistência a um grande volume e diversidade de alunos remotos, com diferentes demandas psicopedagógicas, em um período de tempo determinado.

Para uma melhor compreensão sobre o que entendemos por *assistir o processo de aprendizagem de um aluno*, levando em consideração o seu *Estilo Cognitivo de Aprendizagem* faz-se necessário, neste momento, conceituar os construtos psicopedagógicos mencionados neste trabalho. É o que passamos a apresentar a seguir.

Estilo de Aprendizagem

Caracteriza como uma pessoa prefere aprender. Por exemplo, considere o tópico “A Guerra Civil nos EUA”. Alguém poderia preferir aprender sobre o assunto de forma visual (através da leitura) ou auditiva (através de uma aula presencial); outro poderia preferir aprender de forma ativa (através de simulações) ou de forma passiva (lendo ou ouvindo sobre o assunto).

Estilo Cognitivo

Caracteriza as formas de cognição da informação (STERNBERG & ZHANG, 2001). Por exemplo, alguém pode tender a dividir a informação em partes, vendo cada batalha como uma entidade distinta, ou tenderá a agrupar a informação, vendo muitas ou todas as batalhas como ações similares de guerra; outro poderá tender a ser impulsivo, indo direto às conclusões a respeito da guerra ou, ao contrário, ser reflexivo sobre o assunto. O estilo cognitivo tende a estar muito próximo da *personalidade*, se comparado com outros tipos de estilo.

Para Riding & Rayner (2000), o construto *estilo cognitivo* é compreendido como “*uma abordagem preferida e habitual de um indivíduo organizar e representar a informação*”. (p. 15).

Estilo Cognitivo de Aprendizagem

No Projeto Tapejara, o construto *Estilo Cognitivo de Aprendizagem* foi interpretado como uma medida dos níveis de desempenho nas habilidades cognitivas superiores (i.é., *análise, síntese e avaliação*) e nos processos cognitivos subjacentes (i.é., *raciocínio analógico, raciocínio dedutivo, premissas ausentes, relações abstratas, síntese sequencial, estratégias de questionamento, análise de informação relevante e irrelevante e análise de atributos*), propostos por Bloom e avaliados através do Teste Ross. A conceituação das classes de *Estilo Cognitivo de Aprendizagem* foram inferidas

a partir do desempenho dos sujeitos testados, nas habilidades cognitivas, advindas da taxionomia de objetivos educacionais de Bloom e nos processos cognitivos subjacentes a estas habilidades, avaliados no Teste Ross. O Capítulo 4 descreve a metodologia utilizada na geração das classes de *Estilo Cognitivo de Aprendizagem* utilizadas nesta tese.

A geração das classes de *Estilo Cognitivo de Aprendizagem* utilizadas neste trabalho baseou-se nos pressupostos da Psicologia Cognitiva, sob o enfoque do Processamento da Informação. A interpretação que se faz a respeito destas classes neste trabalho é a de que cada uma delas reflete o modo como um indivíduo, que se encontra em um determinado estágio de desenvolvimento cognitivo, aborda novas informações durante a execução de uma atividade didática, em um ambiente de ensino e aprendizagem na Web.

2.4 Habilidades e Processos Cognitivos e os Estilos Cognitivos de Aprendizagem

Os processos cognitivos são basicamente atividades cognitivas que acontecem na memória, envolvendo a codificação e os processos de pensamento, os quais são normalmente investigados em laboratórios experimentais. Quando esses processos de pensamento, os quais são descritos em termos de habilidade dos indivíduos que consistentemente realizam certos tipos de tarefas, tais como testes psicológicos, eles são referidos como 'habilidade cognitivas' (SCHEMECK, 1988).

Os estilos cognitivos são padrões diferenciais de reações diante de uma estimulação recebida, via processamento cognitivo da informação e enfrentamento cognitivo da realidade. Os estilos cognitivos remetem mais a formas, tipos ou qualidade da configuração mental do que aos aspectos de conteúdos ou de eficiência desta configuração.

2.5 Trabalhos Relacionados

Sob o ponto de vista psicopedagógico, encontramos na literatura uma extensa variedade de estudos, teóricos e experimentais, que abordam a importante questão de como identificar que *características individuais* de um aluno poderiam influenciar, de forma positiva, o seu processo de aprendizagem em um *Ambiente de Ensino e Aprendizagem Adaptativo na Internet*. Para ilustrar, mencionamos os seguintes autores: (DUFRESNE & TURCOTTE, 1997), (MACGREGOR, 1999), (MARTINEZ & BUNDERSON, 2000), (FORD & CHEN, 2000), (MCMANUS, 2000), entre outros. A seguir apresentamos uma discussão sucinta de alguns dos trabalhos acima relacionados.

Dufresne & Turcotte (1997) investigaram como o estilo cognitivo, baseado na *dependência*² e *independência*³ de área, influencia as estratégias navegacionais em um ambiente de ensino hipermídia. O principal objetivo da pesquisa apresentada era considerar o estilo cognitivo do usuário para a construção de uma interface que melhor se adaptasse a esta sua característica. Os estilos considerados foram: dependentes de área e independentes de área, derivados a partir do trabalho de H. A. Witkin et al., citado em (DUFRESNE & TURCOTTE, 1997).

² Dependente de área: sujeitos deste estilo tendem a perceber as partes a partir do conhecimento do todo.

³ Independente de área: sujeitos deste estilo tendem a perceber as partes independente do conhecimento que eles têm do todo.

Estes autores partiram do pressuposto que o *estilo cognitivo* influencia como o usuário usa o computador, assim como pode explicar alguns problemas e características de comportamento, observadas a partir deste. Por exemplo, alunos do tipo *independente de área* organizam-se melhor quando lhes é permitido adotar suas próprias estratégias. Ao contrário, alunos do tipo *dependente de área* tendem a adotar uma abordagem passiva, preferindo ser guiado ou auxiliado por agentes externos. Estes autores também acreditam que um ambiente educacional hipermídia tem potencial para ser adaptado ao estilo cognitivo do usuário (suas estratégias), favorecendo assim a sua aprendizagem.

Em suas investigações, foram experimentados diferentes níveis de controle sobre o sistema por parte do usuário, de modo a facilitar as interações de diferentes tipos de usuários. Foram desenvolvidas duas versões de interface: uma permitindo o acesso livre à informação e a outra, permitindo o acesso com restrições.

Os resultados de suas análises estatísticas revelaram diferenças importantes do comportamento exploratório no ambiente de ensino, relacionadas às características do usuário. Por exemplo, o usuário identificado como sendo *independente de área*, navega melhor nos ambientes livres, onde ele tem controle sobre suas opções de navegação; ao contrário, os usuários *dependentes de área*, sentem-se mais confortáveis quando são guiados.

Martinez & Bunderson (2000) investigaram a influência de diferenças individuais de aprendizagem em ambientes de ensino adaptativo na Web. Estas diferenças individuais foram representadas através de diferentes perfis de alunos, introduzidos pelos autores, e denominados ‘orientações de aprendizagem’ (na língua inglesa *Learning Orientations*). O ambiente de aprendizagem testado (ou Sistema SILPA - *System for Intentional Learning and Performance Assessment*) correspondeu a um ambiente interativo de aprendizagem na Web, desenvolvido para investigar como o aluno gerencia a sua aprendizagem em ambientes de aprendizagem, projetado para dar suporte às ‘orientações de aprendizagem’ (ou perfis) de alunos.

Martinez & Bunderson (2000) trabalharam com os seguintes perfis de aluno: (i) aluno orientado a *transformação*; (ii) aluno orientado a *desempenho*; (iii) aluno orientado ao *conformismo* e; (iv) aluno *resistente* (na língua inglesa referenciados como, respectivamente: *transforming, performing, conforming* e *resistant*). O aluno orientado a *transformação* é bastante influenciado pela consciência dos aspectos psicológicos que o motiva. Dá muita importância à força pessoal, aos recursos intrínsecos, habilidade, comprometimento, persistência, esforço assertivo, aprendizagem sofisticada, desempenho, estratégias de resolução de problemas e expectativas positivas para auto-gerenciar, com sucesso, uma aprendizagem permanente. Este tipo de aluno gerencia estratégias de aprendizagem holista (“busca a visão do todo”) à analítica (“busca pelas partes que formam o todo”), com objetivos de pequeno e longo alcance e se diverte aprendendo. Ele se arrisca a cometer erros para se tornar mais especialista naquilo que é objeto de seu estudo.

O aluno orientado a *transformação* freqüentemente se apóia em tarefas pequenas, cronogramas, prazos, padrões de desempenho normativo, expectativa social, etc. para a motivação extrínseca da aprendizagem. Gosta de assumir a responsabilidade e o controle da sua aprendizagem e, de boa vontade, torna-se ativamente envolvido no manejo do processo de aprendizagem. Este perfil aprende melhor em ambientes de aprendizagem abertos, de descoberta ou desafio, que o encoraja e dá suporte à construção do seu conhecimento.

O aprendiz orientado a *desempenho* é do tipo que não se arrisca e, conscientemente, sistematicamente e com habilidade usa processos psicológicos, estratégias, preferências e sua habilidade de auto-regulação para alcançar a média padrão dos objetivos de aprendizagem e tarefas. É imediatista e orientado a tarefa; é extrinsecamente motivado e assume poucos riscos com erros e desafios ou objetivos difíceis; é focado em notas e prêmios e em padrões de realizações normativos. Frequentemente baseia-se no relacionamento com um professor particular, nos recursos externos disponíveis e sofre influência social para realizar uma tarefa. Precisa de um forte motivo que o impulse em direção a um maior desempenho intencional e a maiores níveis de conhecimento. Aprende melhor em ambientes semi-estruturados, que imprimem competição, diversão e assistência para auto-motivação. Este grupo de aprendizes pode melhorar através da aprendizagem pelo pensamento holista.

O aluno orientado ao *conformismo* é submisso. Geralmente, aceita passivamente o conhecimento, o armazena e o reproduz. Apoia-se em outros como guia, necessita de exemplos, *feedbacks* explícitos e aprende melhor através da instrução linear, passo-a-passo. Esta orientação de aprendizagem pode melhorar com o aumento dos riscos. Finalmente, o aluno *resistente* é do tipo que duvida que: (i) ele pode aprender ou se divertir ao tentar alcançar qualquer objetivo proposto por outros; (ii) a aprendizagem acadêmica compulsória possa auxiliá-lo a alcançar objetivos pessoais ou iniciar mudanças desejadas; e (iii) seus valores pessoais, interesses e objetivos possam ser beneficiados pelos objetivos acadêmicos.

Os autores concluíram que esta é uma nova perspectiva de investigação a ser continuada, especialmente quando a intenção é projetar ambientes de aprendizagem, remotos, ou não, que atendam as necessidades psicopedagógicas do aluno. Como resultado da sua investigação, os autores descreveram algumas tendências preliminares:

- Alunos do tipo *transformista* indicaram uma tendência para o uso de estratégias com características assertiva, sofisticada, aprendizagem por descoberta, ambientes do tipo “mentor”, quando a meta é: ser assertivo, ser desafiado pela resolução de problemas complexos e ser auto-gerenciável.
- Alunos do tipo *orientado a desempenho* indicaram uma tendência para o uso de estratégias com características de baixo risco, energizante, competitiva, ambientes do tipo “guia”, que encoraje a sua auto-motivação, ao mesmo tempo em que minimize a necessidade de esforço extra e dificuldades padrão.
- Alunos do tipo *conformista* indicaram uma tendência para o uso de estratégias com característica estruturada, sem risco, e ambiente do tipo que “guia”, no sentido de auxiliá-los a aprender, de forma confortável, a medida em que eles aumentam a internalização do desempenho da aprendizagem intencional.

Ford & Chen (2000) investigaram sobre a correlação entre as classes de estilo cognitivo, correspondentes às dimensões ‘independente e dependente de área’, e os comportamentos de aprendizagem durante a execução de um processo de aprendizagem em um ambiente hipermídia, por um grupo de alunos. Neste estudo, o estilo cognitivo mostrou-se estar relacionado com diversos aspectos do comportamento de aprendizagem. Por exemplo, os alunos identificados como dependentes de área, no ambiente de ensino hipermídia, apresentaram as seguintes características (entre outras):

- Fizeram uso intenso do mapa do *site*.
- Fizeram pouco uso do índice de conteúdos.
- Fizeram pouco uso dos botões ‘para frente’ e ‘para trás’.

- Gastaram mais tempo proporcional estudando os níveis mais altos da hierarquia dos conteúdos, em comparação com o percentual de seu tempo gasto nos níveis mais detalhados.
- Adotaram uma abordagem de ordenação relativamente aleatória em relação aos elementos da tarefa de avaliação prática.

Por outro lado, os alunos identificados como independentes de área, no ambiente de ensino hipermídia, apresentaram as seguintes características:

- Fizeram pouco uso do mapa do *site*.
- Fizeram uso intenso do índice de conteúdos.
- Fizeram uso intenso dos botões ‘para frente’ e ‘para trás’.
- Gastaram pouco tempo proporcional estudando os níveis mais altos da hierarquia dos conteúdos, em comparação com o alto percentual de seu tempo gasto nos níveis mais detalhados.
- Adotaram uma abordagem fracamente relacionada com a ordenação relativamente aleatória em relação aos elementos da tarefa de avaliação prática.

As principais conclusões do estudo indicaram que diferentes estilos cognitivos utilizaram diferentes estratégias. Entretanto, a extensão e as condições sobre as quais diferentes estratégias afetam os resultados de aprendizagem não é claro.

McManus da Saginaw Valley State University, Estados Unidos (MCMANUS, 2000), construiu o modelo do aluno baseado na característica da *auto-regulação*, em um ambiente de ensino e aprendizagem individual e assíncrono na Web. Segundo (BANDURA, 1986; SCHUNK, 1991; ZIMMERMAN, 1989, apud MCMANUS, 2000), a aprendizagem auto-regulada consiste em uma combinação complexa de aspectos cognitivos, metacognitivos, motivacionais e de estratégias ambientais e atributos. Aprendizes auto-regulados controlam ativamente sua aprendizagem, o ambiente de aprendizagem e as interações entre eles.

A característica da auto-regulação do aluno é medida a partir do questionário MSLQ (*Motivated Strategies for Learning Questionnaire* (PINTRICH & GARCIA, 1991, apud MCMANUS, 2000)). Na sua investigação, o autor considerou três níveis de auto-regulação: alto, médio e baixo. Os alunos altamente auto-regulados monitoram e guiam o seu próprio aprendizado; enquanto que os alunos com nível de auto-regulação baixo são, motivacionalmente e metacognitivamente passivos na recepção da instrução.

Além da característica de auto-regulação do aluno, o autor combinou duas outras variáveis. Uma delas diz respeito à característica da não-linearidade do ambiente de ensino considerado (típico em ambientes hipermídia); a outra se refere a uma tática de ensino, que o autor referenciou como ‘organizador prévio’ (na língua inglesa, *advance-organizer*). A não-linearidade da apresentação do material instrucional pode permitir que o aluno navegue livremente de um recurso didático para outro, mantendo o controle sobre a organização da informação que individualmente lhe é relevante.

A variável referente à tática organizador prévio constitui-se de pequenos parágrafos, que introduzem novas informações, e que têm o importante papel de conectar o assunto que o aprendiz irá desenvolver na seqüência, com a sua estrutura de conhecimento pré-existente. Segundo os resultados dos estudos deste autor, os ‘organizadores prévios’ são mais efetivos em textos menos organizados, ou seja, em ambientes altamente não-lineares.

Em seu trabalho, McManus concluiu que a característica da auto-regulação, isoladamente, não se mostrou significativa. Entretanto, a correlação entre auto-

regulação e não-linearidade mostrou que os alunos com alto nível de auto-regulação realizam um trabalho pobre em ambientes com nível de não-linearidade baixo; enquanto que os alunos com nível de auto-regulação médio realizam um trabalho pobre em ambientes com nível de não-linearidade alto. Os escores relativamente altos dos alunos com nível de auto-regulação baixo e médio em ambientes com baixo nível de não-linearidade podem indicar que a apresentação pré-organizada é mais efetiva para estes aprendizes; enquanto que a falta de controle restringe o uso de estratégias de auto-regulação personalizadas para os aprendizes altamente auto-regulados. Os ambientes medianamente não-lineares pareceram ser mais efetivos para os aprendizes altamente auto-regulados. Os baixos escores dos aprendizes altamente e medianamente auto-regulados em ambientes altamente não-lineares podem estar refletindo a falta de experiência dos aprendizes considerados.

2.6 Considerações Finais

A partir desta revisão bibliográfica, fizemos algumas considerações:

- Pelo estudo que fizemos na literatura, observamos uma forte preocupação dos cientistas cognitivos em investigarem o modo como características individuais do aluno (i.é, estilo cognitivo, mecanismo de auto-regulação, construtos de orientação da aprendizagem, etc.) influenciam o seu comportamento e o seu desempenho de aprendizagem, em um ambiente de ensino na Web. Estes trabalhos demonstraram ter objetivos comuns, quais sejam, construir material pedagógico e estratégias de ensino comprometidas com as necessidades de aprendizagem do aluno remoto. Acredita-se que os resultados destes trabalhos serão norteadores para a construção de ambientes computacionais de ensino e aprendizagem, cujo principal objetivo consiste em auxiliar o professor na difícil tarefa de assistir o processo de aprendizagem do aluno remoto através da adaptação da instrução, de forma automática e individualizada, aos diferentes perfis de aluno. A Tabela 2.1 resume algumas características do estudo que fizemos sobre a modelagem do aluno, sob o enfoque da Psicologia Cognitiva.
- Nesta tese investigamos a influência de uma característica individual do aluno em um ambiente de ensino individual e assíncrono na Web, como a principal fonte de adaptação da instrução. O foco deste estudo consistiu em buscar possíveis correlações entre as classes de ECA consideradas e suas respectivas *trajetórias de aprendizagem* padrão. O ECA do aluno e sua trajetória de aprendizagem formam a base psicopedagógica para a modelagem do aluno proposta.
- Nos trabalhos acima descritos, de um modo geral, o perfil do aluno é identificado de forma explícita, ou seja, a partir de algum instrumento que permita a sua avaliação. A proposta desta tese é inferir o estilo cognitivo do aluno a partir da observação do seu comportamento, enquanto ele executa um conjunto de interações com o ambiente de aprendizagem.

Tabela 2.1: Resumo de trabalhos relacionados sob o ponto de vista da psicologia cognitiva

Tutor	Fundamentação Psicopedagógica	Perfis de aluno	Como um perfil é identificado?	Referência
Uso das facilidades do módulo de BD no Excel	Estilo cognitivo baseado na dependência de área	<ul style="list-style-type: none"> • Dependente de área (DA) • Independente de área (IA) 	Teste EFT - Embedded Figure Test (Wittin, Oltman, Raskin & Karp, 1971)	DUFRESNE & TURCOTTE, 1997)
SILPA	<ul style="list-style-type: none"> • Teoria da aprendizagem intencional • Construtores de orientação da aprendizagem 	<ul style="list-style-type: none"> • Orientado a transformação • Orientado a desempenho • Orientado ao conformismo • Resistente 	Previamente e de forma explícita (questionário)	(MARTINEZ & BUNDERSON, 2000)
Curso de HTML	<ul style="list-style-type: none"> • Estilo cognitivo baseado na dependência de área • Estilo de aprendizagem: holista e serialista 	<ul style="list-style-type: none"> • IA – Holista • IA – Serialista • DA – Holista • DA - Serialista 	Previamente e de forma explícita (questionário)	(FORD & CHEN, 2000)
Operating Systems Basics Tutorial	No construto de auto-regulação do aluno	<ul style="list-style-type: none"> • Altamente auto-regulado • Medianamente auto-regulado • Pouco auto-regulado 	Previamente e de forma explícita (questionário)	(MACMANUS, 2000)

3 REFERENCIAL TEÓRICO SOB O PONTO DE VISTA COMPUTACIONAL

O objetivo de modelar computacionalmente o *Estilo Cognitivo de Aprendizagem do aluno* baseado na sua *Trajatória de Aprendizagem* em um ambiente de ensino e aprendizagem adaptativo na Web nos levou a busca de um aporte computacional, teórico e metodológico, na área da Inteligência Artificial, em diferentes subáreas de aplicação, quais sejam: Sistemas Tutores Inteligentes (STI), Sistemas Adaptativos de Aprendizagem na Web, Aprendizado de Máquina (AM) indutivo por exemplos e Descoberta de Conhecimento em Bases de Dados (KDD⁴). O estudo realizado nestas subáreas da IA enfocou os aspectos relacionados, especialmente, com a modelagem de características do usuário e/ou aluno e com a modelagem dos padrões de navegação na Web.

Este Capítulo apresenta uma revisão sucinta sobre os fundamentos computacionais, relacionados às subáreas da IA acima mencionadas, bem como apresenta uma justificativa e o contexto para a sua utilização, em cada uma delas.

3.1 Sistemas Tutores Inteligentes

Os Sistemas Tutores Inteligentes (STIs) são sistemas instrucionais, baseados em computador, que se caracterizam, especialmente, pelo seu conhecimento sobre o *domínio* sendo ensinado e pelo seu conhecimento sobre o *conhecimento* do aluno nesse domínio.

Os STIs tiveram a sua origem dentro da ciência da computação, mais especificamente, dentro da área da inteligência artificial (IA). Estes sistemas surgiram no final dos anos 70, inspirados nos sistemas educacionais da época, ou seja, os então chamados sistemas CAI (na língua inglesa, *Computer Aided Instruction* ou Instrução Assistida por Computador). Os sistemas educacionais do tipo CAI tinham como característica induzir o aprendiz a uma resposta correta mediante uma série de estímulos cuidadosamente planejados (tutor decide *o que, quando e como* ensinar). Por outro lado, os STIs (ou ICAI – *Intelligent CAI*) surgiram com a abordagem de simular alguma das capacidades cognitivas do aluno e utilizar estes resultados como base nas decisões pedagógicas a serem tomadas pelo sistema (aluno compartilha com o tutor sobre os seus objetivos de aprendizagem, dificuldades, etc.).

A inteligência dos STIs baseia-se em três diferentes tipos de conhecimento (BURNS & CAPPS, 1988): (i) conhecimento que o sistema tem sobre os conteúdos a serem ensinados (*conhecimento especialista*); (ii) conhecimento que o sistema tem sobre o

⁴ *Knowledge Discovery from Databases*. A sigla em inglês é utilizada neste trabalho por ser amplamente difundida na literatura.

conhecimento do aluno sobre esses conteúdos (conhecimento sobre o *modelo do aprendiz*); e (iii) conhecimento que o sistema tem sobre a pedagogia das *estratégias de ensino*, com o objetivo de adequar a instrução às necessidades atuais de aprendizagem do aprendiz (conhecimento pedagógico). A Figura 3.1 ilustra como as diferentes bases de conhecimento podem interagir em um STI.

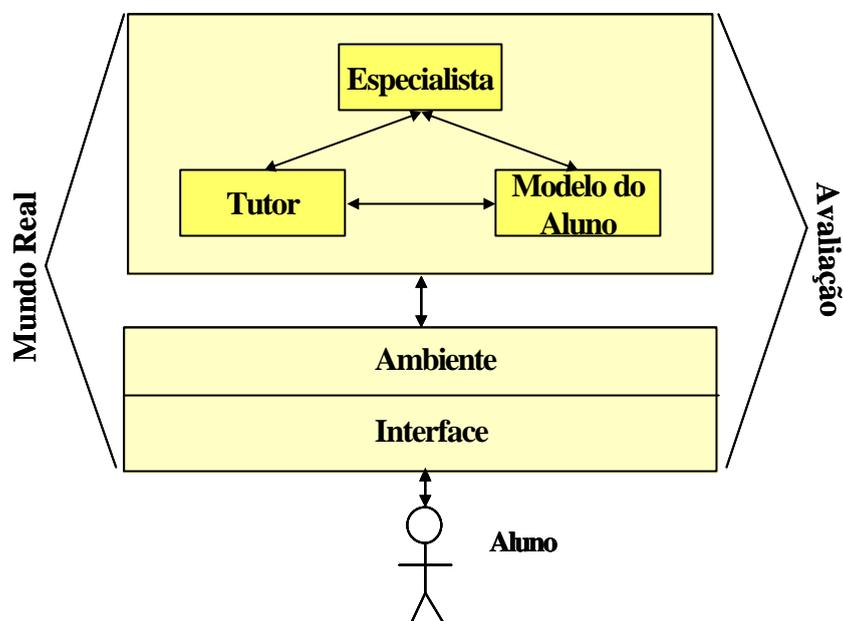


Figura 3.1: Arquitetura tradicional de um STI (BURNS & CAPPS, 1988)

O *módulo especialista* contém o conhecimento do domínio sendo ensinado. O *modelo do aluno* integra ao processo de diagnóstico à estrutura de dados que representa o estado atual de conhecimento do aluno sobre o domínio. O *módulo tutor* identifica as deficiências de conhecimento do aluno e seleciona uma estratégia para apresentar a ele. O ambiente e a interface canalizam a comunicação entre o aluno e o tutor.

Hoje em dia, considerando que o termo “Tutor” está muito ligado à idéia de *ensino tradicional diretivo* (BERCHT, 2001) e, considerando que os objetivos educacionais pretendidos não passam por esta abordagem, adotamos o termo “Ambiente Inteligente de Ensino e Aprendizagem” em nosso trabalho. Um Ambiente Inteligente de Ensino e Aprendizagem (AIEA) corresponde a um conjunto de ferramentas de software, intencionalmente desenvolvidas para uso em situações de ensino e aprendizagem, e que utilizam técnicas de IA com o objetivo de adaptar as estratégias de ensino às demandas psicopedagógicas do aprendiz remoto. Uma vez que a evolução dos sistemas inteligentes de ensino passa obrigatoriamente pelos STIs, parte da bibliografia consultada neste trabalho faz referência aos Sistemas Tutores Inteligentes.

Considerando que esta tese enfoca as questões relacionadas à modelagem do aluno, faz-se necessário à compreensão da terminologia utilizada neste contexto. Segundo (VANLEHN, 1988), uma das importantes tarefas de um STI consiste em inferir o estado atual de conhecimento do aprendiz sobre o assunto que ele está estudando e então, a partir desta informação, adaptar a instrução às necessidades cognitivas particulares do aluno naquele momento. O componente que representa o estado atual de conhecimento do aluno denomina-se *modelo do aluno* e o processo de inferência propriamente dito denomina-se *diagnóstico*. Estes componentes, que devem ser projetados em conjunto, compõem o que se denomina *modelagem do aluno*.

O resultado do *diagnóstico cognitivo* normalmente é utilizado para uma variedade de propósitos, tais como:

- Possibilitar que o tutor conduza o aluno a um novo tópico do programa da disciplina quando ele estiver habilitado para isto;
- Possibilitar que o tutor dê assistência ao aluno, em algum momento de dificuldade, e de forma não solicitada;
- Possibilitar que o tutor gere novos problemas para o aluno resolver, de forma dinâmica, ao invés de seguir uma lista pré-definida;
- Possibilitar que o tutor apresente alguma explicação sobre novos conceitos, utilizando apenas aqueles conceitos (ou terminologia) que o aluno é capaz de compreender naquele momento.

O principal objetivo do diagnóstico cognitivo, ou diagnóstico do *estilo cognitivo de aprendizagem* do aluno remoto, consiste em possibilitar ao tutor a condução da estratégia pedagógica ajustada à habilidade cognitiva que este aluno demonstra possuir, num dado instante.

Neste trabalho optamos por utilizar o termo “*diagnóstico cognitivo*” ao invés de simplesmente “*diagnóstico*”, uma vez que o nosso foco não está relacionado com o conhecimento que o aluno tem do conteúdo, mas com suas habilidades cognitivas individuais para experienciar um processo de aprendizagem em um ambiente educacional na Internet.

Tradicionalmente, no contexto de um STI, a *modelagem do aluno* esteve muito direcionada à modelagem do *nível de conhecimento* do aluno sobre o domínio do curso sendo ensinado e das questões relacionadas à modelagem do conhecimento especialista. No final da década de 80, Kurt VanLehn (VANLEHN, 1988) avaliou o problema da *modelagem do aluno* sob três diferentes dimensões: (i) escopo do conhecimento disponível sobre o aluno (i.é, estados mentais, estados intermediários e estado final); (ii) tipos de conhecimento (i.é, procedimental e declarativo); e (iii) a avaliação das diferenças entre o especialista e o aluno (i.é, modelo de *overlay*, biblioteca de erros, etc.).

O enfoque deste trabalho não está voltado à modelagem do *nível de conhecimento* do aluno enquanto ele resolve um problema, e sim à modelagem de suas *habilidades cognitivas superiores*, conforme a Taxonomia de Bloom. No contexto do Projeto Tapejara, e conseqüentemente desta tese, o desempenho nas habilidades cognitivas e nos processos cognitivos subjacentes, avaliados no Teste Ross, determinou as classes (ou dimensões) de *Estilo Cognitivo de Aprendizagem* (ECA) utilizadas neste trabalho.

A modelagem do ECA do aluno consiste na principal contribuição desta tese. Ao invés de somente modelar o seu nível de conhecimento, nossa abordagem propõe que o ECA do aluno seja integrado ao modelo do aluno. Com isto, pretende-se ampliar a capacidade do AIEA para assistir o processo de aprendizagem do aluno remoto, auxiliando-o no desenvolvimento de suas habilidades cognitivas relacionadas aos conteúdos sendo estudados.

O conhecimento sobre o estágio de desenvolvimento cognitivo do aluno emerge a partir da observação e análise da sua *Trajétoria de Aprendizagem* (TA) pelas páginas Web do curso. O pressuposto básico é de que uma TA representa, de forma implícita, as ações cognitivas sendo realizadas pelo aluno remoto. Entretanto, a grande questão é: “*como descobrir os padrões de TA, típico de cada uma das classes de ECA consideradas?*”.

3.2 Sistemas Adaptativos de Aprendizagem na Web

Um Sistema Hipermídia Adaptativo (SHA) foi definido como “qualquer sistema de hipertexto ou hipermídia, que reflete algumas características do usuário no modelo de usuário, e que aplica este modelo para adaptar os diversos aspectos visíveis do sistema ao usuário” (BRUSILOVSKY, 1995). Portanto, uma das questões centrais desses sistemas diz respeito à modelagem do usuário. O modelo do usuário contém todas as informações que o sistema conhece sobre o usuário para realizar a adaptação.

Nosso principal interesse nos sistemas SHA refere-se aos diversos estudos realizados nesta área, especialmente aqueles relacionados com a modelagem do usuário. De acordo com a revisão bibliográfica apresentada por (BRUSILOVSKY, 1995), em meados dos anos 90, as principais características do usuário que eram levadas em consideração como fonte de adaptação pelos sistemas SHA eram: (i) objetivo do usuário, (ii) conhecimento, (iii) experiências prévias, (iv) experiência no hiperespaço e (v) preferências.

Em um ambiente de ensino e aprendizagem, essas características podem ser interpretadas como: (i) objetivo de aprendizagem do aluno, o qual se modifica freqüentemente de sessão para sessão, ou até mesmo, dentro de uma mesma sessão; (ii) conhecimento, na maior parte das vezes representado através de um modelo de *overlay* (baseado no modelo estrutural do domínio sendo estudado); (iii) experiência prévia do aluno, fora do assunto, mas que é relevante o suficiente para ser considerada (profissão, experiência no trabalho em áreas relacionadas, etc.); (iv) experiência com o hiperespaço, no sentido de quão fácil o aluno consegue navegar e tem familiaridade com a interface, etc.; e, por último, (v) preferências, no sentido de que o aluno pode preferir alguns nós e *links* entre tantos e pode preferir partes de uma página, entre outras.

Hoje em dia, considerando o crescente investimento em aplicações na Web, especialmente as aplicações do tipo *e-learning* (aprendizagem eletrônica) ou os Sistemas Adaptativos de Ensino e Aprendizagem na Web, nos deparamos com novas questões em relação à modelagem do aluno. Kobsa et al. apud Gaudioso & Boticario (2002), sugerem que se faça a distinção entre: (i) *dados do aluno*; (ii) *dados de uso do ambiente educacional*; e (iii) *dados do ambiente*. Os *dados do aluno* compreendem as suas diversas características, representadas no modelo do aluno. Os dados de *uso do ambiente educacional* compreendem aos dados referentes às interações do aluno com esse ambiente. Finalmente, os *dados do ambiente* compreendem aqueles dados que não estão relacionados com o aluno, e sim com o ambiente propriamente dito.

Dados do Aluno

Em relação aos *dados do aluno*, hoje em dia observa-se uma forte tendência em relação à modelagem de características individuais do aluno (i.é, *personalidade, estilos de aprendizagem, estilo cognitivo, fatores emocionais*, etc.), no sentido de que essas características sejam modeladas de forma complementar àquelas características mencionadas por Brusilovsky. Essa nova tendência pode ser observada através dos trabalhos de: D'Amico (1999), que modelou aspectos de personalidade, Soldato (1995) e Bercht (2001), que modelaram fatores emocionais, Reed & Oughton (1997), que modelaram aspectos relacionados a gênero, Martinez & Bunderson (2000), que investigaram diferentes orientações de aprendizagem, Riding & Cheema (1998), Felder & Silverman (1988), Ford & Chen (2000) e Kelly & Tangney (2002), que investigaram aspectos relacionados aos estilos de aprendizagem e estilos cognitivos.

Dados de Uso do Ambiente Educacional

Em relação aos *dados de uso* do ambiente educacional (na língua inglesa referenciado como “*Web usage*”), o enfoque está voltado à modelagem dos padrões de comportamento na Web. De acordo com Zaiiane (2001), na área do comércio eletrônico (*e-commerce*), um esforço significativo de pesquisas tem sido feito com o objetivo de vislumbrar métodos que considerem os acessos dos clientes a *sites* comerciais e seus respectivos comportamentos durante um processo de compra, visando melhorar a satisfação desses clientes através de recomendações inteligentes, visando sempre o aumento das vendas e o lucro.

Entretanto, Zaiiane chama a atenção para o fato de que, na área de *e-learning*, muitos estudos ainda se fazem necessários, especialmente aqueles relacionados com a descoberta de padrões de comportamento do aluno nesses ambientes. A exemplo dos trabalhos desenvolvidos na área do *e-commerce*, encontramos na literatura uma forte tendência das pesquisas na área de sistemas educacionais na Web, no sentido de descobrir padrões de acesso dos alunos ao material pedagógico e de compreender o seu comportamento na Web. Os resultados dessas investigações são fundamentais para o desenvolvimento de sistemas educacionais adaptativos, que de forma automática possam analisar e compreender o comportamento cognitivo do aluno remoto e, a partir daí, possam fornecer assistência pedagógica ajustada às suas demandas de aprendizagem, tornando o processo de aprendizagem mais efetivo e eficaz.

As investigações referentes à descoberta de padrões de navegação na Web passam pelo estudo das *seqüências de páginas visitadas* pelo usuário em uma sessão na Web. Grande parte dos trabalhos encontrados na literatura nessa área adota uma abordagem indutiva na obtenção desses padrões, assim como fazem uso intensivo de técnicas de *Mineração de Dados*, conforme apresentamos na seqüência deste Capítulo. Por exemplo, Cooley et al. (1997) apresentaram cinco diferentes técnicas voltadas à mineração de padrões de acesso em transações Web: (i) *análise de caminhos*; (ii) *regras de associação*; (iv) *padrões seqüenciais*; (v) *regras de classificação*; e (v) *análise de clusters*.

A *análise de caminhos* é realizada por diferentes tipos de grafos, os quais passam a representar alguma relação entre as páginas Web visitadas pelo usuário. O grafo mais óbvio corresponde ao leiaute físico de um *site* na Web, onde as páginas correspondem aos nós e as arestas correspondem aos *links* entre essas páginas. A maioria dos trabalhos busca determinar com que freqüência um padrão foi percorrido.

A técnica de descoberta de padrões através do uso de *regras de associação* normalmente é aplicada em transações de Banco de Dados (BD). Neste caso, o problema envolve a descoberta de associações e correlações entre referências a vários arquivos disponíveis no servidor por um dado cliente. Cada transação é composta por um conjunto de URLs visitadas por um cliente durante o seu acesso ao *site*. Por exemplo, a partir do uso de regras de associação é possível encontrar correlações do tipo: “40% dos clientes que visitaram a URL: *.../companhia/product1* também visitaram *.../companhia/product2*”.

O problema da descoberta de *padrões seqüenciais* é encontrar padrões entre transações tal que, a presença de um conjunto de itens é seguida por outros, considerando a ordenação temporal das transações. A descoberta de *padrões seqüenciais* a partir do acesso ao arquivo de *log* de um servidor Web permite às aplicações na Web predizerem o padrão das visitas dos clientes e, conseqüentemente, permitem um melhor direcionamento de propagandas comerciais a estes clientes. Por

exemplo, analisando estas informações, o sistema de mineração Web poderia determinar o relacionamento temporal entre itens de dados tais como: “... 60% dos clientes que compraram a partir da URL ../companhia/product1, também compraram a partir da URL ../companhia/product4, em um período de 15 dias”.

A descoberta de *regras de classificação* permite o desenvolvimento de um perfil de itens de dados pertencentes a um grupo particular de acordo com seus atributos comuns. Esse perfil pode ser usado para classificar novos itens de dados que serão adicionados ao BD. No contexto da mineração de comportamento na Web, a técnica de classificação permite o desenvolvimento de perfis de clientes que visitam um determinado servidor de arquivos, com base em informações demográficas, disponíveis para esses clientes, ou baseada em seus padrões de acesso. Por exemplo, a classificação sobre o log dos acessos pode levar a descoberta de relacionamentos tais como: “... 50% dos clientes que compraram a partir da URL ../companhia/product2 tinham idade entre 20 a 25 anos e moravam no nordeste”.

Finalmente, a *análise de cluster* permite o agrupamento de clientes ou itens de dados que têm características similares. Esta técnica pode facilitar o desenvolvimento e execução de futuras estratégias de marketing.

O desenvolvimento e a utilização dessas técnicas de mineração de padrões de comportamento na Web (na língua inglesa *Web Usage Mining*) constituem-se, hoje em dia, o grande foco de interesse das aplicações na Web. Embora ainda pouco desenvolvida, soluções como essas têm sido encontradas na literatura atual em relação aos sistemas de Ensino e Aprendizagem na Web. Para exemplificar, citamos alguns trabalhos recentes encontrados na literatura: Stern & Woolf (2000), Levene (2003), Cooley & Mobasher & Sprivastava (1999), Spiliopoulou (1999), entre outros.

Alinhados com a atual tendência dos sistemas adaptativos de ensino e aprendizagem, nesta tese enfocamos a modelagem do *Estilo Cognitivo de Aprendizagem* do aluno através do seu comportamento de aprendizagem na Web (*Trajetória de Aprendizagem*). Para a obtenção do conhecimento a respeito das trajetórias de aprendizagem padrões, de cada uma das classes de estilo cognitivo consideradas, adotamos uma abordagem *quase-experimental* e *indutiva*, baseada em uma análise estatística-exploratória para a identificação dos perfis dos itens de dados e seus atributos, que melhor classificassem o estilo cognitivo do aluno remoto.

3.3 Aprendizado de Máquina

No domínio de um STI (ou de um Sistema Especialista), o conhecimento necessário para representar as classes de ECA e seus atributos, bem como o conhecimento inferencial necessário para realizar o diagnóstico cognitivo do aluno podem ser obtidos de duas maneiras: (i) pelo projetista do sistema ou; (ii) por um agente artificial que aprende a partir da experiência. No primeiro caso, a aquisição do conhecimento é realizada tendo como referência o conhecimento de um especialista no domínio sendo considerado, o que teoricamente pressupõe uma área de conhecimento já estabelecida. Em relação ao segundo caso, Russel & Norvig (1995) comentam: “*sempre que o projetista dispuser de um conhecimento incompleto sobre o domínio sendo considerado, a ‘aprendizagem de máquina’ é a única maneira de um agente artificial adquirir o conhecimento que ele necessita para tomar suas decisões...*”.

Considerando que *a priori* não dispúnhamos do conhecimento sobre as TAs padrão dos ECAs considerados, necessário a sua modelagem computacional, buscamos apoio

na subárea de *Aprendizagem de Máquina* (AM). A AM é uma importante subárea de pesquisa em Inteligência Artificial (IA), na qual são estudados diversos métodos computacionais com o objetivo de adquirir novos conhecimentos, novas habilidades e novos meios de organizar o conhecimento já existente (MITCHELL apud BATISTA, 2003).

Carbonel (1990) identifica quatro paradigmas principais de AM e diversos sub-paradigmas sendo investigados: *Aprendizagem Indutiva* (i.é, aquisição de conceitos a partir de um conjunto de exemplos positivos e negativos); *Aprendizagem Analítica* (i.é, aprendizagem baseada em explicação e em alguns métodos de aprendizagem analógica e baseada em casos); *Algoritmos Genéticos* (i.é, sistemas classificadores) e *Métodos de Aprendizagem Conexionista* (i.é, redes neurais). Segundo este autor, estes paradigmas emergiram a partir de diferentes raízes científicas, desenvolveram métodos computacionais diferentes e freqüentemente baseiam-se em diferentes formas de avaliação do seu sucesso. Entretanto, estes paradigmas compartilham do objetivo comum de construir máquinas que aprendem de modo significativo para uma variedade de tarefas de um domínio. Em todas as abordagens, a aprendizagem pode ser operacionalmente compreendida como a habilidade para executar novas tarefas que não podiam ser executadas antes, ou executar tarefas já executadas antes, mas que passam a executar melhor (i.é, mais rápido, com maior precisão, etc.), como resultado das modificações produzidas pelo processo de aprendizagem.

O aprendizado indutivo é um dos mais úteis, pois permite a obtenção de novos conhecimentos a partir de exemplos particulares, previamente observados (BATISTA, 2003). Entretanto, é um dos mais desafiadores, pois o conhecimento gerado ultrapassa os limites das premissas, e não existem garantias de que esse conhecimento seja verdadeiro.

3.4 Aprendizado de Máquina Indutivo por Exemplos

O aprendizado indutivo por exemplos é o processo de inferência indutiva realizada sobre exemplos observados, os quais são fornecidos ao aprendiz por um professor ou oráculo. Em AM, o aprendiz é um sistema computacional, freqüentemente denotado por *sistema de aprendizado*, *algoritmo de aprendizado*, ou simplesmente *indutor*.

O aprendizado indutivo por exemplos pode ser dividido em *aprendizado supervisionado* e *não supervisionado* (MONARD & BARANAUSKAS apud BATISTA, 2003), descritos a seguir.

Aprendizado Supervisionado

No aprendizado supervisionado é fornecido ao sistema de aprendizado um conjunto de exemplos $E = \{E_1, E_2, \dots, E_N\}$, sendo que cada exemplo $E_i \in E$ possui um rótulo associado. Esse rótulo define a *classe* a qual o exemplo pertence. Formalmente, pode-se dizer que cada exemplo $E_i \in E$ é uma tupla

$$E_i = (\vec{x}_i, y_i) \quad (3.1)$$

na qual \vec{x}_i é um vetor de valores que representam as características, ou atributos, do exemplo E_i , e y_i é o valor da classe desse exemplo. O objetivo do aprendizado supervisionado é induzir um mapeamento geral dos vetores \vec{x} para y . Portanto, o sistema de aprendizado deve construir um modelo do tipo $y = f(\vec{x})$, de uma função

desconhecida, f , que permite prever valores y para exemplos previamente não vistos.

Entretanto, o número de exemplos utilizados para a criação do modelo não é, na maioria dos casos, suficiente para caracterizar completamente essa função f . Assim sendo, os sistemas de aprendizado são capazes de induzir uma função h que aproxima f , ou seja, $h(\vec{x}) \approx f(\vec{x})$. Nesse caso, h é chamada de hipótese sobre a função conceito f .

Aprendizado Não Supervisionado

No aprendizado não supervisionado é fornecido ao sistema de aprendizado um conjunto de exemplos E , no qual cada exemplo consiste somente de vetores \vec{x} , não incluindo a informação sobre a classe y . O objetivo no aprendizado não supervisionado é construir um modelo que procura por regularidades nos exemplos, formando agrupamentos ou clusters de exemplos com características similares.

Nomenclatura

Um conjunto de exemplos ou conjunto de dados $E = \{E_1, E_2, \dots, E_N\}$ é um conjunto de vetores $\vec{x}_1, \dots, \vec{x}_N$, com ou sem a classe associada y . A Tabela 3.1 mostra a forma geral de um conjunto de exemplos E com N exemplos e M atributos. Essa tabela está no formato atributo-valor (também denominada tabela flat), a qual é utilizado como entrada pela maioria dos algoritmos de aprendizado.

Tabela 3.1: Tabela atributo-valor

	A_1	A_2	...	A_M	Y
E_1	x_{11}	x_{12}	...	x_{1M}	y_1
E_2	x_{21}	x_{22}	...	x_{2M}	y_2
...
E_N	x_{N1}	x_{N2}	...	x_{NM}	y_N

O atributo Y é normalmente chamado de *atributo-classe* e, conforme visto anteriormente, somente está presente em conjuntos de dados para *aprendizado supervisionado*. Neste tipo de aprendizado, o atributo classe pode ser um atributo qualitativo que assume um conjunto de valores discretos $C = \{C_1, C_2, \dots, C_{Ncl}\}$ ou um atributo quantitativo que assume um conjunto de valores reais. No primeiro caso, a hipótese h é denominada *classificador*, e a tarefa de aprendizado é denominada *classificação*. No segundo caso, a hipótese h é denominada de *regressor*, e a tarefa de aprendizado é denominada *regressão*.

O foco deste trabalho é o *aprendizado supervisionado* por *classificação*. Os exemplos disponíveis contêm uma entrada para cada aluno que participou do experimento, conforme é apresentado no Capítulo 4. O atributo-classe corresponde ao ECA do aluno; os demais atributos correspondem aos indicadores de sua TA durante a execução do módulo de ensino experimental.

3.5 Aprendizado Supervisionado e Classificação

Segundo Henery (1994), os métodos de classificação comumente praticados e estudados podem ser agrupados sob três diferentes abordagens: (i) abordagem

estatística; (ii) aprendizado de máquina e (iii) redes neurais. A seguir, apresentamos uma breve discussão sobre cada uma delas.

Abordagem Estatística

A abordagem estatística caracteriza-se por prover um modelo básico explícito de probabilidades, ou seja, o modelo estatístico fornece a probabilidade de uma determinada instância ser de uma classe, ao invés de simplesmente realizar uma classificação determinística. Além disso, é assumido que as técnicas estatísticas serão manipuladas por estatísticos, de modo que alguma intervenção humana é necessária em relação à seleção de variáveis e transformação, assim como toda a estruturação do problema.

A comunidade estatística identifica duas fases investigatórias sobre *classificação*. A primeira fase, ou a fase “clássica” concentra-se em derivações do trabalho de Fisher sobre *discriminação linear*. A Segunda fase, ou a fase “moderna” explora modelos de classes mais flexíveis, muitos dos quais tentam prover uma estimativa da distribuição conjunta, utilizando como referência as características de cada classe as quais, por sua vez, podem prover uma regra de classificação.

Entre os métodos estatísticos clássicos, Mitchell (1994) cita: Discriminante Linear, Discriminante Quadrático, Discriminante Logístico, Regra de Bayes. Entre as técnicas estatísticas modernas, Molina et al. (1994) citam: Estimativa de Densidade, K-Vizinhos Mais Próximos, Classificador por Caça e Projeção, Classificador Bayesiano Ingênuo, Redes Causais, etc. Em relação aos métodos estatísticos clássicos citados, os três primeiros baseiam-se na *probabilidade máxima*. A Regra de Bayes trabalha com diferentes probabilidades *a priori* e com diferentes custos de erro. Os métodos modernos enfocam abordagens não paramétricas.

Aprendizado de Máquina

Diferentemente da abordagem estatística, em AM o enfoque recai sobre procedimentos computacionais automatizados, baseados em operações lógicas ou binárias, que aprendem um conceito a partir de uma série de exemplos. Dentro desta abordagem, especial atenção é dada às *árvores de decisão*, na qual o resultado de uma classificação emerge a partir de uma seqüência de passos lógicos. Esta abordagem é capaz de resolver o problema mais complexo dado uma quantidade de dados suficiente. Ainda dentro da abordagem AM, outras técnicas têm sido desenvolvidas, incluindo os *algoritmos genéticos* e procedimentos da *lógica indutiva*. Segundo Henery (1994), estas técnicas, em princípio, nos permitem trabalhar com tipos de dados mais genéricos, incluindo casos onde o número e tipos de atributos podem variar e onde níveis adicionais de aprendizagem são impostos, com uma estrutura hierárquica de atributos e classes e assim por diante.

Em AM, a meta é gerar expressões de classificação simples o suficiente para serem compreendidas por agentes humanos. Estas expressões devem imitar o raciocínio humano para prover a compreensão do processo decisório. Como na abordagem estatística, o conhecimento básico deve ser explorado no desenvolvimento, mas a operação do processo deve ocorrer sem a intervenção dos agentes humanos.

Redes Neurais

Tecnicamente, uma Rede Neural (RN) consiste de níveis de nós interconectados, onde cada nó reproduz uma função não-linear a partir de suas entradas. As entradas de um nó podem vir de outros nós ou diretamente dos dados de entrada. Alguns nós são

identificados como saída da rede. A rede completa representa um conjunto bastante complexo de interdependências, as quais podem incorporar qualquer grau de não-linearidade, permitindo que sejam modeladas muitas funções gerais.

As RNs têm sido consideradas como um espelho, guardadas as devidas proporções, do comportamento da rede de neurônios do cérebro humano. Esta abordagem combina a complexidade de algumas técnicas estatística com a meta em AM, ou seja, imitar a inteligência humana.

3.6 Descoberta de Conhecimento em Bases de Dados

Hoje em dia, uma nova área de pesquisa conhecida como Descoberta de Conhecimento em Bases de Dados – KDD - tem despertado o interesse da comunidade que investiga a utilização de novas técnicas e ferramentas computacionais, que têm como objetivo automatizar a análise inteligente de dados em grandes bases de dados e a geração de informações úteis aos seus usuários. Segundo Fayyad & Piatetsky-Shapiro & Smyth (1996), a descoberta de conhecimento em bases de dados corresponde a um “*processo não-trivial de identificação de padrões de dados válidos, novos, potencialmente úteis e, principalmente, compreensíveis pelo usuário final*”.

KDD é uma área de pesquisa multidisciplinar que envolve outras áreas de pesquisa como Inteligência Artificial, Banco de Dados, Estatística e Visualização Gráfica (PIATETSKY & SHAPIRO apud BATISTA, 2003). Cada uma destas áreas contribui com métodos e ferramentas para a consolidação de KDD.

No contexto desta tese, o principal interesse em KDD está no aporte teórico-metodológico disponível nesta área, para descrever as diversas etapas do trabalho desenvolvido durante um processo de descoberta de conhecimento, por indução através de exemplos. Especificamente, o principal foco está voltado à descoberta das TAs padrões, típicas de cada uma das classes de ECA estudadas. Neste caso, conforme a definição de Fayyad & Piatetsky-Shapiro & Smyth (1996), os *dados* correspondem às TAs realizadas pelos alunos durante o experimento realizado e apresentado nos Capítulos 5 e 6. As TAs são representadas através de um conjunto de variáveis, indicadoras do comportamento de aprendizagem do aluno na Web. Estas variáveis, por sua vez, são compiladas a partir do arquivo de *log*, ou *diário de navegação*, durante uma seção de aprendizagem do aluno.

Os *padrões* mencionados por Fayyad & Piatetsky-Shapiro & Smyth (1996), correspondem a uma expressão, em alguma linguagem, que irá descrever a TA típica de cada uma das classes de ECA consideradas. Extrair um *padrão* a partir dos dados corresponde à geração de uma descrição, alto-nível, das TAs típicas de cada Estilo Cognitivo de Aprendizagem.

Na definição de Fayyad & Piatetsky-Shapiro & Smyth (1996), o termo *processo* implica dizer que a descoberta de conhecimento compreende diversas etapas, as quais envolvem: *preparação de dados*, *busca de padrões* (mineração de dados), *avaliação* do conhecimento adquirido e *refinamento*, todas elas envolvendo repetidas iterações. O termo *não-trivial* significa que alguma busca ou inferência está envolvida, ou seja, não corresponde a uma computação direta de quantidades pré-definidas como, por exemplo, calcular um valor médio a partir de um conjunto de números.

Segundo Fayyad & Piatetsky-Shapiro & Smyth (1996), o processo de descoberta de conhecimento é orientado de acordo com o seu objetivo, estabelecido no primeiro passo. Existem dois tipos de objetivo: *verificação* e *descoberta*. Quando o objetivo é

verificação, o sistema de Mineração de Dados (MD) que realiza a busca de padrões propriamente dita, limita-se a verificar as hipóteses do usuário. Quando o objetivo é *descoberta*, o sistema MD autonomamente encontra novos padrões. A *descoberta* ainda pode ser subdividida em: *predição* e *descrição*. No caso de *predição*, o sistema MD tenta encontrar padrões para prever comportamentos futuros dos dados. No caso de *descrição*, o sistema MD tenta encontrar padrões para apresentar ao usuário uma forma compreensível do comportamento dos dados. Neste estudo, o objetivo é a descoberta das TAs padrão das classes de ECA consideradas.

Fayyad & Piatetsky-Shapiro & Smyth (1996), enumeraram algumas etapas básicas, a serem desenvolvidas durante um processo de descoberta de conhecimento, quais sejam: 1) Identificação e entendimento do problema; 2) Identificação e coleta de dados relevantes; 3) Limpeza e transformação de dados; 4) Pré-processamento de dados; 5) Redução de atributos; 6) Análise exploratória dos dados e formulação de hipóteses; 7) Mineração de dados (MD); 8) Avaliação e interpretação de resultados; 9) Consolidação do conhecimento descoberto.

A seguir, passamos a descrever, de forma sucinta, as diversas etapas de um processo KDD.

Identificação e Entendimento do Problema

A primeira fase do processo de descoberta de conhecimento implica em compreender o domínio da aplicação e identificar o conhecimento prévio relevante, assim como implica na identificação dos objetivos do processo KDD, ou seja, entre as necessidades do usuário, o que pode ser resolvido através da utilização de algum método de Mineração de Dados (MD). De um modo geral, os principais métodos de MD são: *classificação*, *regressão*, *segmentação*, *sumarização* e *deteção de desvio* (Fayyad & Piatetsky-Shapiro & Smyth, 1996), conforme é descrito a seguir.

Em um processo de aprendizagem presencial, o professor presta assistência pedagógica aos seus alunos a partir da observação e da avaliação que ele faz a respeito das interações entre: o professor e o aluno, entre o aluno e o material pedagógico e entre aluno-aluno. Neste estudo a questão é: considerando um ambiente EAD, como avaliar o comportamento do aluno remoto, a partir da observação de suas interações com o material pedagógico na Web? Em outras palavras, como automatizar, de forma inteligente, o diagnóstico do estilo cognitivo do aluno remoto a partir da análise e interpretação da sua trajetória de aprendizagem pelas páginas Web de um curso? No contexto desta tese, o *diagnóstico cognitivo* do aluno remoto envolve uma atividade de *classificação*.

Identificação e Coleta de Dados Relevantes

Uma vez que o problema foi identificado e entendido, é necessário identificar quais atributos da base de dados serão utilizados na análise. Em um BD comercial, os atributos considerados relevantes normalmente estão dispersos em tabelas distintas, muitas vezes em um formato inapropriado para serem utilizados no processo KDD, e sem uma documentação atualizada para consulta. Além disso, muitas vezes, os dados precisam ser rotulados, caso seja necessário a aplicação de um método de classificação.

Em um Ambiente de Ensino e Aprendizagem na Web, esta etapa consiste em coletar os dados a partir da principal fonte de informação que é o arquivo de *log* de navegação, armazenado no servidor Web. Para cada acesso às páginas Web do curso pelo aluno remoto, são registrados os seguintes atributos: a *origem do acesso* (endereço de IP), a

data e *hora* do acesso e o *recurso* solicitado (URL). Portanto, estes são os atributos originais, a partir dos quais o conhecimento é construído.

Neste estudo, esta etapa foi simplificada uma vez que trabalhamos com um arquivo de *log* dedicado, definido como uma Tabela na base de dados (BD) do ambiente de ensino e aprendizagem. Da mesma forma, o ambiente de ensino e aprendizagem era ‘fechado’ e a informação sobre a URL também era armazenada em uma outra Tabela da base de dados.

Limpeza e Transformação de Dados

Esta etapa, e a etapa seguinte, de pré-processamento de dados, são consideradas críticas em um processo KDD, uma vez que consomem entre 80% a 95% do esforço e dos recursos necessários para a realização da descoberta de conhecimento (ZAIANE, 2001). Hoje em dia, existem diversas ferramentas para analisar um arquivo de *log* Web, tais como: NetTracker, Analog, etc. De um modo geral, estas ferramentas fornecem uma análise estatística limitada dos dados, especialmente no que diz respeito a sua capacidade para auxiliar a compreensão de informações implícitas ou tendências ocultas (ZAIANE, 2001). Embora os dados registrados no *log* reflitam o uso real do aluno pelas páginas Web do curso, eles não registram *comportamento*, *relacionamentos* entre seus dados, enfim, não registram aqueles dados que necessitam do *conhecimento* inerente ao modelo do ambiente de ensino e aprendizagem sendo representado nas páginas Web consideradas.

Em um Ambiente de Ensino e Aprendizagem na Web, onde os dados relevantes estão armazenados no arquivo de *log* de um servidor Web, esta etapa é muitas vezes dificultada por dois grandes motivos (ZAIANE, 2001): (i) como identificar um aluno, de forma única, a partir do seu endereço de IP em uma sessão de estudo? (ii) como identificar uma seção de aprendizagem de um aluno, uma vez que todos os registros dos alunos que tiveram acesso ao *site* estão misturados neste arquivo, e a única ordenação existente é a cronológica? Além disso, mesmo quando uma única página é solicitada pelo aluno, existe a possibilidade de que sejam geradas no *log* diversas entradas. Nestes casos, o acesso aos registros de um único aluno por uma ferramenta de mineração de dados fica bastante dificultado.

Felizmente, em Ambientes Educacionais na Web, o problema é muitas vezes simplificado, uma vez que o aluno não é anônimo, i.é, normalmente ele precisa se identificar para ter acesso ao *site* educacional. Entretanto, identificar uma seção de estudo não é uma tarefa trivial.

Em um processo KDD, a limpeza dos dados corresponde à eliminação daqueles registros do *log* que são considerados irrelevantes para a análise do comportamento do aluno. Por exemplo, neste estudo, os registros considerados irrelevantes corresponderam a: acesso a menus, mensagens da aplicação para o aluno, falha de conexão e tempo de permanência nulo em um recurso.

O principal objetivo da transformação de dados visa é justamente transformar a representação dos dados a fim de superar quaisquer limitações existentes nos algoritmos que serão empregados para a extração de padrões (mineração de dados). Algumas das transformações mais comuns correspondem a: normalização de atributos, discretização de atributos quantitativos, transformação de atributos qualitativos em quantitativos e atributos de tipos de dado complexos. Neste estudo, recorreremos a diferentes tipos de transformações, em diferentes momentos do processo de descoberta de conhecimento, conforme é apresentado no Capítulo 6.

Um exemplo típico de transformação diz respeito ao atributo complexo de data e hora. Frequentemente estes atributos são transformados em um outro atributo com a mesma informação, mas com um tipo de dado que o algoritmo seja capaz de analisar. Neste trabalho, por exemplo, o atributo hora foi transformado em um atributo que mede o tempo de permanência em um dado recurso didático e forma de apresentação deste.

Pré-Processamento de Dados

A fase de pré-processamento tem como objetivo aprimorar a qualidade dos dados coletados (BATISTA, 2003). Frequentemente, os dados apresentam diversos problemas, tais como: grande quantidade de valores desconhecidos, ruído (atributos com valores incorretos), atributos de baixo valor preditivo, grande desproporção entre o número de exemplos de cada classe, etc. Nesta etapa, além da preocupação com a possível presença de atributos com *baixo valor preditivo* e com a *grande desproporção* entre o número de exemplos de cada classe de ECA, nos debruçamos sobre a tarefa de *construção de atributos*.

A construção de atributos é o processo de composição de atributos ditos primitivos (pertencentes ao conjunto de dados original), produzindo-se novos atributos, possivelmente relevantes para a descrição de um conceito (BATISTA, 2003).

Da forma como os dados se apresentavam no arquivo de *log* os tornavam inadequados à tarefa de descoberta de conhecimento sobre as TAs das classes de ECAs consideradas. Neste estudo, a construção de atributos foi orientada a partir da definição do conjunto de variáveis (e suas métricas), indicadoras do funcionamento dos ECAs, conforme é apresentado no Capítulo 4.

Redução de Atributos

Nesta fase, frequentemente também é analisada a questão da *dimensionalidade* de atributos, ou seja, o número efetivo de atributos a serem considerados como discriminativos na classificação podem ser reduzidos. Segundo Batista (2003), a princípio, a seleção dos atributos mais representativos pode aumentar a probabilidade desses atributos serem incluídos no classificador induzido. Caso contrário, a análise pode ser comprometida tratando atributos não representativos que não serão incorporados no classificador pelo sistema de aprendizado.

Por exemplo, a existência de um atributo com informação similar (alta correlação) com um dos atributos selecionados pode fazer com que o indutor decida não utilizar o atributo selecionado no classificador induzido.

Batista comenta que encontrar os atributos mais representativos em um conjunto de dados não é uma tarefa trivial. Em seu trabalho, foram utilizados os seguintes métodos: filtro e *wrapper*. Um método filtro é um método de seleção de atributos que é aplicado para selecionar os atributos antes que ocorra o processo de indução. O método *wrapper* realiza uma busca por um subconjunto de atributos representativos por meio da adição e remoção de atributos no conjunto de dados e da medição da taxa de erro do classificador resultante.

Em nosso trabalho, dado a restrição imposta pelo número reduzido de exemplos a serem fornecidos ao indutor, a realização desta etapa deve compor uma etapa dos trabalhos futuros, previstos nesta tese.

Análise Exploratória dos Dados e Formulação de Hipóteses

Segundo Fayyad & Piatetsky-Shapiro & Smyth (1996), antes de selecionar algum método para a busca de padrões nos dados, precisamos analisar que modelos e parâmetros podem ser apropriados (p. ex., modelos voltados a dados categóricos são diferentes dos modelos de vetores sobre valores reais). Além disso, é necessário encontrar um método de MD que atenda os objetivos do processo KDD sendo executado (p. ex., o usuário pode estar interessado ou na compreensão do modelo, ou na sua capacidade de predição).

No atual estágio deste estudo, a compreensão do modelo é fundamental, especialmente para que os psicólogos cognitivos e os educadores o interpretem e auxiliem na avaliação e consolidação do conhecimento descoberto. Considerando que não dispúnhamos de hipóteses *a priori* sobre as trajetórias de aprendizagem das classes de ECA sendo modeladas, consumimos um grande esforço na realização desta etapa do processo KDD, apresentada em detalhe no Capítulo 6.

Mineração de Dados

Os principais objetivos em MD, na prática, tende a ser: *predição* e *descrição*. A *predição* envolve utilizar algumas variáveis ou campos da base de dados para prever valores desconhecidos ou futuros de outras variáveis de interesse. A *descrição* preocupa-se em encontrar um padrão que explique, de forma compreensível, o comportamento dos dados. Em um contexto KDD, a *descrição* tende a ser mais importante que a *predição* (FAYYAD & PIATETSKY-SHAPIRO & SMYTH, 1996).

Em um processo KDD, o componente MD freqüentemente envolve a aplicação de repetidas iterações de um método MD particular, visando encontrar um *padrão* que represente o comportamento dos dados. Neste contexto, um *padrão* pode ser pensado como uma instância de um *modelo*. Por exemplo, $f(x) = 3x^2 + x$ é um padrão, enquanto que $f(x) = ax^2 + bx$ é considerado um modelo.

Basicamente, existem dois formalismos matemáticos usados para representar o modelo de conhecimento gerado nesta etapa: *estatístico* e *lógico*. A abordagem *estatística* permite efeitos não-determinísticos; ao passo que a abordagem *lógica* é puramente determinística. A abordagem estatística é a abordagem mais usada na prática, especialmente pela presença da incerteza no processo de geração dos dados no mundo real.

A fase de mineração de dados envolve decidir quais algoritmos serão aplicados aos dados para procurar padrões (FAYYAD & PIATETSKY-SHAPIRO & SMYTH, 1996). Nesta fase, pode-se utilizar algoritmos provenientes de diversas áreas de conhecimento, tais como: Aprendizado de Máquina, Estatística, Redes Neurais e Banco de Dados. Esta fase também inclui decidir quais modelos e parâmetros podem ser apropriados (i.é, modelo para dados nominais são diferentes dos modelos sobre vetores com valores reais), e que melhor atendem as necessidades do processo KDD (i.é, a prioridade pode estar ou na compreensão do modelo, ou no seu poder preditivo).

Em um ambiente de aprendizagem na Web, é necessário resumir *tendências* e *padrões* que possam ser interpretados pelos educadores que estão disponibilizando cursos remotos (ZAIANE, 2001). Hoje em dia, a maioria dos métodos de MD foi desenvolvido para outras áreas, com objetivos diversos da área educacional. Mesmo assim, esses métodos são gerais o suficiente, de modo que os Sistemas Educacionais podem se beneficiar deles.

A seguir apresentamos uma breve descrição sobre os principais métodos usados em MD.

- Classificação e regressão

A *classificação* corresponde a uma função de aprendizagem que mapeia (classifica) um item de dado em uma das diversas classes pré-definidas. A *regressão* é uma função de aprendizagem que mapeia um item de dado a uma variável preditiva com valor real. Por exemplo, estimar a probabilidade de que um paciente morra dado o resultado de um conjunto de exames.

- Clusterização

A *clusterização* corresponde a uma tarefa descritiva comum, onde se busca identificar um conjunto finito de categorias ou *clusters* para descrever os dados. As categorias podem ser mutuamente exclusivas e exaustivas ou consistir de uma representação rica tal como uma hierarquia ou categorias sobrepostas.

- Sumarização

A *sumarização* envolve métodos para encontrar uma descrição compacta para um subconjunto de dados. Um exemplo simples disto corresponde a tabulação da média e desvio padrão de todos os atributos. Esta técnica freqüentemente é aplicada em análises de dados exploratória e interativa e na geração automática de relatórios.

- Modelagem de dependências

A *modelagem de dependência* consiste em encontrar um modelo que descreva as dependências significantes entre as variáveis. Existem dois níveis de dependência: nível *estrutural* e nível *quantitativo*. O nível *estrutural* especifica, freqüentemente através de um gráfico, quais atributos são localmente dependentes um do outro. O nível *quantitativo* especifica a força da dependência através de alguma escala numérica. Um exemplo típico são as Redes Bayesianas de crença.

- Mudança e detecção de desvios

A mudança e detecção de desvio enfocam a descoberta das modificações mais significativas nos dados a partir de valores normativos ou previamente medidos.

Um algoritmo de MD possui três componentes básicos: (1) *modelo de representação*; (2) *modelo de avaliação*; e (3) *método de busca*. O *modelo de representação* é a linguagem usada para descrever os padrões encontrados. O *modelo de avaliação* corresponde a uma afirmação quantitativa de quão bem um padrão particular (modelo e seus parâmetros) se ajustam aos objetivos do processo KDD. Por exemplo, um modelo preditivo freqüentemente é julgado pela precisão da predição empírica em algum conjunto de teste. Um modelo descritivo pode ser avaliado através das dimensões da precisão preditiva, novidade, utilidade e capacidade de compreensão do modelo.

O *método de busca* consiste de dois componentes: (1) *busca de parâmetros*; e (2) *busca do modelo*. Na *busca de parâmetros*, o algoritmo de MD deve procurar por aqueles parâmetros que otimizam o critério do modelo de avaliação nos dados observados e um modelo fixo de representação. A *busca do modelo* ocorre como um laço sobre o método de busca de parâmetro: a representação do modelo é modificada tal que uma família de modelos é considerada.

Avaliação e interpretação de resultados

Esta fase é a fase da interpretação dos padrões minerados. É possível que, durante esta etapa do processo de descoberta de conhecimento, seja necessário retornar a

alguma das etapas anteriores para, iterativamente, tentar melhorar o modelo obtido. Esta fase também envolve a visualização dos padrões extraídos e dos modelos, ou a visualização dos dados a partir dos quais os modelos foram extraídos.

Consolidação do conhecimento descoberto

Nesta fase o conhecimento extraído pode ser integrado ao sistema ao qual ele se destina, ou simplesmente documentado e publicado as partes interessadas. Também nesta fase do processo pode ser interessante verificar e resolver possíveis conflitos com crenças anteriores sobre o conhecimento sob investigação.

3.7 Trabalhos Relacionados

Sob o enfoque dos Sistemas Tutores Inteligentes e dos Sistemas Hiperfídia Adaptativos, são poucos aqueles sistemas que implementam características individuais do aluno tais como: estilo cognitivo e de aprendizagem. De acordo com o levantamento realizado por Bajraktarevic & Hall & Fullick (2003), os sistemas SHA encontrados, que adotaram essa abordagem foram: INSPIRE (GRIGORIADOU et al., 2001), CS388 (CARVER et al., 1996), RAPITS (WOODS & WARREN, 1996) e AEC-ES (TRIANTAFILLOU et al., 2002).

Por exemplo, o sistema INSPIRE adotou a Teoria de Kolb, das experiências de aprendizagem, que reconhece quatro diferentes estilos de aprendizagem: os *ativistas*, os *pragmáticos*, aqueles com tendência à *reflexão* e os *teoristas*. O modelo do aluno é composto de duas partes: informações gerais (idade, sexo) e nível de conhecimento atual na unidade sendo estudada. As lições são divididas em níveis e são geradas dinamicamente. Os seus autores usam técnicas de *apresentação adaptativa*, em diferentes seqüências de apresentação. Os elementos dos estilos de aprendizagem aparecem, ou não, dentro de uma lição. Técnicas de navegação adaptativa tais como *anotação de links* na área navegacional do sistema é utilizada. O sistema RAPITS é um sistema de ensino adaptativo que compara o modelo do aluno com o conhecimento do domínio e que, automaticamente, pode modificar o estilo de apresentação ao aluno. O permite que o aluno percorra as lições *seqüencialmente* ou que ele prossiga no curso hiperfídia de modo não linear. O sistema AEC-ES é um sistema educacional adaptativo baseado no estilo cognitivo do aluno, através das dimensões dependência/independência de área. Neste sistema são disponibilizadas ferramentas de suporte navegacional tais como: mapas conceituais, caminhos gráficos, organizadores prévios, assim como são utilizadas técnicas de *apresentação adaptativa*. Os alunos são contemplados com estratégias instrucionais que melhor se ajustam ao seu estilo cognitivo preferencial, com a opção de mudá-la.

Além dos sistemas acima mencionados, ainda citamos os protótipos EDUCE (KELLY & TANGNEY, 2002) e I-Help (BULL et al., 2001). O tutor EDUCE incorpora ao modelo do aluno duas características individuais: (i) tipo de inteligência, de acordo com a classificação das *Inteligências Múltiplas* de Gardner; e (ii) objetivo de aprendizagem, segundo a classificação de Bloom. Neste tutor, estas características do aluno são inferidas a partir das interações deste com o sistema. O *monitor* das ações do aluno observa, monitora e coordena todo o *feedback* dado pelo aluno na forma dos links ativados, botões pressionados e textos digitado. O tutor EDUCE realiza a adaptação da apresentação ao nível dos conteúdos e como suporte à navegação, ao nível de *links*. A primeira forma inclui apresentações textuais, multimídia, etc., enquanto que o suporte à

navegação inclui guia direto e anotação de *links*. O desenvolvimento das habilidades cognitivas é estimulado através das formas de apresentação dos conteúdos.

O Sistema de Ajuda Inteligente – I-Help – foi projetado visando a sua utilização em um ambiente de ensino e aprendizagem. Nosso interesse neste trabalho refere-se à utilização do estilo cognitivo do aluno como uma das fontes de informação para que o sistema selecione o colega-ajudante apropriado. O sistema I-Help reconhece dois papéis para os alunos cadastrados: o ajudante e o ajudado. O processo de seleção baseia-se nos critérios definidos tanto pelo aluno que efetuará a ajuda, quanto por aquele que a solicita. Por exemplo, como ajudante, cada aluno define suas características, tais como: número máximo de ajudas simultâneas, assuntos de seu interesse, lista dos alunos que ele se dispõe a ajudar, etc. Como ajudado, o aluno pode definir: a lista dos alunos que ele gostaria que o ajudassem, a lista daqueles que conhecem bastante um determinado conjunto de tópicos, a lista daqueles que tem afinidade com o seu estilo de pensar, etc.

Os estilos cognitivos considerados no I-Help são: holista-analítico e verbal-visual, segundo a classificação de Riding e Cheema, citados por Bull et al. (2001). A classificação do aluno segundo estes estilos é realizada a partir de um questionário muito simplificado. Esta característica do aluno pode ou não ser relevante no momento da seleção do colega que irá efetuar a ajuda. Isto irá depender dos critérios especificados pelo aluno que recebe a ajuda, em relação aos que poderão ajudá-lo.

Entre os trabalhos que enfocaram o uso de técnicas de aprendizagem de máquina na modelagem do aluno citamos: MANIC (STERN & WOOLF, 2000), CAPIT (MAYO & MITROVIC, 2000) e CLARISSE (EÏMEUR et al., 2002). O sistema MANIC (*Multimedia Asynchronous Networked Individualized Courseware*) modela duas características do aluno para realizar a adaptação dos conteúdos: *nível de dificuldade* e *estilo de aprendizagem* de sua preferência. A primeira característica é identificada a partir de um pré-teste e serve para o sistema identificar *o quanto* o aluno conhece sobre o conteúdo a ser estudado. A outra é determinada através de um classificador Bayesiano ingênuo (*Naive Bayes Classifier*) e serve para o sistema identificar *o que* o aluno quer, levando em consideração *como* ele gosta de estudar. Os conteúdos pedagógicos são desenvolvidos em diferentes versões para um mesmo conceito. Essas diferentes versões possuem diferentes níveis de dificuldade e diferentes estilos de aprendizagem, de modo que o sistema possa adaptá-los ao perfil do aluno.

O objetivo do sistema MANIC é ‘aprender’ sobre as preferências do aluno a partir da observação de suas interações com o sistema. O classificador Bayesiano ingênuo (CBI), que tem uma abordagem probabilística, pode ser interpretado como um caso particular de uma Rede Bayesiana de probabilidades, usado para fazer *classificação*. No caso particular, temos uma *variável-classe* e um conjunto de *variáveis-atributo*, consideradas consequência da *variável-classe*. Um CBI envolve duas etapas de aprendizagem. Na primeira delas, são calculadas as probabilidades a priori de todas as variáveis e as probabilidades condicionais das *variáveis-atributo*, com base nos dados de treinamento. O conjunto estas estimativas corresponde à hipótese a ser aprendida. Essa hipótese é então usada para classificar cada uma das novas instâncias, na segunda etapa do processo de aprendizagem.

No ambiente MANIC, a aprendizagem de máquina é usada para prever o objeto de conteúdo que o aluno irá desejar. Um objeto de conteúdo tem a ele associado um conjunto de características tais como: *tipo_mídia* – TM (i.é, gráfico ou texto), *tipo_instrucional* – TI (i.é, explicação, exemplo, descrição e definição), *nível_dificuldade* – ND (i.é, fácil, médio ou difícil) e *desejado_pelo_aluno* – DA (i.é, sim, não). Para determinar se o objeto de conteúdo é desejado pelo aluno, o tutor

observa a reação do aluno em relação ao objeto. Cada objeto que é apresentado tem a opção de ser ocultado pelo aluno, assim como aqueles que não são apresentados têm links que os permitem ser mostrados. Se o objeto foi apresentado e não foi ocultado pelo aluno, ou se o objeto não foi inicialmente apresentado, mas foi solicitado, então o objeto é considerado como desejado pelo aluno. Um objeto não é desejado pelo aluno quando, ele foi apresentado ao aluno, mas este o ocultou, ou o *link* correspondente ao objeto não foi usado.

O sistema tutor inteligente CAPIT (*Capitalisation And Punctuation Intelligent Tutor*) tem o propósito de ensinar regras de pontuação e uso de caracteres maiúsculo, na língua inglesa, para crianças entre 8 e 10 anos. Nesse tutor, a modelagem do aluno foi realizada através de uma Rede Bayesiana de Crença (RBC). A RBC foi construída com o objetivo de prever o desempenho de uma criança em um novo problema, considerando o desempenho passado da criança. O modelo de inferência é usado para selecionar o problema mais apropriado para a criança, de modo que ela se sinta desafiada, porém não desencorajada. O modelo foi induzido a partir dos dados gerados pelo uso do sistema por uma classe de 28 alunos. Primeiramente, o projetista especificou diferentes modelos causais, a partir de seus pressupostos a respeito dos possíveis fatores que poderiam, ou não, ser relevantes. A decisão sobre um dos modelos baseou-se em testes de significância estatística. Os parâmetros numéricos emergiram a partir dos dados.

A ferramenta CLARISSE (*Clusters And Rules ISSuEd*) implementa um método de aprendizagem de máquina, que corresponde a categorização de itens de dados. Diferentemente das técnicas de classificação, na categorização (ou *clusterização*) as categorias não são conhecidas *a priori*. Elas são reveladas durante o processo de geração. O trabalho realizado pela ferramenta consiste em, recursivamente, dividir um conjunto inicial de itens e construir uma árvore de decisão, a qual será usada para identificar as categorias. A ferramenta CLARISSE foi projetada para inicializar o modelo do conhecimento do aluno (*o que* e *o quanto* ele conhece sobre o assunto a ser estudado), e deverá ser usada pelo sistema tutor inteligente chamado QUANTI.

Finalmente, sob o enfoque da modelagem computacional voltada à descoberta de padrões de comportamento na Web, mencionamos os seguintes trabalhos: Spiliopoulou (1999), Levene (2003), e Zaïne & Luo (2001).

O trabalho de Spiliopoulou iniciou pelo levantamento e pela modelagem formal de padrões de navegação genéricos na Web. O modelo formal proposto por este autor foi baseado na noção de *seqüência genérica* e em um *padrão de variáveis* (na língua inglesa *template*). A partir do modelo genérico, a investigação seguiu enfocando a questão de como descobrir esses padrões usando técnicas de mineração de dados. A técnica de mineração de dados proposta tenta descobrir as *seqüências genéricas* de acordo com o padrão das variáveis e de modo que, o modelo gerado, satisfaça determinados limiares estatísticos. Este autor modelou as seqüências de navegação como uma *árvore de agregação*. Neste contexto, uma árvore de agregação é uma representação em árvore, de múltiplas seqüências (ramificações), onde os prefixos comuns são fundidos.

Levene modelou o comportamento do usuário na Web através do conceito de *visão web* (na língua inglesa *web view*). Para este autor, uma *visão web* é uma coleção de trilhas relevantes (ou seqüências de páginas web repetidas pelo usuário). Formalmente, uma *visão web* é considerada um grafo direcionado acíclico, induzido por uma coleção de trilhas. Uma trilha é relevante em relação à frequência com que o usuário a utiliza. Levene utilizou cadeias de Markov para construir uma *visão web*.

À semelhança dos trabalhos de mineração de dados desenvolvidos com sucesso no contexto do *e-commerce*, Zaïne & Luo (2001) propuseram um *framework* voltado à mineração de dados no contexto dos sistemas de aprendizagem *on-line*. A idéia por trás desse *framework* era a de permitir que os seus usuários (educadores) pudessem expressar restrições aos dados obtidos e aos estágios de transformação desses, assim como pudessem expressar descoberta de padrões e etapas de análise. Deste modo, seria permitido aos educadores moldarem o processo de mineração de dados as suas necessidades e tarefas a realizar. O *framework* de Zaïne & Lu integra três etapas: (i) obtenção de dados e pré-processamento, (ii) descoberta de padrões; e, (iii) análise dos padrões obtidos. Em qualquer uma das fases, deverá ser permitido aos educadores expressarem suas necessidades através da especificação de restrições e filtros. A definição de filtros durante a fase de pré-processamento dos dados pode reduzir consideravelmente o espaço de busca, assim como a colocação de restrições durante a fase de mineração não somente acelera o processo, como também controla os padrões descobertos. Na fase de avaliação, as restrições podem auxiliar na análise de extensos conjuntos de padrões extraídos.

Além disso, os autores ainda previram que o educador também poderia utilizar filtros na fase de pré-processamento para selecionar um aluno ou um grupo de alunos, selecionar um período de tempo e/ou um subconjunto de páginas Web, com o objetivo de fixar sua atenção nas tarefas de aprendizagem e atividades a serem avaliadas. Além disso, os educadores ainda poderiam definir sua interpretação da sessão do (s) aluno (s) e da seqüência de ‘clics’ realizada por eles.

Para a descoberta de padrões, Zaïne & Luo selecionaram diversos algoritmos, incluindo: mineração de regras de associação, mineração de padrões freqüentes entre as sessões de estudo, mineração de padrões freqüentes durante uma sessão de estudo, etc. em relação a última fase, o objetivo foi o de facilitar a interpretação dos padrões descobertos pelos tomadores de decisão. Neste sentido, os autores implementaram gráficos intuitivos e tabelas. O *framework* proposto é aberto no sentido de que permite a adição de novos algoritmos de mineração a qualquer momento.

Entre os algoritmos inicialmente implementados, foram utilizadas regras de associação para a descoberta de correlações entre as atividades de aprendizagem on-line, pelo menos duas variações de algoritmos para a mineração de padrões seqüenciais, dentro de uma sessão de aprendizagem, ou entre sessões, técnicas de clusterização para agrupar os alunos com comportamentos de acesso às páginas Web similares.

3.8 Considerações Finais

Na seção anterior, descrevemos diversos estudos relacionados com o foco desta tese, ou seja, a modelagem do aluno (ou usuário) em STIs e em SHAs, especialmente sobre aqueles sistemas que realizam a aquisição de conhecimento sobre as características do aluno sendo modeladas através do uso de uma abordagem centrada nos dados. Além disso, considerando o nosso interesse em ambientes adaptativo de ensino e aprendizagem na Web, também enfocamos, em nossa revisão bibliográfica, os aspectos relacionados à modelagem do *comportamento* do aluno (ou usuário) durante suas interações com o ambiente considerado.

As considerações que fizemos dizem respeito às tendências atuais observadas na modelagem do aluno (ou o usuário). Comparando as características do usuário modeladas nos SHA (mencionadas por Brusilovsky (1995)) com os estudos atuais, verificamos uma forte tendência dos sistemas em modelar características individuais tais

como: aspectos de *personalidade, emoção e afetividade, estilos de aprendizagem e estilos cognitivos*, etc., de forma complementar aos dados do usuário até então considerados. O trabalho para modelar computacionalmente essas características tem demandado um esforço de equipes multidisciplinares, formada especialmente por psicólogos e pedagogos, em parceria com especialistas do domínio e em Sistemas de Informação, com a abordagem da IA.

Também observamos o atual esforço de pesquisadores, especialmente da área de MD, em explorar as informações disponibilizadas em um arquivo de *log* de um servidor Web. Essas investigações têm permitido a extração de conhecimento a respeito do comportamento *real* do usuário ao navegar em um *site* na Web. Além de oportunizar o *feedback* de como o *site* é utilizado, também permite a análise e interpretação do comportamento *real* do usuário.

A maioria dos métodos que tentam avaliar o comportamento navegacional e/ou os interesses dos usuários na Web contabilizam a frequência com que as páginas são visitadas. Esse tipo de informação não é suficiente para a identificação de padrões de uso na Web (ZAIÑE & XIN & HAN, 1998). Mesmo não contendo informações adequadas para a realização de uma análise, ainda assim um arquivo de *log* de um servidor Web contém dados úteis a partir dos quais um sistema bem planejado de mineração de dados pode ser desenvolvido, com o objetivo de descobrir informações interessantes.

Em nosso Projeto de pesquisa, a principal motivação em investigar o comportamento das classes de ECA em um ambiente de aprendizagem na Web visou a automatização do diagnóstico do ECA do aluno remoto, através da análise de suas interações com o ambiente de ensino e aprendizagem (*Trajectoria de Aprendizagem*). Portanto, os propósitos desta tese estão alinhados com as tendências atuais de modelagem do aluno em um ambiente adaptativo de ensino e aprendizagem na Web. O esforço deste trabalho certamente passa pelas diversas etapas de um processo KDD, desde a limpeza e transformação dos dados no arquivo de *log*, até a indução dos atributos e comportamento, típicos de cada uma das classes de ECA consideradas, e essenciais à realização do diagnóstico *on-line* do ECA do aluno remoto.

4 A PESQUISA

Para alcançar os objetivos propostos, esta investigação foi desenvolvida em duas etapas. A primeira delas correspondeu à geração das classes de ECA a partir de uma avaliação da população-alvo. A segunda fase correspondeu ao estudo das TAs e geração dos atributos associados a cada uma das classes de ECA, conforme é apresentado a seguir.

4.1 Delineamento da Pesquisa

O estudo está baseado em uma pesquisa de natureza quase-experimental, com análises *quantitativa* e *qualitativa*, e com *pós-teste* somente (Figura 4.1).

Fase 1: Geração das classes de ECA		
Fase 2: Tratamento – Módulo de Ensino Experimental TDMA		
Classes de ECA experimentais: <ul style="list-style-type: none"> • Analógico-Analítico • Concreto-Genérico • Dedutivo-Avaliativo • Analítico-Sintético-Avaliativo • Relacional-Sintético 	Dimensões Avaliadas	
	Indicadores de Comportamento Navegacional	Indicadores de Tempo de Permanência
	Medidas	Medidas
Fase 3: Análises		

Figura 4.1: Delineamento da pesquisa

A variável independente foi o *Estilo Cognitivo de Aprendizagem* (ECA). As medidas corresponderam aos resultados das variáveis *dependentes*, isto é, corresponderam aos indicadores do comportamento navegacional e dos tempos de permanência nas páginas Web do módulo de ensino. O tratamento correspondeu à aplicação do módulo de ensino experimental – TDMA – especialmente projetado com esta finalidade, e descrito em detalhe no Capítulo 5.

A primeira fase, ou fase de *Geração das Classes de ECA experimentais*, foi realizada durante o andamento do Projeto Tapejara pela equipe de psicólogos, parceira no Projeto. Os principais resultados desta fase foram documentados e descritos no contexto desta tese (Capítulo 5). As segunda e terceira fases foram totalmente desenvolvidas nesta tese e estão descritas no Capítulo 6.

4.2 Caracterização dos Sujeitos da Amostra

Conforme mostra a Tabela 4.1, a amostra era composta de 35 sujeitos, distribuídos de forma não igualitária devido à dificuldade circunstancial de disponibilidade destes

durante a execução do Projeto. A média etária predominante da amostra era formada por sujeitos com idade acima dos 40 anos, à exceção dos AA, cuja média etária era formada por sujeitos com idade em torno dos 30 anos. Sobre o grau de instrução, em torno de 50% dos sujeitos estavam no 2º grau (incompleto ou completo) e os restantes estavam no 3º grau. Os sujeitos da amostra eram predominantemente do sexo masculino.

Tabela 4.1: Perfil dos sujeitos da amostra

	AA	CG	DA	ASA	RS	Totais	
Nº de Sujeitos	10	7	8	7	3	35	
Idade Média	33 anos	45 anos	46 anos	44 anos	40 anos	41 anos	
Grau de Instrução	1	-	14,29%	-	-	-	2,86%
	2	40%	42,86	50%	42,86%	66,67%	45,71%
	3	20%	14,29%	-	14,29%	-	11,43%
	4	40%	28,58%	50%	42,86%	33,33%	40,00%
Sexo	1	100%	85,71%	100%	85,71%	100%	94,29%
	2	-	14,29%	-	14,29%	-	5,71%

Estilo Cognitivo: AA - Analógico-Analítico; CG - Concreto-Genérico; DA - Dedutivo-Avaliativo; ASA – Analítico-Sintético-Avaliativo; RS - Relacional-Sintético. Grau de Instrução: 1 – 2º Grau Incompleto; 2 – 2º Grau Completo; 3 – 3º Grau Incompleto; 4 – 3º Grau Completo. Sexo: 1 – Masculino; 2 - Feminino

4.3 Variáveis e suas Medidas

O comportamento navegacional das classes de ECA foi monitorado através dos indicadores correspondentes à *freqüência relativa de acesso* às páginas Web que compunham o material pedagógico e do respectivo *tempo relativo de permanência* nestas. A justificativa para o uso da *freqüência* e *tempo relativos* era poder comparar estas medidas, intra e entre classes de ECA. Sobre esta questão, cabe lembrar que, ao utilizar o módulo de ensino, cada participante foi instruído para que usasse o material instrucional da forma que ele se sentisse mais confortável. Conseqüentemente, ao realizar a sua TA, cada participante definiu a seqüência de acesso aos recursos didáticos, assim como visitou um número aleatório de páginas Web do curso.

A partir dos dados registrados no arquivo de *log*, i.e., o número de identificação do aluno, data e hora do acesso e o tipo da página Web visitada (ou código de identificação do recurso didático e forma de apresentação sendo visitada), foi extraído um conjunto de *indicadores* do comportamento e do desempenho dos estilos cognitivos durante o experimento (Tabela 4.2 abaixo).

Neste estudo, os indicadores correspondentes à *freqüência relativa de acesso* indicam a preferência dos estilos pelos recursos didáticos e formas de apresentação disponibilizados no módulo de ensino experimental. Os indicadores correspondentes aos *tempos de permanência* indicam a velocidade de processamento dos estilos ao navegarem pelos recursos didáticos e formas de apresentação. O *desempenho* indica o esforço realizado pelo aprendiz na execução da avaliação final (nº de avaliações realizadas) e o resultado obtido (aprovado ou reprovado). A análise de desempenho está fora do escopo desta tese.

Tabela 4.2: Indicadores do funcionamento dos ECA e suas medidas

Indicadores de Comportamento Navegacional	Total de páginas visitadas	Somatório do total geral de páginas visitadas por um aluno Somatório do total de páginas de ‘Conceitos’ visitadas por um aluno Somatório do total de páginas de ‘Exercício’ visitadas por um aluno Somatório do total de páginas de ‘Exemplos’ visitadas por um aluno
	Frequência relativa de acesso aos ‘Recursos Didáticos’	Percentual de páginas de ‘conceitos’ visitadas sobre o total geral Percentual de páginas de ‘exercícios’ visitadas sobre o total geral Percentual de páginas de ‘exemplos’ visitadas sobre o total geral Percentual de páginas de ‘revisão’ visitadas sobre o total geral
	Frequência relativa de acesso às ‘Formas de apresentação’	Percentual de páginas de cada uma das formas de apresentação de ‘conceitos’ visitadas sobre o total de páginas de ‘conceitos’ visitadas Percentual de páginas de cada uma das formas de apresentação de ‘exercícios’ visitadas sobre o total de páginas de ‘exercícios’ visitadas Percentual de páginas de cada uma das formas de apresentação de ‘exemplos’ visitadas sobre o total de páginas de ‘exemplos’ visitadas
Indicadores de Tempo de Permanência	Tempo total de permanência	Somatório do tempo total de permanência por aluno Somatório do tempo de permanência nas páginas de ‘conceitos’ visitadas Somatório do tempo de permanência nas páginas de ‘exercícios’ visitadas Somatório do tempo de permanência nas páginas de ‘exemplos’ visitadas
	Tempo de permanência nos ‘Recursos Didáticos’	Percentual de tempo gasto em páginas de ‘conceitos’ sobre o tempo total de permanência no módulo de ensino TDMA Percentual de tempo gasto em páginas de ‘exercícios’ sobre o tempo total de permanência no módulo de ensino TDMA Percentual de tempo gasto em páginas de ‘exemplos’ sobre o tempo total de permanência no módulo de ensino TDMA Percentual de tempo gasto em páginas de ‘revisão’ sobre o tempo total de permanência no módulo de ensino TDMA Percentual de tempo gasto na ‘avaliação final’ sobre o tempo total de permanência no módulo de ensino TDMA
	Tempo de permanência nas ‘Formas de Apresentação’	Percentual de tempo gasto em cada forma de apresentação de ‘conceitos’ visitadas, sobre o total de tempo gasto em páginas de ‘conceitos’ visitadas, sobre o total de tempo gasto em páginas de ‘exercícios’ visitadas, sobre o total de tempo gasto em páginas de ‘exercícios’ visitadas, sobre o total de tempo gasto em páginas de ‘exemplos’ visitadas, sobre o total de tempo gasto em páginas de ‘exemplos’ visitadas
Desempenho	Total de Provas Realizadas	O aprendiz tinha a possibilidade de executar até três diferentes avaliações ou até que ele alcançasse o escore mínimo estabelecido.
	Indicador de Sucesso	(0 – abaixo do percentual mínimo de acertos; 1 – igual ou acima do percentual mínimo)

4.4 Questões de Pesquisa

Considerando a nossa crença de que o estilo cognitivo de aprendizagem determina diferentes formas de abordar novas informações durante um processo de aprendizagem e que, o sucesso do aluno está relacionado com a forma como ele aprende, colocamos três questões de pesquisa, as quais enfocam a análise das interações das classes de ECA com o módulo de ensino experimental, especificamente desenvolvido com esta finalidade.

1. Como automatizar o diagnóstico *on-line* do *Estilo Cognitivo de Aprendizagem* do aluno a partir da observação e análise da sua trajetória de aprendizagem em um *Ambiente de Ensino e Aprendizagem na Web*?
2. Quais os indicadores (ou parâmetros) de uma *trajetória de aprendizagem* que melhor discriminam a trajetória típica de cada uma das classes de ECA consideradas?
3. Como automatizar a aquisição do conhecimento necessário para realizar o diagnóstico *on-line* (ou classificação) do ECA do aluno remoto?

5 O PROJETO TAPEJARA

Conforme mencionado anteriormente, O projeto Tapejara – Sistemas Inteligente de Ensino na Internet – em cujo contexto se insere esta tese, teve como meta buscar uma solução que contribuísse para minimizar o comprometimento psicopedagógico de um sistema de ensino e aprendizagem na Internet.

Sob o ponto de vista computacional, o Projeto Tapejara teve como principal objetivo implementar um ambiente inteligente de ensino e aprendizagem na Web. Os principais requisitos para a implementação deste ambiente incluíam o projeto e construção de uma arquitetura computacional que suportasse o reconhecimento dos padrões de comportamento dos estilos cognitivos do aluno, baseado em suas interações com o ambiente (diagnóstico cognitivo) e, com base neste conhecimento suportasse a realização da adaptação da instrução ao perfil cognitivo deste aluno.

A metodologia adotada no projeto e construção do sistema previu seis etapas de investigação, quais sejam:

1. Identificação das dimensões cognitivas (ou classes) de Estilos Cognitivos de Aprendizagem em uma amostra da população-alvo (funcionários da empresa de telecomunicações, parceira no projeto).
2. Projeto e construção do módulo de ensino experimental, na área das telecomunicações, com o objetivo de analisar o comportamento cognitivo das classes de estilos cognitivos consideradas.
3. Estudo das trajetórias de aprendizagem por ECA.
4. Modelagem do ECA do aluno.
5. Modelagem do agente artificial, responsável pelo diagnóstico cognitivo do aluno.
6. Modelagem do agente artificial pedagógico, responsável pela adaptação da instrução propriamente dita, com base na utilização de estratégias e táticas psicopedagógicas, adequadas a cada perfil cognitivo.

As etapas (1), (2) e parte da (3), foram desenvolvidas durante o prazo de vigência do Projeto Tapejara e estão publicadas em: (SOUTO et al., 2000), (SOUTO et al., 2001), (BICA et al., 2001), (SOUTO et al., 2002a), (SOUTO et al., 2002b), e (SOUTO et al., 2002c). O foco da tese em andamento inclui a complementação da etapa (3) e a execução das etapas (4) e (5).

A compreensão desta tese passa pela compreensão das etapas anteriores, desenvolvidas durante o projeto. Com este objetivo apresentamos, neste Capítulo, uma descrição sucinta das etapas (1) e (2).

5.1 Identificação das Classes de Estilos Cognitivos de Aprendizagem

Conforme a metodologia adotada e anteriormente mencionada, nesta seção apresentamos um breve relato de como a etapa (i) foi trabalhada, ou seja, como os estilos cognitivos de aprendizagem foram gerados a partir da aplicação do “Teste Ross dos Processos Cognitivos” em uma amostra de 231 sujeitos, constituída por técnicos e engenheiros da empresa de Telecomunicações, usuários potenciais dos Cursos de Telecomunicações e SDH.

5.1.1 Análise dos Dados Oriundos da Aplicação do Teste Ross

Conforme apresentado em (MADEIRA et al., 2000b), o Teste Ross foi aplicado em uma amostra de 231 sujeitos, selecionados a partir de uma população composta por 1121 sujeitos. A análise de dados ocorreu em três momentos. No primeiro deles, o Teste Ross foi avaliado a partir de três níveis de validação: (i) considerando os 105 itens do teste, o Alfa de Crombach = 0,923; (ii) considerando os oito Processos Cognitivos avaliados, o Alfa de Crombach = 0,8429; e, considerando as três Habilidades Cognitivas avaliadas, o Alfa de Crombach = 0,8364. Estes resultados mostraram que o Teste se mostrou consistente e verdadeiro. Na validação do Teste Ross em relação a população alvo, a principal adaptação consistiu na classificação dos sujeitos de acordo com os seus desempenhos nas diferentes seções do teste, ao invés de considerar o número de itens.

Nos segundo e terceiro momentos, a análise dos dados continuou, respectivamente, com as *análise fatorial* e *análise de cluster*. A partir da análise fatorial foram analisados os fatores (i.e. os processos e habilidades cognitivas consideradas no Teste Ross) que explicavam a variância dos resultados, assim como a especificação dos fatores e agrupamento dos dados por fator. A Figura 5.1 mostra o resultado desta análise.

<p>Habilidade 1 (Análise) = 75,37 % da variância total</p>	<p><u>Processos</u></p> <ul style="list-style-type: none"> • Analogias (14 itens) – 48,08 % • Premissas ausentes (8 itens) – 8,72 % • Análise de info.relev.e Irrelev. (15 itens) – 9,42 %
<p>Habilidade 2 (Síntese) = 10,60 % da variância total</p>	<p><u>Processos</u></p> <ul style="list-style-type: none"> • Relações abstratas (14 itens) – 7,11 % • Síntese seqüencial (10 itens) – 6,11 % • Análise de atributos (15 itens) – 4,82 %
<p>Habilidade 3 (Avaliação) = 14,03 % da variância total</p>	<p><u>Processos</u></p> <ul style="list-style-type: none"> • Raciocínio dedutivo (18 itens) – 9,90 % • Estratégias de questionam. (12 itens) - 5,82 %

Figura 5.1: Análise Fatorial: explicação da variância por habilidade cognitiva (MADEIRA et al., 2000)

Na análise de *cluster*, os sujeitos foram agrupados pela similaridade do seu nível de desempenho em cada processo e habilidade cognitiva. A Tabela 5.1 mostra os resultados das análises e apresenta as classes de ECAs identificadas, segundo os critérios mencionados (MADEIRA et al., 2000b).

Tabela 5.1: Classes de ECAs agrupadas por desempenho (4-5 superior, 3 médio, 1-2 inferior) (MADEIRA et al., 2000)

Classes de Estilos Cognitivos	Sujeitos	Amostra %	Habilidades Psicopedagógicas		
			Habilidade em Análise (73%)	Habilidade em Síntese (10,6%)	Habilidade em Avaliação (14,02%)
Analógico-Analítico	109	47,19	4 ou 5	-	-
Concreto-Genérico	60	25,97	1 ou 2	-	-
Dedutivo-Avaliativo	24	10,39	3	1, 2 ou 3	4 ou 5
Relacional-Sintético	07	3,03	3	4 ou 5	1, 2 ou 3
Estilo Analítico-Sintético-Avaliativo	31	13,42	3	1, 2, 3 e 4	1, 2, 3, 4 e 5

Os sujeitos avaliados com um nível ‘superior’ de desempenho na habilidade de análise foram classificados como pertencentes à classe dos *Analógico-Analíticos* (AA). Os sujeitos que foram avaliados com um nível ‘inferior’ de desempenho na habilidade de análise foram classificados como pertencentes à classe dos *Concreto-Genéricos* (CG). Os sujeitos que foram avaliados com um nível ‘superior’ na habilidade de avaliação, ‘médio-inferior’ na habilidade de síntese e ‘médio’ na habilidade de análise foram classificados como pertencentes à classe dos *Dedutivo-Avaliativos* (DA), e assim por diante.

O quinto grupo, denominado *Analítico-Sintético-Avaliativo* (ASA), mostrou-se muito heterogêneo, ou seja, não apresentou similaridade interna em relação ao desempenho nas habilidades e processos cognitivos avaliados pelo Teste Ross. Considerando o critério de agrupamento dos sujeitos, esta classe agregou os sujeitos que foram avaliados ou com um nível ‘médio’ na habilidade de análise, ou com um nível ‘médio-inferior’ na habilidade de síntese, ou com um nível ‘médio-superior’ na habilidade de avaliação.

5.1.2 Conceituando as Classes de ECA Geradas

O conceito de cada uma das classes de ECA utilizadas neste trabalho foi primeiramente apresentado em (MADEIRA et al., 2000). O trabalho de conceituação foi desenvolvido pela equipe de psicólogos, parceira no projeto Tapejara. Os conceitos foram inferidos a partir do desempenho dos sujeitos testados, nas habilidades cognitivas, advindas da taxionomia de objetivos educacionais de Bloom (BLOOM et al., 1972), e nos processos cognitivos, subjacentes a estas habilidades, avaliados no Teste Ross.

Analógico-Analítico

O estilo cognitivo de aprendizagem *Analógico-Analítico* refere-se aquele agrupamento de sujeitos que tende a buscar a aprendizagem de novas informações através da utilização de padrões de comparações com outros conhecimentos, previamente aprendidos. Para tanto, busca trabalhar com a informação em blocos, decompondo-a, com a finalidade de estabelecer relações análogas com outras partes de outros conhecimentos já armazenados.

Tipicamente, são sujeitos com elevada capacidade de realizar elaborações, ou seja, gerar conhecimentos novos (não fornecidos *a priori* no material didático), estabelecendo “pontes” com os conhecimentos anteriormente adquiridos. Assim sendo, tendem a possuir elevada capacidade e eficiência na compreensão das inter-relações entre várias idéias e, também, na capacidade de fazer generalizações. Pela sua

característica de realização de grande quantidade de elaboração, podem necessitar de um tempo maior para a aprendizagem, pois ao se defrontarem com uma nova informação, tendem a buscar uma considerável profundidade no assunto, através de reflexão intensa.

Concreto-Genérico

O estilo cognitivo de aprendizagem *Concreto-Genérico* refere-se aquele agrupamento de sujeitos que busca a aprendizagem de novas informações de forma linear e seqüencial, dando preferência às estratégias de memorização que utilizem “pistas” de recuperação baseadas em exemplos concretos. Para tanto, busca a trabalhar com a informação em sua totalidade (holisticamente), o que por vezes pode lhe dificultar a aprendizagem, fazendo com que busque sistematicamente a exemplificação para facilitar a memorização. Preza que se mostre a eles o que fazer, em etapas, possibilitando a sua prática da tarefa.

Tipicamente, são sujeitos que prestam atenção aos procedimentos e detalhes dos mesmos, podendo por vezes se perder nestes. A memória é uma de suas melhores habilidades intelectuais, embora corra o risco de não organizar bem as informações na memória. Isto pode ser um reflexo do fato destes sujeitos trabalharem pouco com abstração dos princípios e conceitos, principalmente aqueles que exijam maior grau de elaboração e abstração. Tendem a ser pragmáticos e cuidadosos na situação de aprendizagem. Os objetivos de aprendizagem, o critério de avaliação e *feedback* têm que ser claros para este estilo, porque assim ele pode trabalhar em prol dos objetivos.

Dedutivo-Avaliativo

O estilo cognitivo de aprendizagem *Dedutivo-Avaliativo* refere-se aquele agrupamento de sujeitos que busca a aprendizagem de novas informações através da identificação do padrão lógico, subjacente ao conteúdo sendo apresentado. Realiza análises exaustivas da coerência, validade e veracidade das informações. Para tanto, busca avaliar possíveis falácias lógicas na informação, agindo de forma sistemática e crítica.

Tipicamente, são sujeitos com elevada capacidade de trabalho e atenção, tendo grande prazer em encontrar explicações lógicas para os acontecimentos. Por serem sistemáticos, trabalham com método na busca da informação. Podem chegar a desconsiderar grande quantidade de exemplos concretos quando acreditam já terem compreendido o padrão lógico subjacente à nova informação. Por vezes podem se mostrar precipitados na compreensão da informação. A organização do material é crucial para este tipo de aprendiz.

Relacional-Sintético

O estilo cognitivo de aprendizagem *Relacional-Sintético* refere-se aquele agrupamento de sujeitos que busca a aprendizagem de novas informações através da reorganização das subpartes do conjunto de informações fornecidas em uma estrutura conceitual mais enxuta. Para tanto busca decompor a informação em conceitos, até unificá-los em um conceito integrador, mais abrangente e abstrato.

Tipicamente, são sujeitos com elevada capacidade de abstração e de geração de hipóteses sobre os fatores envolvidos num determinado tipo de conhecimento. Constantemente estão a revisar e reformular conceitos a partir da integração de novas informações relacionadas ao tema em questão. Tendem a ter facilidade de trabalhar mentalmente com imagens e apreciam o uso de diagramas, esquemas e

demonstrações. São especificamente eficientes na leitura de gráficos e mapas mentais. Aprendem melhor com abstrações e suas relações.

Analítico-Sintético-Avaliativo

Por inferência nossa, os sujeitos desta classe agregam características ou dos Analíticos, ou dos Sintéticos, ou dos Avaliativos.

5.2 Projeto e Construção do Módulo de Ensino Experimental

O módulo de ensino experimental TDMA, desenvolvido durante o Projeto Tapejara, teve a finalidade de ser utilizado como o instrumento para a análise do funcionamento cognitivo dos estilos cognitivos e suas preferências pedagógicas.

De acordo com as demandas de treinamento da empresa parceira no Projeto, foi selecionado o Curso de Telecomunicações como aquele a ser desenvolvido. O módulo experimental inicial escolhido foi o TDMA (na língua inglesa, *Time Division Multiplex Access*), que consiste na tecnologia básica da comunicação móvel, utilizada pela empresa. Este módulo foi desenvolvido por uma equipe multidisciplinar, ainda durante o desenvolvimento do Projeto Tapejara. Esta equipe incluiu profissionais das áreas da Psicologia, Pedagogia, projetistas Web, e um especialista na área de telecomunicações.

5.2.1 Requisitos do Módulo de Treinamento Experimental

O planejamento dos conteúdos deveria levar em consideração as características cognitivas dos estilos gerados a partir do público-alvo (seção 5.1.2) e os objetivos educacionais propostos pelo especialista. Adicionalmente, deveria ser considerado que os aprendizes tinham conhecimento prévio da tecnologia de *multiplexação* e familiaridade com a terminologia da área. O domínio de conhecimento do módulo experimental caracterizava-se por exigir do aprendiz o conhecimento de uma terminologia específica, com jargões comumente utilizados na língua inglesa e um número significativo de siglas.

5.2.2 Plano Pedagógico do Módulo de Ensino Experimental

Objetivos educacionais

- Compreender o conceito TDMA
- Compreender as aplicações do TDMA no acesso *Wireless*
- Compreender os componentes que fazem parte da arquitetura TDMA (ERB e Aparelho Móvel).
- Entender a organização das informações controle, sinalização usuário dentro dos slots de tempo do TDMA.
- Entender como o TDMA amplia a capacidade instalada de um sistema AMPS.

Heurísticas psicopedagógica consideradas

Com vistas a contemplar as necessidades psicopedagógicas das classes de estilos cognitivos, durante o planejamento do módulo de ensino experimental foram inferidas algumas heurísticas psicopedagógica, a partir da conceituação prévia dos estilos, as quais foram consideradas na formulação do material instrucional. A Tabela 5.2 abaixo resume estas heurísticas.

Modelo pedagógico

Os conteúdos do domínio foram projetados baseados na prática didática tradicional, ou seja, os conteúdos pedagógicos foram organizados e disponibilizados em quatro diferentes tipos de recursos didáticos: (a) conceitos; (b) exemplos; (c) exercícios e; (d) revisão. Para cada um dos recursos didáticos foi projetado e disponibilizado um conjunto de diferentes formas de apresentação, as quais incluíram formas *textuais*, *gráficas*, *esquemáticas* ou uma combinação destas (Tabela 5.3). Após a realização do módulo de ensino, ou seja, quando o aluno sentia-se apto, ele deveria executar uma avaliação final, a qual tinha como objetivo testar os conhecimentos adquiridos pelo aluno. Em relação à avaliação final, foi fixado o desempenho mínimo de 90%, i.e., o aluno deveria acertar 90% das questões da prova e, além disso, ele tinha até três chances (através da execução de três provas distintas) para alcançar os 90%.

Tabela 5.2: Os estilos cognitivos e as heurísticas psicopedagógicas

Estilo Cognitivo	Recursos Didáticos
Analógico-analítico	<ul style="list-style-type: none"> • Uso de conceitos e exemplos com textos e esquemas comparativos. • Esquemas com figuras comparativas, mesclando texto e imagem para facilitar o processo analítico e as relações análogas.
Dedutivo-avaliativo	<ul style="list-style-type: none"> • Utilização de perguntas proporcionando a busca de informações que permita ao aprendiz inferir um padrão lógico nas informações obtidas.
Relacional-sintético	<ul style="list-style-type: none"> • Conteúdo de forma sintética e esquemática. • Relacionar idéias, conceitos mais gerais e sintetizar as informações em um sistema lógico, facilitando a ordenação de idéias numa estrutura lógica, abstrata e integrada.
Concreto-genérico	<ul style="list-style-type: none"> • Exemplos concretos em linguagem simples, utilizando-se de figuras e diagramas que auxiliem na exemplificação. • Texto destacado para auxiliar a memorização. • Conteúdo deve ser interligado e disposto através de uma forma hierárquica e seqüencial nos esquemas gerais.

Tabela 5.3: Recursos didáticos e formas de apresentação no TDMA

Recursos Didáticos	Conceitos	Exercícios	Exemplos
Formas de Apresentação	Textual	Verdadeiro ou Falso	Textual c/ Figura
	Textual c/ Figura	Relacionar Colunas	Esquema c/ Figuras
	Esquema c/ Figura	Escolha Simples	
		Preencher Lacunas	
		Escolha Simples c/ Figura	

5.2.3 A interface do Módulo de Ensino Experimental

A interface utilizada no módulo de ensino TDMA foi projetada com o objetivo de não induzir o aprendiz em uma forma seqüencial e prévia diante das opções encontradas para a sua navegação nos conteúdos do módulo. O uso das cores e o *layout* foram baseados em um estudo anterior com a população-alvo. Aos ícones que aparecem no menu principal, associou-se texto explicativo sobre o tipo de forma apresentada, facilitando assim a navegação do sujeito.

A Figura 5.2 mostra o menu principal e a disposição dos seus elementos componentes.

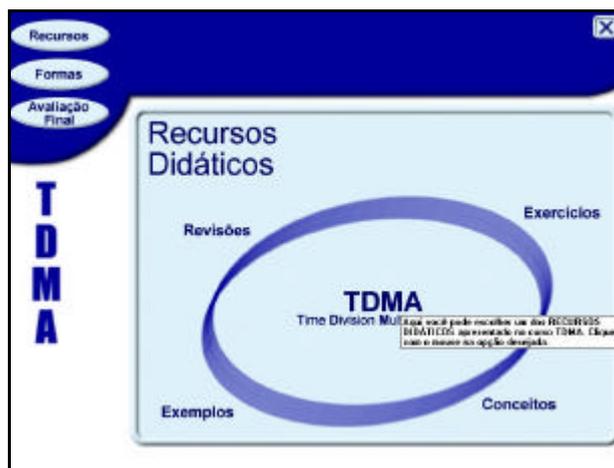


Figura 5.2: A interface do módulo experimental TDMA

Uma vez selecionado um dos recursos didáticos, o sistema automaticamente disponibilizava as formas de apresentação correspondentes. As telas de apresentação destas formas igualmente seguiam o mesmo padrão de interface, ou seja, as opções possíveis eram disponibilizadas em torno da elipse gráfica.

5.3 Aplicação do Módulo de Ensino Experimental

Os participantes do experimento foram 35 sujeitos, entre técnicos e engenheiros, funcionários da empresa de Telecomunicações, parceira no Projeto Tapejara. O critério de seleção dos participantes correspondeu aos sujeitos mais típicos de cada classe de ECA identificada. Originalmente foi estabelecido um número representativo de 28 sujeitos por classe de ECA, para a realização do módulo de ensino experimental. O número mínimo de sujeitos requeridos para cada classe de ECA eram 7 (sete) sujeitos e o máximo 14 (quatorze). Infelizmente, por questões operacionais (reformulações organizacionais e de controle da Empresa), não foi possível preencher o número mínimo previsto de sujeitos em alguns casos. A Tabela 5.4 abaixo mostra como ficou a distribuição da amostra entre as 5 (cinco) classes de ECA.

A limitação do número de casos em cada classe de ECA representou uma grande limitação durante o desenvolvimento deste estudo.

Tabela 5.4: Distribuição dos sujeitos da amostra

ECA	AA	CG	DA	ASA	RS
Número de Sujeitos previstos	Mínimo: 07 Máximo: 14	Mínimo: 07 Máximo: 14	Mínimo: 07 Máximo: 14	Mínimo: 07 Máximo: 14	07
Número de Sujeitos obtidos	10	07	08	07	03

Durante a execução do módulo de ensino experimental, todas as interações do aluno com o material instrucional eram registradas em um arquivo de *log* (diário de navegação). Cada registro neste *log* incluía: o número de identificação do aluno, data e hora do acesso e o tipo da página Web (i.e., 'Conceito', 'Exercício', 'Exemplo', 'Revisão' ou 'Avaliação' e a forma de apresentação correspondente, se fosse o caso).

Os procedimentos de aplicação deste módulo foram conduzidos por uma equipe de psicólogos e pedagogos, que supervisionaram a execução do módulo TDMA pelos alunos. O experimento transcorreu durante um período de um mês e meio. As seções eram agendadas conforme a disponibilidade dos funcionários. O ambiente experimental era constituído de um laboratório com 7 computadores PC-IBM, separados por uma divisória, simulando um ambiente individualizado. Este laboratório, que estava localizado no Centro de Treinamento da empresa parceira, foi especialmente construído com a finalidade de criar um ambiente de aprendizagem na Web.

Antes de executar o módulo experimental, os alunos recebiam uma breve explicação sobre o módulo e o seu funcionamento, salientando que cada um poderia seguir no seu ritmo, conforme suas preferências de aprendizagem. Após, lhes era disponibilizado, no seu computador, um módulo DEMO através do qual eles poderiam visualizar uma demonstração explicativa de todo o funcionamento estrutural do módulo, ao mesmo tempo em que poderiam se familiarizar com a interface do módulo experimental, evitando um desgaste extra durante a execução do mesmo. Além disto, durante a execução do módulo, a equipe de psicólogos e pedagogos poderiam prestar, tão somente, auxílio operacional, quer por problemas relacionados ao computador do aprendiz, quer por problemas de conexão com a rede dos computadores.

6 O PROCESSO DE DESCOBERTA DE CONHECIMENTO

O objetivo deste capítulo é descrever o trabalho realizado durante o processo de descoberta do conhecimento sobre as TAs padrão dos ECA. Os dados utilizados como exemplos e, a partir dos quais realizamos a indução do conhecimento necessário para a modelagem do ECA do aluno, tiveram origem no experimento realizado no contexto do Projeto Tapejara.

A manipulação dos dados do experimento, desde o seu estado primitivo (arquivo de *log*) até a sua forma operacional (tabela *atributo-valor*), utilizada no estudo aqui apresentado, seguiu o padrão de um processo KDD.

6.1 Limpeza e Transformação de Dados

Conforme foi mencionado no Capítulo 3, a limpeza dos dados correspondeu à eliminação daqueles registros do arquivo de *log* que foram considerados irrelevantes para a análise do comportamento do aluno. Os registros considerados irrelevantes, que foram removidos, corresponderam a:

- Acesso a menus
- Mensagem da aplicação para o aluno
- Falha de conexão
- Tempo de permanência nulo em determinado recurso didático

O processo de limpeza propriamente dito foi realizado manualmente, a partir de uma filtragem sobre o arquivo de *log* original.

Considerando que o arquivo de *log* continha os seguintes campos: *data do acesso*, *hora do acesso*, *código do aluno* e *código da URL* visitada, as principais transformações realizadas corresponderam a:

- Transformação do ‘código da URL’ em dois atributos, correspondentes, respectivamente, ao ‘código do recurso didático’ e ao ‘código da forma de apresentação’ usados naquele acesso
- Transformação dos códigos alfanuméricos em códigos numérico
- Cálculo do tempo de permanência em cada ‘recurso didático’ visitado

Considerando a natureza intervalar das variáveis monitoradas e a limitação do tamanho da amostra, procedemos à categorização (discretização) das variáveis indicadoras do comportamento navegacional e dos tempos de permanência nos recursos didáticos e formas de apresentação. Nesta categorização utilizando os percentis com dois pontos de corte. Para tanto, utilizamos o pacote estatístico SPSS. As três categorias

geradas foram denominadas de ‘Baixa’, ‘Média’ e ‘Alta’, correspondendo aos graus de intensidade com que os recursos didáticos e formas de apresentação foram utilizados pelos sujeitos da amostra (Tabela 6.1).

Nesta Tabela, os valores relativos à intensidade de uso dos recursos didáticos, que delimitam as faixas ‘Baixa’, ‘Média’ e ‘Alta’, correspondem à frequência relativa de uso sobre o total de páginas Web visitadas no módulo. Por outro lado, os valores relativos ao uso das formas de apresentação correspondem à frequência relativa de uso sobre o total de páginas Web visitadas do recurso didático que lhe corresponde.

Tabela 6.1: Categorização das faixas de frequência relativa e tempos de permanência nos ‘Recursos Didáticos’ e ‘Formas de Apresentação’ dos sujeitos da amostra

	CATEGORIAS	
	Intensidade de Uso	Tempo de Permanência
Uso dos ‘Recursos Didáticos’		
Conceito	<u>Baixa</u> : até 32 <u>Média</u> : entre 32 e 50 <u>Alta</u> : acima de 50	<u>Baixa</u> : até 24 <u>Média</u> : entre 24 e 39 <u>Alta</u> : acima de 39
Exercício	<u>Baixa</u> : até 24 <u>Média</u> : entre 24 e 40 <u>Alta</u> : acima de 40	<u>Baixa</u> : até 21 <u>Média</u> : entre 21 e 33 <u>Alta</u> : acima de 33
Exemplo	<u>Baixa</u> : até 2 <u>Média</u> : entre 2 e 25 <u>Alta</u> : acima de 25	<u>Baixa</u> : até 2 <u>Média</u> : entre 2 e 11 <u>Alta</u> : acima de 11
Uso das ‘Formas de apresentação’ de conceitos		
Somente Textual	<u>Baixa</u> : até 3 <u>Média</u> : entre 3 e 7 <u>Alta</u> : acima de 7	<u>Baixa</u> : até 3 <u>Média</u> : entre 3 e 10 <u>Alta</u> : acima de 10
Textual c/ Figura	<u>Baixa</u> : até 13 <u>Média</u> : entre 13 e 25 <u>Alta</u> : acima de 25	<u>Baixa</u> : até 10 <u>Média</u> : entre 10 e 22 <u>Alta</u> : acima de 22
Esquema c/ Figura	<u>Baixa</u> : até 11 <u>Média</u> : entre 11 e 17 <u>Alta</u> : acima de 17	<u>Baixa</u> : até 5 <u>Média</u> : entre 5 e 9 <u>Alta</u> : acima de 9
Uso das ‘Formas de apresentação’ de exercícios		
V ou F	<u>Baixa</u> : até 2 <u>Média</u> : entre 2 e 7 <u>Alta</u> : acima de 7	<u>Baixa</u> : até 2 <u>Média</u> : entre 2 e 7 <u>Alta</u> : acima de 7
Relacionar Colunas	<u>Não Usou</u> : = 0 <u>Baixa</u> : entre 0 e 5 <u>Alta</u> : acima de 5	<u>Não Usou</u> : = 0 <u>Baixa</u> : entre 0 e 6 <u>Alta</u> : acima de 6
Escolha Simples	<u>Não Usou</u> : = 0 <u>Baixa</u> : entre 0 e 11 <u>Alta</u> : acima de 11	<u>Não Usou</u> : = 0 <u>Baixa</u> : entre 0 e 6 <u>Alta</u> : acima de 6
Preencher Lacunas	<u>Não Usou</u> : = 0 <u>Baixa</u> : entre 0 e 5 <u>Alta</u> : acima de 5	<u>Não Usou</u> : = 0 <u>Baixa</u> : entre 0 e 6 <u>Alta</u> : acima de 6
Escolha Simples c/ Figura	<u>Baixa</u> : até 3 <u>Média</u> : entre 3 e 12 <u>Alta</u> : acima de 12	<u>Baixa</u> : até 2 <u>Média</u> : entre 2 e 8 <u>Alta</u> : acima de 8
Uso das ‘Formas de apresentação’ de exemplos		
Textual c/ Figura	<u>Baixa</u> : até 2 <u>Média</u> : entre 2 e 14 <u>Alta</u> : acima de 14	<u>Baixa</u> : até 1 <u>Média</u> : entre 1 e 8 <u>Alta</u> : acima de 8
Esquema c/ Figura	<u>Não Usou</u> : = 0 <u>Baixa</u> : entre 0 e 9 <u>Alta</u> : acima de 9	<u>Não Usou</u> : = 0 <u>Baixa</u> : entre 0 e 3 <u>Alta</u> : acima de 3

6.2 Pré-Processamento de Dados

Basicamente, o comportamento navegacional das classes de ECA (ou Trajetórias de Aprendizagem) foi analisado a partir da *freqüência relativa de acesso* aos recursos didático e formas de apresentação dos mesmos (preferências dos ECAs), bem como através dos *tempos relativos de permanência* nestes recursos e formas (velocidade de processamento dos ECAs). Tanto a *freqüência relativa de acesso* aos recursos didático e formas de apresentação, como os *tempos relativos de permanência* nestes recursos e formas, compunham os indicadores do comportamento do aluno na Web.

Assim, o esforço nesta etapa correspondeu à geração desses indicadores a partir dos dados primitivos no arquivo de *log*. Para a geração desses indicadores, conforme especificado na Tabela 4.1, foi projetada e desenvolvida uma ferramenta específica. A ferramenta desenvolvida opera em duas fases: (i) acesso à base de dados para a recuperação dos registros do *log-global*, correspondentes a um aluno, seleção e geração de um *log-individual* temporário; (ii) acesso ao *log-individual* para a contabilização e geração, propriamente dita, dos indicadores.

A fase de geração do *log-individual* é bastante simplificada uma vez que o *log-global* é gerado e controlado dentro do próprio ambiente de ensino. Na segunda fase, os indicadores calculados são armazenados na base de dados do ambiente de ensino para posterior utilização pelos indutores e, futuramente, por algum agente inteligente, responsável pelo diagnóstico cognitivo *on-line* do aluno remoto.

Por fim, a fase de pré-processamento foi concluída com a geração propriamente dita da tabela atributo-valor, com cada entrada na tabela correspondendo a um aluno que participou do experimento. Cada uma destas entradas foi composta pelas variáveis dependentes, ou indicadores, e pela variável independente, ou seja, o ECA do aluno. A inclusão do ECA do aluno na tabela atributo-valor foi realizada manualmente.

6.3 Análise Exploratória de Dados e Formulação de Hipóteses

Considerando que não dispúnhamos de pressupostos *a priori* sobre as *Trajetórias de Aprendizagem* dos ECAs (conceitualmente definidas no Capítulo 5) e do seu funcionamento em um ambiente de aprendizagem na Web, neste primeiro momento estamos trabalhando com uma análise exploratória e descritiva dos comportamentos observados. Esperamos que num futuro próximo tenhamos a oportunidade de validar estatisticamente estes resultados, especialmente quando a base de dados correspondente tiver crescido o suficiente, para termos uma amostra significativamente grande.

Todas as análises apresentadas neste documento referem-se à observação das interações (ou movimentos) dos sujeitos da amostra, até a execução da primeira avaliação (ou prova), enquanto estes navegavam pelas páginas Web do módulo de ensino experimental. A escolha da primeira prova como referência para a geração dos indicadores do *comportamento navegacional* e dos *tempos de permanência* nos recursos didáticos está baseada em nossa crença de que, até este momento, o aprendiz tende a interagir de forma mais espontânea, ou seja, até a 1ª prova é mais provável que o aprendiz esteja menos suscetível à preocupação com o seu desempenho.

6.3.1 Levantamento Descritivo Inicial dos Dados da Amostra

Com base nos dados do arquivo de *log*, procedeu-se à análise estatística-descritiva destes dados, levando em consideração os indicadores mais significativos para este

estudo. Nesta análise gerou-se a média, o desvio-padrão e o escopo, conforme é apresentado na Tabela 6.2. Esta análise foi realizada com o auxílio do pacote estatístico SPSS.

Tabela 6.2: Resultados descritivos da amostra ao realizar o módulo de ensino experimental

	Média (%)	Desvio Padrão (%)	Escopo (%)
Uso dos ‘Recursos Didáticos’			
Conceito	42,72	21,96	4,17 – 97,62
Exercício	33,22	21,06	0 – 89,47
Exemplo	17,41	18,15	0 – 79,17
Uso das ‘Formas de apresentação’ de conceitos			
Textual	5,65%	4,81	0 – 19,44
Textual c/ Figura	22,45%	17,81	0 – 91,67
Esquema c/ Figura	14,62%	10,97	0 – 50
Uso das ‘Formas de apresentação’ de exercícios			
V ou F	5,67%	6,94	0 – 34,28
Relacionar Colunas	3,84%	5,17	0 – 25
Escolha Simples	7,16%	8,61	0 – 32
Preencher Lacunas	4,08%	5,21	0 – 20
Escolha Simples c/ Figura	12,47%	16,29	0 – 72
Uso das ‘Formas de apresentação’ de exemplos			
Textual c/ Figura	11,23%	12,46	0 – 54
Esquema c/ Figura	6,19%	7,88	0 – 30
Tempo de Permanência nos ‘Recursos Didáticos’			
Conceito	31,10	14,37	0,79 – 65,79
Exercício	28,45	18,24	0 – 72,16
Exemplo	8,40	8,37	0 – 25,99
Tempo de Permanência nas ‘Formas de apresentação’ de conceitos			
Textual	6,63	6,25	0 – 22,64
Textual c/ Figura	16,62	11,09	0 – 41,15
Esquema c/ Figura	7,85	5,96	0 – 23,79
Tempo de Permanência nas ‘Formas de apresentação’ de exercícios			
V ou F	5,41	5,49	0 – 19,62
Relacionar Colunas	6,27	8,81	0 – 35,15
Escolha Simples	4,81	5,64	0 – 17,52
Preencher Lacunas	4,63	5,55	0 – 20,58
Escolha Simples c/ Figura	8,36	11,68	0 – 58,33
Tempo de Permanência nas ‘Formas de apresentação’ de exemplos			
Textual c/ Figura	6,11	6,24	0 – 21,01
Esquema c/ Figura	2,29	3,27	0 – 13,94

6.3.2 Comportamento Navegacional dos ECAs

Visando a comparação entre as classes de estilos cognitivos e a identificação do funcionamento das mesmas enquanto realizando um processo de aprendizagem na Web, investigamos, primeiramente, a *frequência relativa* ou as *preferências* das classes de ECA pelos recursos didáticos e pelas formas de apresentação.

Conforme mencionado anteriormente, o objetivo desta análise consiste em identificar as preferências das classes de ECA pelos recursos didáticos e pelas formas de apresentação, disponibilizados no módulo experimental. O método de análise adotado consistiu em: (i) análise da ‘ordem decrescente da preferência’ pelos recursos didáticos em cada estilo (frequência relativa intra-classe); (ii) análise da frequência relativa média

de acesso a um determinado recurso didático ou forma de apresentação para cada uma das classes de ECA em relação às demais classes (frequência relativa entre-classes); (iii) análise da frequência relativa média de acesso a um determinado recurso didático ou forma de apresentação, em relação à frequência relativa média da amostra para o mesmo recurso ou forma de apresentação. Estas análises foram realizadas a partir de um conjunto de gráficos gerados no MS-Excel.

Frequência relativa média de acesso aos Recursos Didáticos

A Figura 6.1 mostra a distribuição dos percentuais de acesso aos recursos didáticos pelas classes de ECA. Esta análise não leva em consideração o recurso de ‘Revisão’ devido ao fato de este recurso ter sido projetado fora do padrão esperado, o que impediu a sua utilização nesta análise.

A ordem (decrecente) da frequência relativa de acesso aos recursos didáticos pelo estilo AA seguiu o padrão ‘conceito → exercício → exemplo’. Em relação aos demais estilos, este estilo foi o que usou mais frequentemente o recurso de ‘Conceito’ (50,34% do total de páginas visitadas). Em relação ao uso dos recursos de ‘Exercício’ e ‘Exemplo’, a frequência relativa de acesso pelos sujeitos AA foi média (30,39% e 13,02%, respectivamente, do total de páginas visitadas) e inferior à média da amostra.

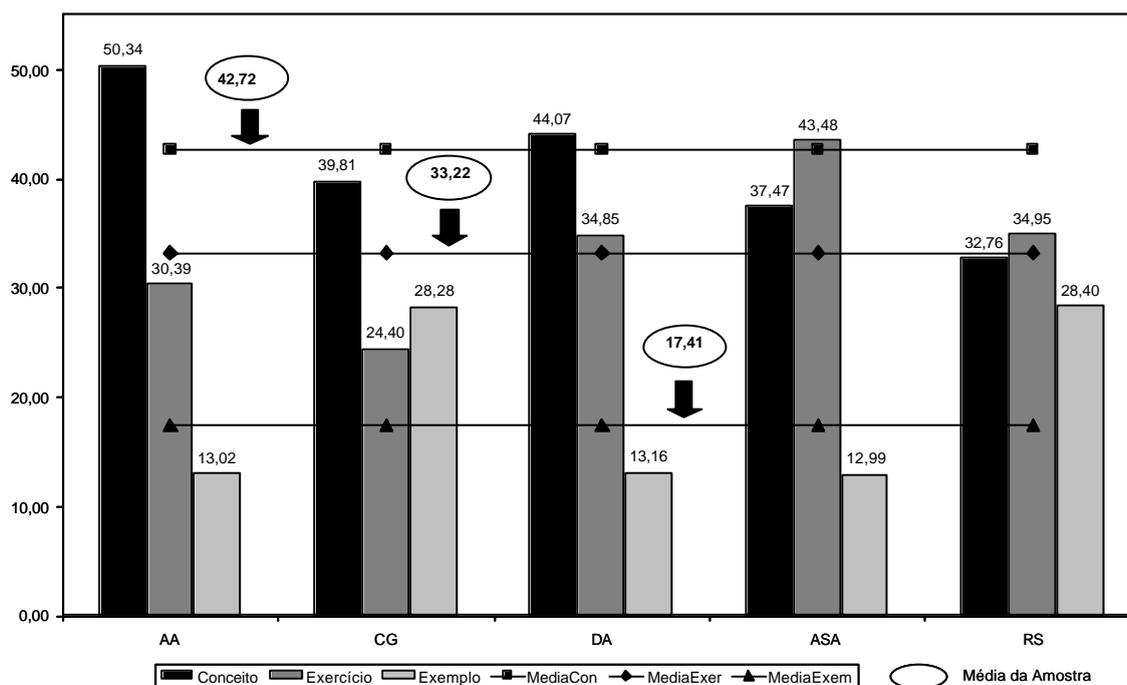


Figura 6.1 : Frequência relativa média de acesso aos ‘Recursos Didáticos’ – o eixo vertical representa o percentual médio correspondente ao uso dos recursos didáticos antes da primeira prova pelas classes de ECA. As linhas rotuladas representam o percentual médio da amostra

A ordem (decrecente) da frequência relativa de acesso aos recursos didáticos pelo estilo CG seguiu o padrão ‘conceito → exemplo → exercício’. Em relação aos demais estilos, este estilo foi o que usou mais frequentemente o recurso de ‘Exemplo’ (28,28% do total de páginas visitadas). A frequência relativa média de acesso aos recursos didáticos de ‘Conceito’ e ‘Exercício’ foram inferiores à média da amostra (39,81% e 24,40%, respectivamente, do total de páginas visitadas).

A ordem (decrecente) da frequência relativa de acesso aos recursos didáticos pelo estilo DA seguiu o padrão ‘conceito → exercício → exemplo’. Em relação aos demais

estilos, o estilo DA não apresentou nenhum destaque quanto à frequência relativa de acesso aos recursos didáticos. Observou-se apenas que as frequências relativas médias de acesso aos recursos de ‘Conceito’ e ‘Exercício’ foram superiores à média da amostra; e que a frequência relativa média de acesso ao recurso de ‘Exemplo’ foi inferior à média da amostra.

A ordem (decrecente) de frequência relativa de acesso aos recursos didáticos pelo estilo ASA seguiu o padrão ‘exercício → conceito → exemplo’. Em relação aos demais estilos, o estilo ASA foi o que usou mais frequentemente o recurso de ‘Exercício’ (43,48% do total de páginas visitadas). Em relação às frequências relativas médias de acesso aos recursos de ‘Conceito’ e ‘Exemplo’, observou-se que estas foram inferiores às respectivas médias da amostra.

Finalmente, quanto ao estilo RS, observamos que a ordem (decrecente) da frequência relativa de acesso aos recursos didáticos seguiu o padrão ‘exercício → conceito → exemplo’. Em relação aos demais estilos, o estilo RS não apresentou nenhum destaque quanto à frequência relativa de acesso aos recursos didáticos. Observou-se apenas que a frequência relativa de acesso média ao recurso de ‘Conceito’ foi inferior à média da amostra, assim como as frequências relativas médias de acesso aos recursos de ‘Exercício’ e ‘Exemplo’ foram superiores às respectivas médias da amostra.

Frequência relativa média de acesso às formas de apresentação dos ‘Conceitos’

A Figura 6.2 mostra a distribuição dos percentuais médios de uso referente às formas de apresentação dos ‘Conceitos’ pelas classes de ECA.

A ordem (decrecente) da frequência relativa de acesso às formas de apresentação de ‘Conceito’ pelo estilo AA seguiu o padrão ‘textual c/ figura → esquema c/ figura → somente textual’. Em relação aos demais estilos, este estilo foi o que usou mais frequentemente as formas ‘Textual c/ Figura’ e ‘Somente Textual’ (28,70% e 7,49%, respectivamente, do total de páginas de ‘Conceitos’ visitadas). Em relação à forma ‘Esquema c/ Figura’, a frequência média de acesso pelo estilo AA foi inferior à média da amostra.

Da mesma forma que o estilo AA, a ordem (decrecente) da frequência relativa de acesso às formas de apresentação de ‘Conceito’ pelo estilo CG seguiu o padrão ‘textual c/ figura → esquema c/ figura → somente textual’. Em relação aos demais estilos, o estilo CG foi o que usou menos frequentemente a forma ‘Somente Textual’. Em relação à forma ‘Textual c/ Figura’, a frequência relativa média de acesso pelo estilo CG foi superior à média da amostra. Em relação à forma ‘Esquema c/ Figura’, a intensidade média de uso pelo estilo CG foi inferior à média da amostra.

A ordem (decrecente) da frequência relativa de acesso às formas de apresentação de ‘Conceito’ pelo estilo DA seguiu o padrão ‘esquema c/ figura → textual c/ figura → somente textual’. Em relação aos demais estilos, o estilo DA foi o que usou mais frequentemente a forma ‘Esquema c/ Figura’ (20,18% do total de páginas de ‘Conceitos’ visitadas). Em relação à forma ‘Somente Textual’, a frequência relativa média de acesso pelo estilo DA foi superior à média da amostra. Em relação à forma ‘Textual c/ Figura’, a frequência relativa média de acesso pelo estilo DA foi inferior à média da amostra.

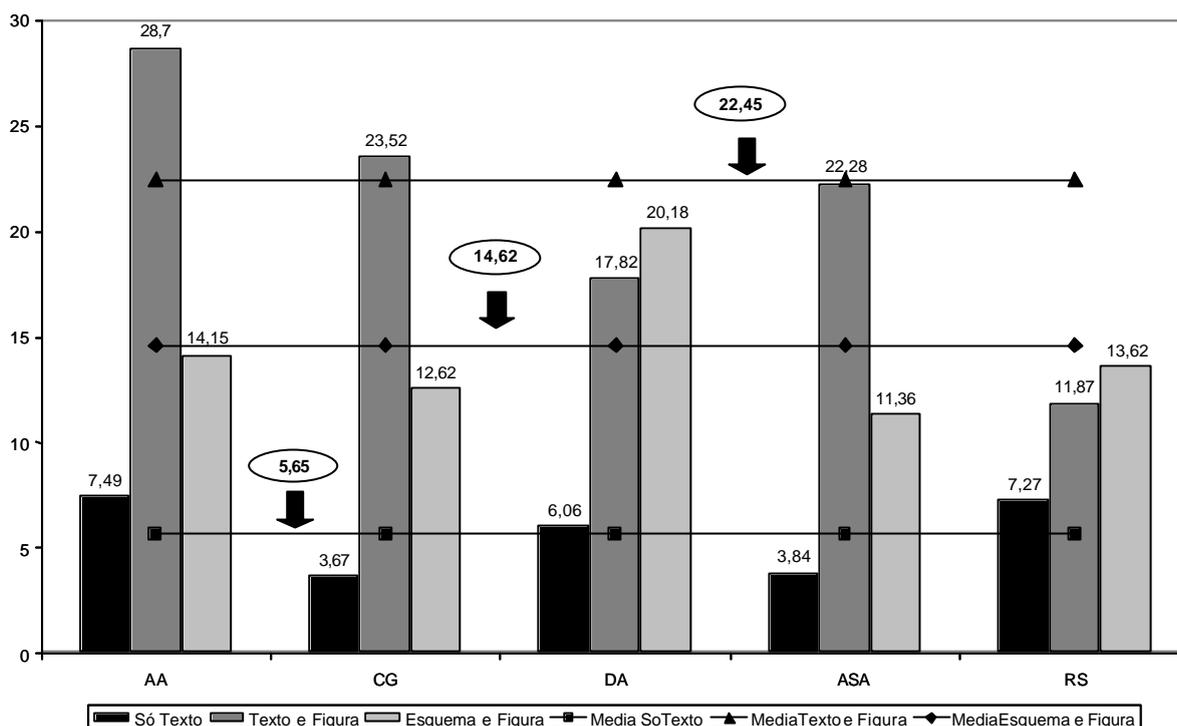


Figura 6.2: Frequência relativa média de acesso às ‘Formas de Apresentação dos Conceitos’ – o eixo vertical representa o percentual médio de uso destas formas sobre o total de páginas de ‘Conceitos’ visitadas antes da primeira prova pelas classes de ECA. As linhas rotuladas representam o percentual médio da amostra para estas formas.

A ordem (decrecente) da frequência relativa média de acesso às formas de apresentação de ‘Conceito’ pelo estilo ASA seguiu o padrão ‘textual c/ figura → esquema c/ figura → somente textual’, da mesma forma que os estilos AA e CG. Em relação aos demais estilos, o estilo ASA foi o que menos frequentemente usou a forma ‘Esquema c/ Figura’ (11,36% do total de páginas de ‘Conceitos’ visitadas). Em relação às formas ‘Textual c/ Figura’ e ‘Somente Textual’, as respectivas frequências médias de acesso pelo estilo DA foram inferiores às médias da amostra.

Quanto ao estilo RS, a ordem (decrecente) da frequência relativa média de acesso às formas de apresentação de ‘Conceito’ seguiu o padrão ‘esquema c/ figura → textual c/ figura → somente textual’. Em relação aos demais estilos, o estilo RS foi o que menos usou a forma ‘Textual c/ Figura’ (11,87% do total de páginas de ‘Conceitos’ visitadas). Em relação à forma ‘Somente Textual’, a frequência relativa média de acesso pelo estilo RS foi superior à média da amostra. Em relação à forma ‘Esquema c/ Figura’, a frequência relativa média de acesso pelo estilo RS foi inferior à média da amostra.

Frequência relativa média de acesso às formas de apresentação dos ‘Exercícios’

A Figura 6.3 mostra a distribuição dos percentuais médios de acesso referente às formas de apresentação dos ‘Exercícios’ pelas classes de ECA.

A ordem (decrecente) da frequência relativa média de acesso às formas de apresentação de ‘Exercício’ pelo estilo AA seguiu o padrão ‘escolha simples c/ figura → escolha simples → relacionar colunas → V ou F → preencher lacunas’. Em relação aos demais estilos, o estilo AA foi o que menos frequentemente usou a forma ‘V ou F’

(2,92% do total de páginas de ‘Exercícios’ visitadas). Em relação às formas ‘Relacionar Colunas’, ‘Escolha Simples’ e ‘Escolha Simples c/ Figura’, a frequência média de acesso pelo estilo AA foi superior à média da amostra. Em relação à forma ‘Preencher Lacunas’ a frequência média de acesso pelo estilo AA foi inferior à média da amostra.

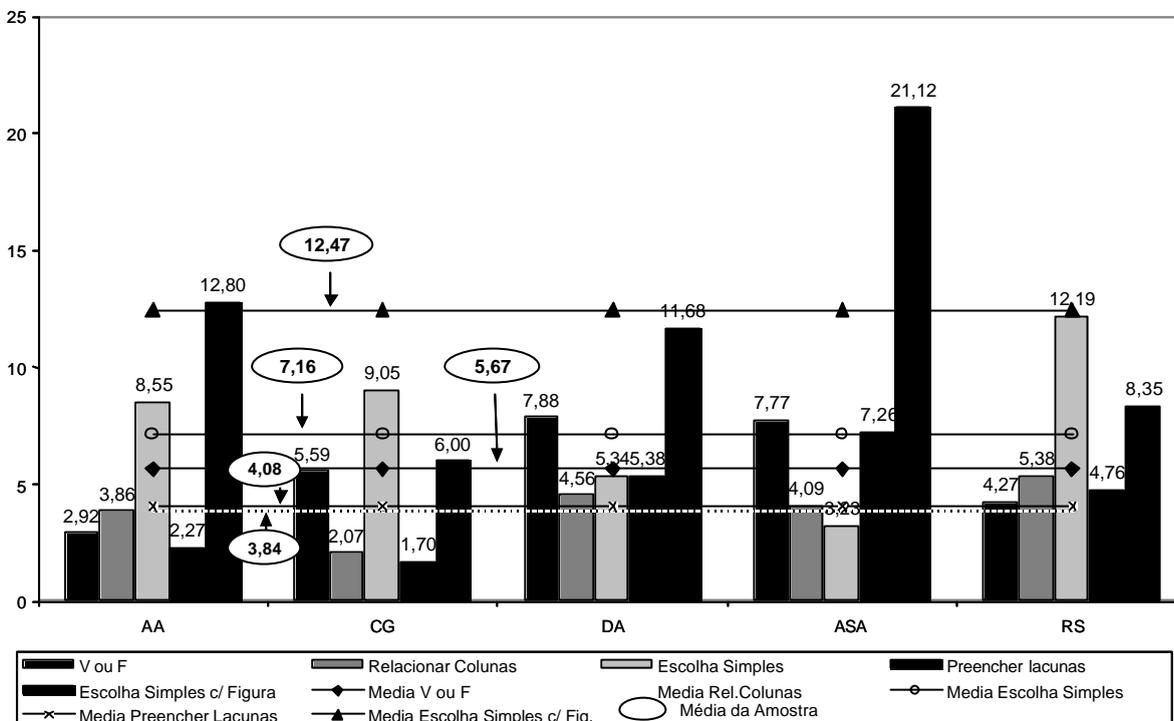


Figura 6.3: Frequência relativa média de acesso às ‘Formas de Apresentação dos Exercícios’ – o eixo vertical representa o percentual médio de uso destas formas sobre o total de páginas de ‘Exercícios’ visitadas antes da primeira prova pelas classes de ECA. As linhas rotuladas representam o percentual médio da amostra para estas formas.

A ordem (decrecente) da frequência relativa média de acesso às formas de apresentação de ‘Exercício’ pelo estilo CG seguiu o padrão ‘escolha simples → escolha simples c/ figura → V ou F → relacionar colunas → preencher lacunas’. Em relação aos demais estilos, o estilo CG foi o que menos frequentemente usou as formas ‘Relacionar Colunas’, ‘Preencher Lacunas’ e ‘Escolha Simples c/ Figura’ (2,07%, 1,70% e 6,00%, respectivamente, do total de páginas de ‘Exercícios’ visitadas). Em relação à forma ‘V ou F’, a frequência média de acesso pelo estilo CG foi muito próxima à média da amostra, assim como em relação à forma ‘Escolha Simples’ a frequência média de acesso pelo estilo CG foi superior à média da amostra.

A ordem (decrecente) da frequência relativa média de acesso às formas de apresentação de ‘Exercício’ pelo estilo DA seguiu o padrão ‘escolha simples c/ figura → V ou F → preencher lacunas → escolha simples → relacionar colunas’. Em relação aos demais estilos, o estilo DA foi o que mais usou a forma ‘V ou F’ (7,88% do total de páginas de ‘Exercícios’ visitadas). Em relação às formas ‘Relacionar Colunas’ e ‘Preencher Lacunas’, a frequência relativa média apresentada pelo estilo DA foi superior à média da amostra. Em relação às formas ‘Escolha Simples’ e ‘Escolha Simples c/ Figura’, a frequência relativa média apresentada pelo estilo DA foi inferior à média da amostra.

A ordem (decrecente) da frequência relativa média de acesso às formas de apresentação de ‘Exercício’ pelo estilo ASA seguiu o padrão ‘escolha simples c/ figura

→ V ou F → preencher lacunas → relacionar colunas → escolha simples'. Em relação aos demais estilos, o estilo ASA foi o que mais frequentemente usou as formas 'Escolha Simples c/ Figura' e 'Preencher Lacunas' (21,12% e 7,26%, respectivamente, do total de páginas de 'Exercícios' visitadas). Por outro lado, o estilo ASA foi o que menos usou a forma 'Escolha Simples' (3,23% do total de páginas de 'Exercícios' visitadas). Quanto às formas 'V ou F' e 'Relacionar Colunas', a intensidade média de uso pelo estilo ASA foi superior à média da amostra.

Finalmente, quanto ao estilo RS, a ordem (decrecente) da frequência relativa média de acesso às formas de apresentação de 'Exercício' seguiu o padrão 'escolha simples → escolha simples c/ figura → relacionar colunas → preencher lacunas → V ou F'. Em relação aos demais estilos, o estilo RS foi aquele que mais frequentemente utilizou as formas 'Relacionar Colunas' e 'Escolha Simples' (5,38% e 12,19% do total de páginas de 'Exercícios' visitadas). Em relação às formas 'V ou F' e 'Escolha Simples c/ Figura', a frequência média de acesso pelo estilo RS foi superior à média da amostra. Em relação à forma 'Preencher Lacunas', a frequência média de acesso pelo estilo RS foi muito próxima à média da amostra.

Frequência relativa média de acesso às formas de apresentação dos 'Exemplos'

A Figura 6.4 mostra a distribuição dos percentuais médios de acesso referente às formas de apresentação dos 'Conceitos' pelas classes de ECA.

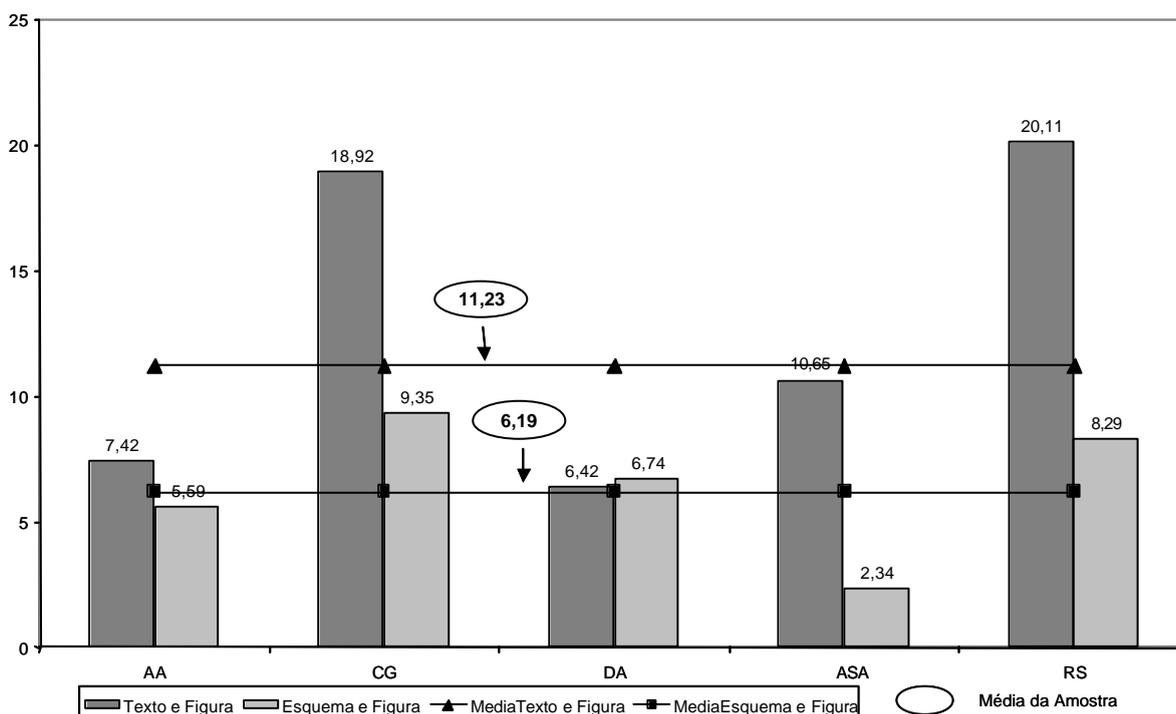


Figura 6.4: Frequência relativa média de acesso às 'Formas de Apresentação dos Exemplos' – o eixo vertical representa o percentual médio de uso destas formas sobre o total de páginas de 'Exemplos' visitadas antes da primeira prova pelas classes de ECA. As linhas rotuladas representam o percentual médio da amostra para estas formas.

A ordem (decrecente) da frequência relativa média de acesso às formas de apresentação de 'Exemplo' pelo estilo AA seguiu o padrão 'textual c/ figura → esquema c/ figura'. Em relação aos demais estilos, o estilo AA não apresentou nenhum

destaque em relação à frequência relativa média de acesso às formas de exemplos. Apenas observou-se que a frequência média de acesso a estas formas foi inferior à média da amostra.

A ordem (decrecente) da frequência relativa média de acesso às formas de apresentação de 'Exemplo' pelo estilo CG seguiu o padrão 'textual c/ figura → esquema c/ figura'. Em relação aos demais estilos, o estilo CG foi o que apresentou maior frequência relativa de acesso à forma 'Esquema c/ Figura'. Em relação à forma 'Textual c/ Figura', a frequência relativa média de acesso pelo estilo CG foi superior à média da amostra.

A ordem (decrecente) da frequência relativa média de acesso às formas de apresentação de 'Exemplo' pelo estilo DA seguiu o padrão 'esquema c/ figura → textual c/ figura'. Em relação aos demais estilos, o estilo DA foi o que apresentou menor frequência relativa de acesso à forma 'Textual c/ Figura' (6,42% do total de páginas de 'Exemplo' visitadas). Em relação à forma 'Esquema c/ Figura', o estilo DA apresentou a frequência relativa média de acesso muito próxima à média da amostra.

A ordem (decrecente) da frequência relativa média de acesso às formas de apresentação de 'Exemplo' pelo estilo ASA seguiu o padrão 'textual c/ figura → esquema c/ figura'. Em relação aos demais estilos, o estilo ASA foi o que apresentou menor frequência relativa média de acesso à forma 'Esquema c/ Figura' (2,34% do total de páginas de 'Exemplo' visitadas). Em relação à forma 'Textual c/ Figura', a frequência relativa apresentada pelo estilo ASA foi inferior à média da amostra.

Finalmente, quanto ao estilo RS, a ordem (decrecente) da frequência relativa média de acesso às formas de apresentação de 'Exemplo' seguiu o padrão 'textual c/ figura → esquema c/ figura'. Em relação aos demais estilos, o estilo RS foi o que apresentou maior frequência relativa de acesso à forma 'Textual c/ Figura' (20,11% do total de páginas de 'Exemplo' visitadas). Em relação à forma 'Esquema c/ Figura', a frequência relativa média de acesso pelo estilo RS foi superior à média da amostra.

6.3.3 Tempos de Permanência dos ECA

A seguir, analisamos os tempos de permanência ou a velocidade de processamento das classes de ECA enquanto visitavam os recursos didáticos e as formas de apresentação durante a execução do módulo experimental. O objetivo desta análise consiste em identificar os padrões de permanência dos estilos nos recursos didáticos e nas formas de apresentação.

Assim como o método de análise adotado na análise do comportamento navegacional dos ECAs, o método de análise dos tempos de permanência também adotou o mesmo tratamento para com este indicador, ou seja: (i) análise da 'ordem decrescente dos tempos de permanência' nos recursos didáticos e formas de apresentação, por classe de ECA (análise de permanência intra-classe); (ii) análise dos tempos de permanência de uma dada classe de ECA em um determinado recurso didático ou forma de apresentação, em relação às demais classes (análise de permanência entre-classes); (iii) análise dos tempos de permanência de um determinado estilo, nos recursos didáticos e formas de apresentação, em relação aos tempos de permanência médios da amostra para o mesmo recurso ou forma de apresentação. Estas análises foram realizadas a partir de um conjunto de gráficos gerados no MS-Excel.

Tempo médio de permanência nos ‘Recursos Didáticos’

A Figura 6.5 mostra a distribuição dos percentuais médios referentes aos tempos de permanência das classes de ECA nos recursos didáticos. Assim como na análise do comportamento navegacional, excluímos desta análise o recurso de ‘Revisão’, pelo mesmo motivo exposto na seção 6.3.3.

A ordem (decrecente) do tempo de permanência médio nos recursos didáticos pelo estilo AA seguiu o padrão ‘conceito → exercício → exemplo’. Em relação aos demais estilos, este estilo foi o que permaneceu mais tempo no recurso de ‘Conceito’ (36,37% do tempo total no módulo de ensino), assim como foi o estilo que permaneceu menos tempo no recurso de ‘Exemplo’ (5,94% do tempo total no módulo de ensino). Quanto ao tempo de permanência nos ‘Exercícios’, o estilo AA apresentou uma média inferior à média da amostra para este recurso.

A ordem (decrecente) do tempo de permanência nos recursos didáticos pelo estilo CG seguiu o padrão ‘conceito → exercício → exemplo’. Em relação aos demais estilos, o estilo CG juntamente com o estilo RS foram os estilos que permaneceram menos tempo no recurso de ‘Conceito’ (28,13% e 24,19%, respectivamente, do tempo total no módulo de ensino). O estilo CG também foi o estilo que permaneceu menos tempo no recurso de ‘Exercício’ (21,12% do tempo total no módulo de ensino). Em relação ao recurso de ‘Exemplo’, o estilo CG juntamente com o estilo RS foram os estilos que permaneceram mais tempo neste recurso (11,43% e 15,66%, respectivamente, do tempo total no módulo de ensino).

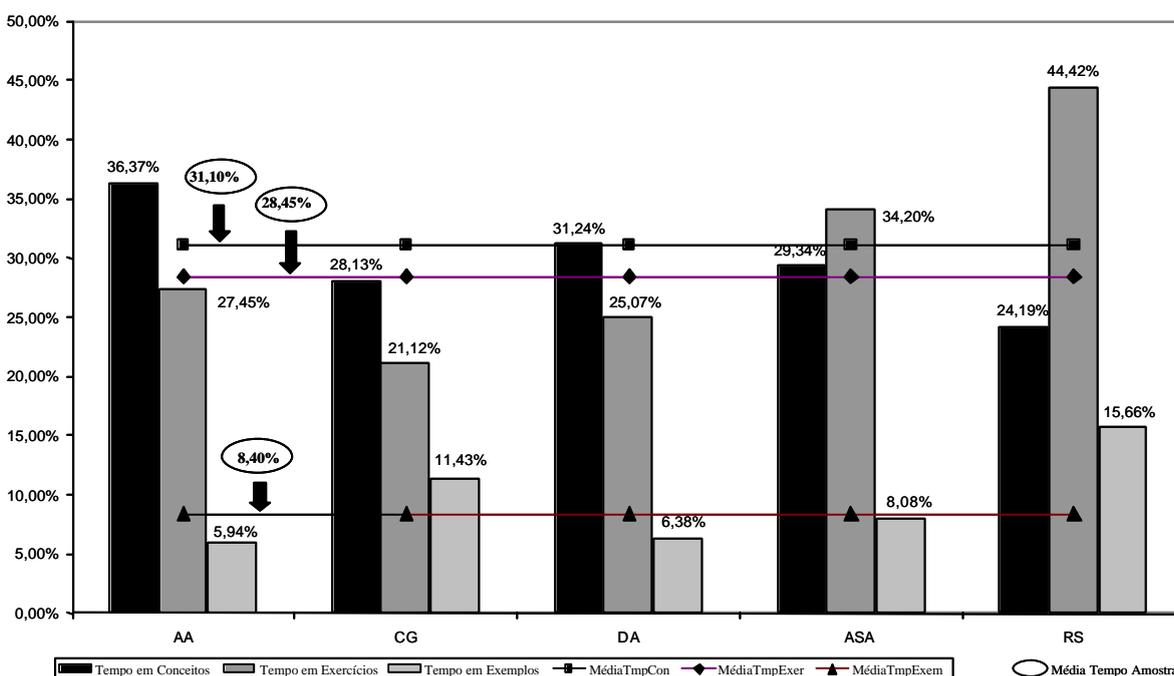


Figura 6.5: Tempo médio de permanência médio nos ‘Recursos Didáticos’ – o eixo vertical representa o percentual médio de permanência nos recursos didáticos, relativo ao tempo total de permanência no módulo de ensino experimental, incluindo a(s) avaliação(ões) final(ais) antes da primeira prova pelas classes de ECA. As linhas rotuladas representam o percentual médio de permanência da amostra nestes recursos.

A ordem (decrecente) do tempo de permanência nos recursos didáticos pelo estilo DA seguiu o padrão ‘conceito → exercício → exemplo’. Em relação aos demais estilos, o estilo DA não apresentou nenhum destaque quanto ao tempo de permanência nos

recursos didáticos. Em relação à média da amostra, o estilo DA permaneceu no recurso de ‘Conceito’ de forma semelhante ao estilo AA. Ambos os estilos permaneceram, em média, mais tempo neste recurso do que a média da amostra (31,10%). Quanto aos tempos de permanência nos ‘Exercícios’ e nos ‘Exemplos’, o estilo DA apresentou tempos de permanência inferiores às respectivas médias da amostra para estes recursos (28,45% e 8,40%, respectivamente, do tempo total no módulo de ensino).

A ordem (decrecente) do tempo de permanência nos recursos didáticos pelo estilo ASA seguiu o padrão ‘exercício → conceito → exemplo’. Em relação aos demais estilos, o estilo ASA juntamente com o estilo RS foram os estilos que permaneceram mais tempo no recurso de ‘Exercício’ (34,20% e 44,42%, respectivamente, do tempo total no módulo de ensino). O tempo de permanência deste estilo no recurso de ‘Conceitos’ foi inferior à média da amostra (29,34% do tempo total no módulo de ensino). Já o tempo de permanência no recurso de ‘Exemplo’ mostrou-se próxima à média da amostra para este recurso (8,08% do tempo total no módulo de ensino).

Finalmente, quanto ao estilo RS, observamos que a ordem (decrecente) do tempo de permanência nos recursos didáticos seguiu o padrão ‘exercício → conceito → exemplo’. Em relação aos demais estilos, o estilo RS foi o estilo que permaneceu mais tempo nos recursos de ‘Exercício’ e ‘Exemplo’ (44,42% e 15,66%, respectivamente, do tempo total no módulo de ensino). Quanto ao recurso de ‘Conceito’, o estilo RS foi o estilo que permaneceu menos tempo neste recurso (24,19% do tempo total no módulo de ensino).

Tempo médio de permanência nas formas de apresentação de ‘Conceitos’

A Figura 6.6 mostra a distribuição dos percentuais médios referentes aos tempos de permanência das classes de ECA nas formas de apresentação dos ‘Conceitos’.

A ordem (decrecente) do tempo de permanência nas formas de apresentação do recurso de ‘Conceitos’ pelo estilo AA seguiu o padrão ‘textual c/ figura → somente textual → esquema c/ figura’. Em relação aos demais estilos, o estilo AA foi o que permaneceu mais tempo na forma de apresentação ‘Textual c/ Figura’ (21,41% do tempo total de permanência nos ‘Conceitos’). Quanto à forma ‘Somente Textual’, este estilo juntamente com o estilo RS foram os estilos que permaneceram mais tempo nesta forma (7,70% e 7,86%, respectivamente, do tempo total de permanência nos ‘Conceitos’). Quanto à forma ‘Esquema c/ Figura’, o tempo médio de permanência do estilo AA foi muito próximo ao tempo da amostra para esta forma.

A ordem (decrecente) do tempo de permanência nas formas de apresentação do recurso de ‘Conceitos’ pelo estilo CG seguiu o padrão ‘textual c/ figura → somente textual → esquema c/ figura’. Em relação aos demais estilos, o estilo CG não apresentou nenhum destaque quanto aos tempos médios de permanência nas formas de apresentação dos ‘Conceitos’. Em relação aos tempos médios da amostra para estas formas, o estilo CG apresentou o tempo médio de permanência na forma ‘Somente Textual’ superior à média da amostra (7,56% do tempo total de permanência nos ‘Conceitos’). O tempo médio de permanência na forma ‘Textual c/ Figura’ foi inferior à média da amostra e, por fim, quanto à forma ‘Esquema c/ Figura’, o tempo médio de permanência nesta pelo estilo CG foi próximo à média da amostra.

A ordem (decrecente) do tempo de permanência nas formas de apresentação do recurso de ‘Conceitos’ pelo estilo DA seguiu o padrão ‘textual c/ figura → esquema c/ figura → somente textual’. Em relação aos demais estilos, o estilo DA foi o que permaneceu mais tempo na forma ‘Esquema e Figura’ (10,68% do tempo total de permanência nos ‘Conceitos’). Quanto à forma ‘Somente Textual’ o estilo DA foi o que

menos utilizou esta forma (4,81% do tempo total de permanência nos ‘Conceitos’). Por fim, quanto à forma ‘Textual c/ Figura’, o tempo de permanência médio do estilo DA nesta forma foi inferior à média da amostra (15,75% do tempo total de permanência nos ‘Conceitos’).

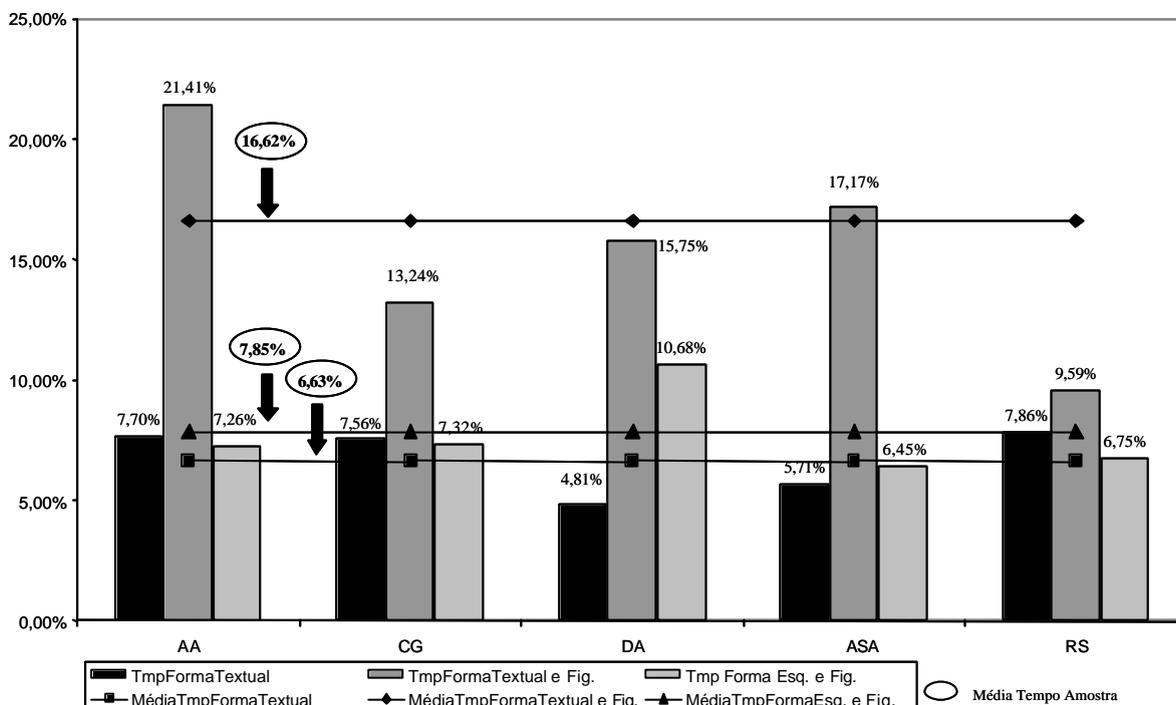


Figura 6.6: Tempo médio de permanência nas ‘Formas de Apresentação dos Conceitos’ – o eixo vertical representa o percentual médio de permanência nestas formas sobre o tempo médio de permanência nas páginas de ‘Conceitos’ visitadas antes da primeira prova pelas classes de ECA. As linhas rotuladas representam o percentual médio de permanência da amostra nestas formas.

A ordem (decrecente) do tempo de permanência nas formas de apresentação do recurso de ‘Conceitos’ pelo estilo ASA seguiu o padrão ‘textual c/ figura → esquema c/ figura → somente textual’. Em relação aos demais estilos, o estilo ASA foi o que permaneceu menos tempo na forma ‘Esquema c/ Figura’ (6,45% do tempo total de permanência nos ‘Conceitos’). Quanto à forma ‘Somente Textual’, o tempo médio de permanência do estilo ASA nesta forma foi inferior à média da amostra (5,71% do tempo total de permanência nos ‘Conceitos’). Quanto à forma ‘Textual c/ Figura’, o tempo de permanência médio do estilo ASA nesta forma foi superior à média da amostra (17,17% do tempo total de permanência nos ‘Conceitos’).

Finalmente, quanto ao estilo RS, observamos que a ordem (decrecente) do tempo de permanência nas formas de apresentação do recurso de ‘Conceitos’ seguiu o padrão ‘textual c/ figura → somente textual → esquema c/ figura’. Em relação aos demais estilos, o estilo RS foi o que permaneceu mais tempo na forma ‘Somente Textual’ (7,86% do tempo total de permanência nos ‘Conceitos’); assim como foi o estilo que permaneceu menos tempo na forma ‘Textual c/ Figura’ (9,59% do tempo total de permanência nos ‘Conceitos’). Quanto à forma ‘Esquema c/ Figura’, o tempo médio de permanência do estilo RS foi inferior à média da amostra para esta forma.

Tempo médio de permanência nas formas de apresentação de ‘Exercícios’

A Figura 6.7 mostra a distribuição dos percentuais médios referentes aos tempos de permanência das classes de ECA nas formas de apresentação dos ‘Exercícios’.

A ordem (decrecente) do tempo de permanência nas formas de apresentação do recurso de ‘Exercícios’ pelo estilo AA seguiu o padrão ‘relacionar colunas → escolha simples → escolha simples c/ figura → V ou F → preencher lacunas’. Em relação aos demais estilos, este foi o estilo que permaneceu menos tempo médio nas formas ‘V ou F’ e ‘Preencher Lacunas’ (3,63% e 2,67%, respectivamente, do tempo total de permanência nos ‘Exercícios’). Quanto às formas ‘Relacionar Colunas’ e ‘Escolha Simples’, os tempos médios de permanência nestas formas pelo estilo AA foram superiores às médias da amostra para estas formas (9,20% e 6,03%, respectivamente, do tempo total de permanência nos ‘Exercícios’). Por fim, quanto à forma ‘Escolha Simples c/ Figura’, o tempo médio de permanência do estilo AA nesta forma foi inferior à média da amostra (5,93% do tempo total de permanência nos ‘Exercícios’).

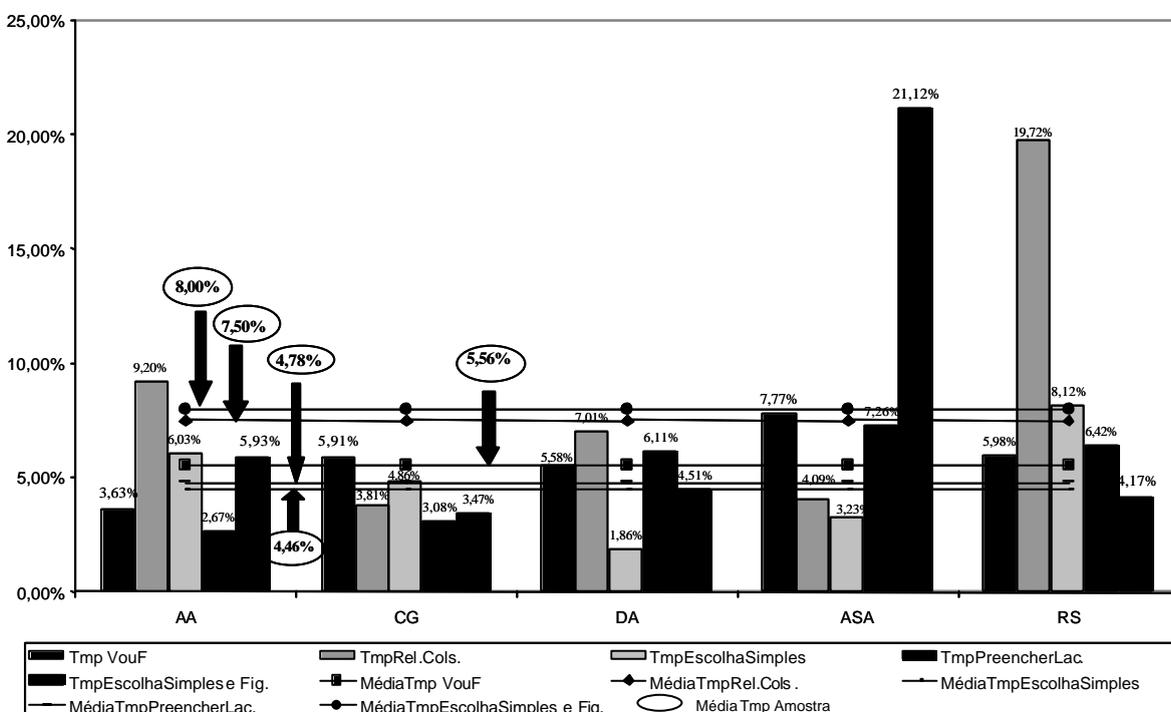


Figura 6.7: Tempo médio de permanência nas ‘Formas de Apresentação dos Exercícios’ – o eixo vertical representa o percentual médio de permanência nestas formas sobre o total do tempo de permanência nas páginas de ‘Exercícios’ visitadas antes da primeira prova pelas classes de ECA. As linhas rotuladas representam o percentual médio de permanência da amostra nestas formas.

A ordem (decrecente) do tempo de permanência nas formas de apresentação do recurso de ‘Exercícios’ pelo estilo CG seguiu o padrão ‘V ou F → escolha simples → relacionar colunas → escolha simples c/ figura → preencher lacunas’. Em relação aos demais estilos, o estilo CG foi o estilo que permaneceu menos tempo nas formas ‘Relacionar Colunas’ e ‘Escolha Simples c/ Figura’ (3,81% e 3,47%, respectivamente, do tempo total de permanência nos ‘Exercícios’). Quanto às formas ‘V ou F’ e ‘Escolha Simples’, o estilo CG permaneceu um tempo médio próximo à média da amostra (5,91% e 4,86%, respectivamente, do tempo total de permanência nos ‘Exercícios’). Por

fim, quanto à forma ‘Preencher Lacunas’, o estilo CG permaneceu um tempo inferior à média da amostra.

A ordem (decrecente) do tempo de permanência nas formas de apresentação do recurso de ‘Exercícios’ pelo estilo DA seguiu o padrão ‘relacionar colunas → preencher lacunas → V ou F → escolha simples c/ figura → escolha simples’. Em relação aos demais estilos, o estilo DA foi o que permaneceu menos tempo na forma ‘Escolha Simples’ (1,86% do tempo total de permanência nos ‘Exercícios’). Em relação às formas ‘Relacionar Colunas’ e ‘Escolha Simples c/ Figura’, os tempos médios de permanência pelo estilo DA foram inferiores às médias da amostra para estas formas. Quanto à forma ‘V ou F’, o estilo DA apresentou um tempo médio de permanência próximo à média da amostra (5,58% do tempo total de permanência nos ‘Exercícios’). Por fim, quanto à forma ‘Preencher Lacunas’, o tempo médio de permanência do estilo DA foi superior à média da amostra.

A ordem (decrecente) do tempo de permanência nas formas de apresentação do recurso de ‘Exercícios’ pelo estilo ASA seguiu o padrão ‘escolha simples c/ figura → V ou F → preencher lacunas → relacionar colunas → escolha simples’. Em relação aos demais estilos, o estilo ASA foi o que permaneceu mais tempo nas formas ‘V ou F’, ‘Preencher Lacunas’ e ‘Escolha Simples e Figura’ (7,77%, 7,26% e 21,12%, respectivamente, do tempo total de permanência nos ‘Exercícios’). Em relação às formas ‘Relacionar Colunas’ e ‘Escolha Simples’ o estilo ASA permaneceu um tempo médio inferior à média da amostra para estas formas (4,09% e 3,23%, respectivamente, do tempo total de permanência nos ‘Exercícios’).

Finalmente, quanto ao estilo RS, a ordem (decrecente) do tempo de permanência nas formas de apresentação do recurso de ‘Exercícios’ seguiu o padrão ‘relacionar colunas → escolha simples → preencher lacunas → V ou F → escolha simples c/ figura’. Em relação aos demais estilos, o estilo RS foi o estilo que permaneceu mais tempo nas formas ‘Relacionar Colunas’ e ‘Escolha Simples’ (19,72% e 8,12%, respectivamente, do tempo total de permanência nos ‘Exercícios’). Quanto à forma ‘V ou F’, o tempo de permanência pelo estilo RS foi próximo à média da amostra para esta forma (5,98% do tempo total de permanência nos ‘Exercícios’). Quanto à forma ‘Preencher Lacunas’, o tempo de permanência pelo estilo RS foi superior à média da amostra; assim como em relação à forma ‘Escolha Simples c/ Figura’, o tempo médio de permanência pelo estilo RS foi inferior à média da amostra.

Tempo médio de permanência nas formas de apresentação de ‘Exemplos’

A Figura 6.8 mostra a distribuição dos percentuais médios referentes aos tempos de permanência das classes de ECA nas formas de apresentação dos ‘Exemplos’.

A ordem (decrecente) do tempo de permanência nas formas de apresentação do recurso de ‘Exemplo’ pelo estilo AA seguiu o padrão ‘textual c/ figura à esquema c/ figura’. Em relação aos demais estilos, o estilo AA não apresentou nenhum destaque quanto aos tempos de permanência nas formas de apresentação dos ‘Exemplos’. Apenas observou-se que os tempos médios de permanência nas formas ‘Textual c/ Figura’ e ‘Esquema c/ Figura’ foram inferiores às médias da amostra para estas formas.

A ordem (decrecente) do tempo de permanência nas formas de apresentação do recurso de ‘Exemplo’ pelo estilo CG seguiu o padrão ‘textual c/ figura → esquema c/ figura’. Em relação aos demais estilos, o estilo CG juntamente com o estilo RS foram os estilos que permaneceram mais tempo nas formas de ‘Exemplo’. Na forma ‘Textual c/ Figura’, o tempo médio de permanência do estilo CG foi superior à média da amostra (8,57% do tempo total de permanência nos ‘Exemplos’). Quanto à forma ‘Esquema c/

Figura', o tempo médio de permanência do estilo CG também foi superior à média da amostra (2,86% do tempo total de permanência nos 'Exemplos').

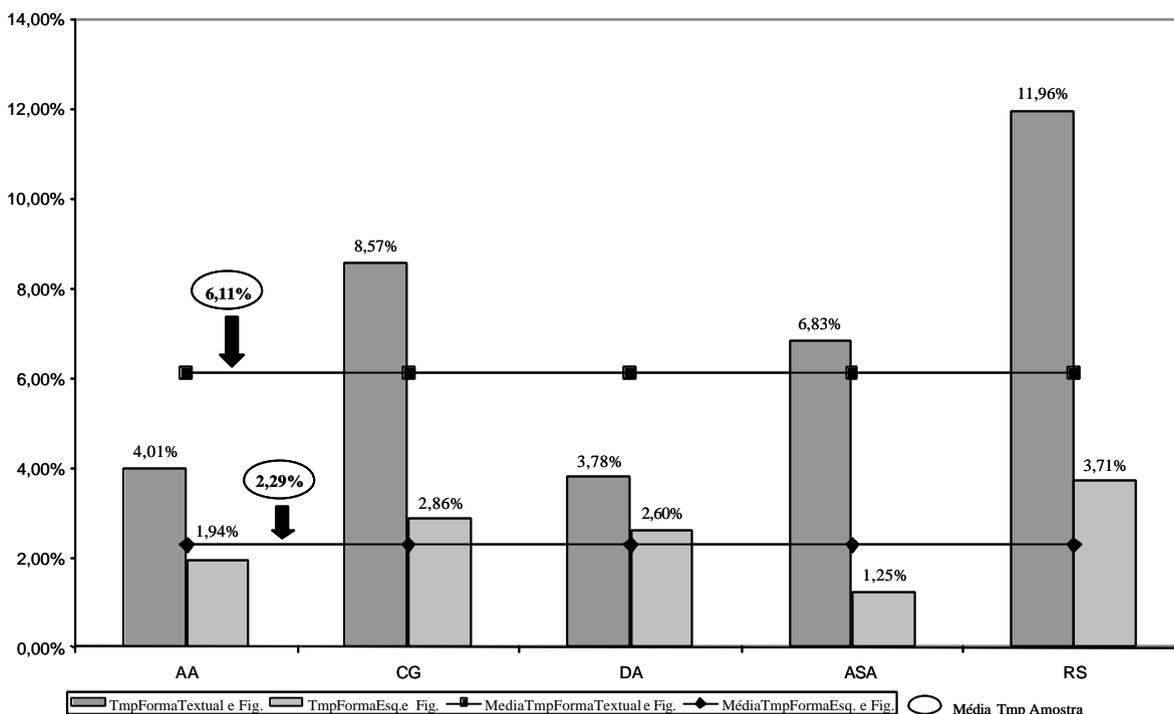


Figura 6.8: Tempo médio de permanência nas 'Formas de Apresentação dos Exemplos'. O eixo vertical representa o percentual médio de permanência nestas formas sobre o total do tempo de permanência nas páginas de 'Exemplos' visitadas antes da primeira prova pelas classes de ECA. As linhas rotuladas representam o percentual médio de permanência da amostra nestas formas.

A ordem (decrecente) do tempo de permanência nas formas de apresentação do recurso de 'Exemplo' pelo estilo DA seguiu o padrão 'textual c/ figura → esquema c/ figura'. Em relação aos demais estilos, o estilo DA foi o que menos tempo permaneceu na forma 'Textual e Figura' (3,78% do tempo total de permanência nos 'Exemplos'). Em relação à forma 'Esquema e Figura', o tempo médio de permanência do estilo DA foi superior ao tempo médio da amostra (2,60% do tempo total de permanência nos 'Exemplos').

A ordem (decrecente) do tempo de permanência nas formas de apresentação do recurso de 'Exemplo' pelo estilo ASA seguiu o padrão 'textual c/ figura → esquema c/ figura'. Em relação aos demais estilos, o estilo ASA foi o que menos tempo permaneceu na forma 'Esquema e Figura' (1,25% do tempo total de permanência nos 'Exemplos'). Em relação à forma 'Textual e Figura', o tempo médio de permanência do estilo ASA foi superior ao tempo médio da amostra (6,83% do tempo total de permanência nos 'Exemplos').

Finalmente, quanto ao estilo RS, observamos que a ordem (decrecente) do tempo de permanência nas formas de apresentação do recurso de 'Exemplo' seguiu o padrão 'textual c/ figura → esquema c/ figura'. Em relação aos demais estilos, o estilo RS foi o estilo que mais tempo permaneceu nas formas de 'Exemplo'. Na forma 'Textual c/ Figura', o tempo médio de permanência do estilo RS foi superior à média da amostra (11,96% do tempo total de permanência nos 'Exemplos'). Quanto à forma 'Esquema c/ Figura', o tempo médio de permanência do estilo RS também foi superior à média da amostra (3,71% do tempo total de permanência nos 'Exemplos').

6.3.4 Movimentos do Aprendiz no Módulo de Ensino Experimental

O objetivo da investigação sobre os movimentos do aprendiz nas páginas Web do módulo experimental também está relacionado com o principal objetivo deste estudo, qual seja, a aquisição do conhecimento sobre o funcionamento dos ECAs durante uma seção de ensino e aprendizagem na Web.

O método de análise adotado consistiu na análise dos gráficos da moda estatística relativa ao recurso didático mais utilizado, em cada movimento, realizado até a primeira prova, pelos sujeitos de uma determinada classe de ECA (Figura 6.9). Os gráficos utilizados nesta análise foram gerados no MS-Excel.

A Figura 6.10 mostra os movimentos de cada uma das classes de ECA até a primeira prova. Nesta Figura, os diferentes padrões de movimentos estão destacados por caixas sombreadas de diferentes cores. A caixa de cor cinza-claro representa o padrão 'conceito-exercício', utilizado pelas classes AA e ASA. A caixa de cor cinza-médio representa o padrão 'exercício-conceito-exemplo', utilizado pela classe CG. Finalmente, a caixa de cor cinza-escuro representa o padrão 'conceito-exemplo', utilizado pelas classes AA e RS.

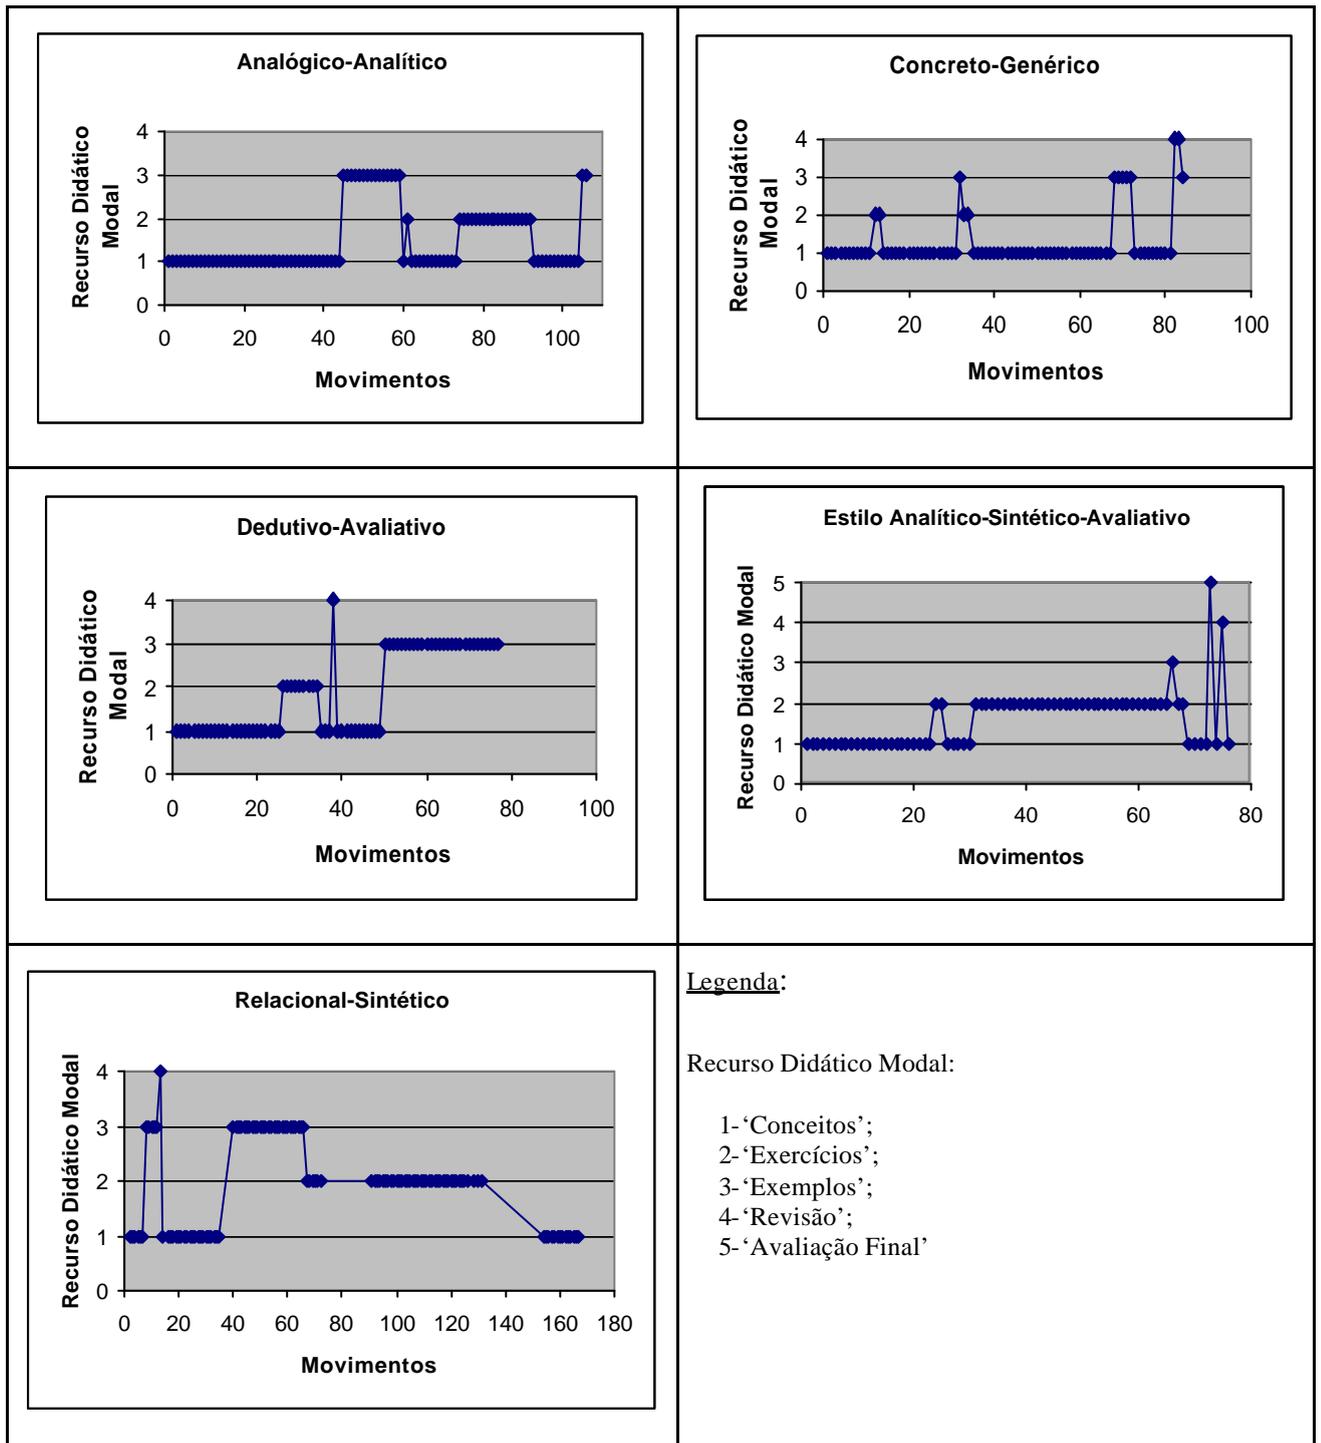


Figura 6.9: Recurso didático modal, em cada movimento, pelos sujeitos das classes de ECA

O estilo Analógico-Analítico (AA) realizou em média 106 movimentos até a primeira prova. Analisando os movimentos espontâneos nestes primeiros 106 movimentos, observou-se que este estilo apresentou duas estratégias básicas de busca da nova informação através do uso repetido dos padrões 'conceito-exemplo' e 'conceito-exercício'. À exceção do estilo Relacional-Sintético (formado apenas por três sujeitos), o estilo AA realizou um número médio de movimentos superior às demais classes de estilo cognitivo consideradas (exploração intensa dos recursos selecionados para estudar).

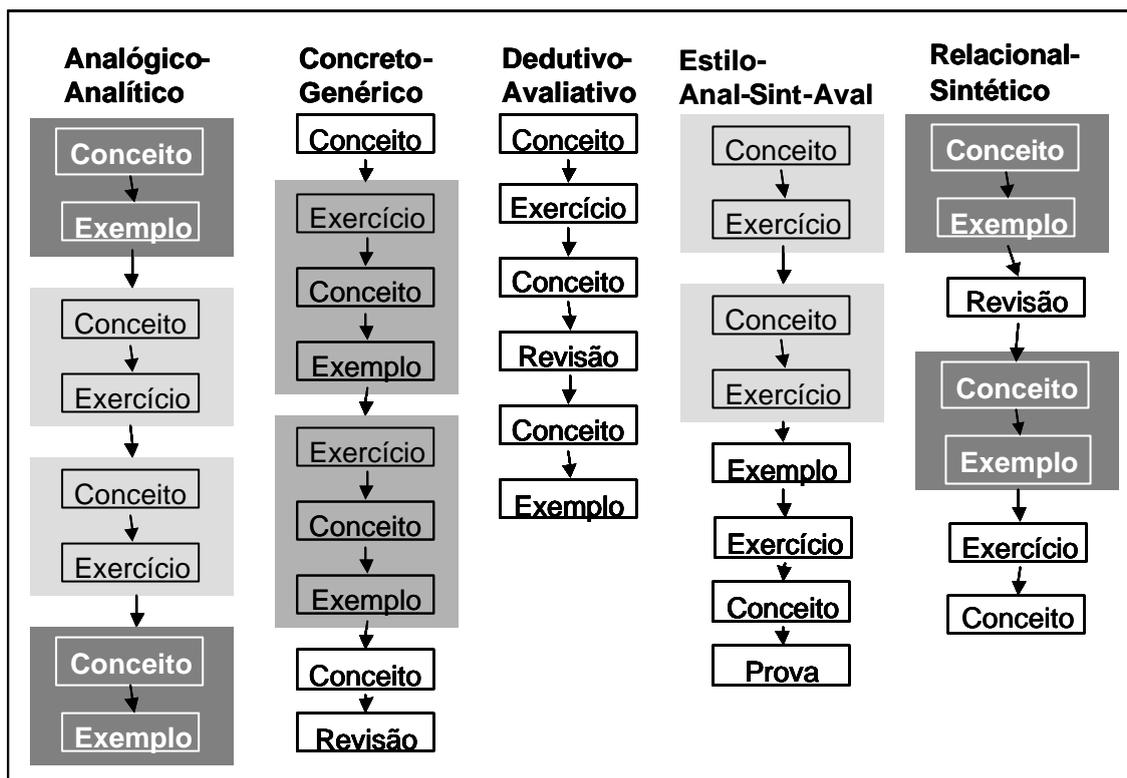


Figura 6.10: Padrões de ações cognitivas dos Estilos Cognitivos até a primeira prova

O estilo Concreto-Genérico (CG) realizou em média 84 movimentos até a primeira prova. Pela análise dos seus movimentos espontâneos nestes primeiros 84 movimentos, observa-se que a estratégia básica de busca da nova informação ocorre através do uso repetido do padrão “exercício-conceito-exemplo”. Em relação à classe dos Analógico-Analíticos, observamos que os Concreto-Genérico exploraram mais os diferentes recursos didáticos disponíveis, mas é possível perceber que a exploração aos recursos não foi intensa. Esta classe de estilo cognitivo optou pela realização da primeira prova em um número médio de movimentos 20% menor que o estilo AA.

O estilo Dedutivo-Avaliativo (DA), por sua vez, realizou em média 77 movimentos antes da primeira prova. Analisando os seus movimentos espontâneos nestes primeiros 77 movimentos, observa-se que a estratégia básica de busca da nova informação consistiu na exploração, sem repetição, de todos os recursos que lhe eram oferecidos, ou seja, o estilo explorou uma vez somente todos os recursos disponíveis e então se habilitou a realização da primeira prova.

A classe correspondente ao Estilo Analítico-Sintético-Avaliativo (ASA) realizou em média 76 movimentos até a primeira prova. Assim como o estilo Analógico-Analítico, esta classe aborda novas informações através do uso repetido do padrão ‘conceito-exercício’. Entretanto, diferentemente dos Analógico-Analítico, reduziu em 20% o número médio de movimentos antes de se habilitar à primeira prova.

Por último, o estilo Relacional-Sintético (RS) apresentou uma grande limitação quanto ao número de sujeitos da sua amostra, ou seja, na fase do experimento tivemos acesso a apenas três sujeitos representantes da classe. Mesmo assim, pela análise dos seus movimentos entre os recursos, observa-se uma tendência na busca de novas informações através do uso repetido do padrão ‘conceito-exemplo’.

6.3.5 Resumo da Análise Exploratória

Uma vez que o principal objetivo deste estudo é identificar os indicadores que melhor discriminam o funcionamento de aprendizagem das classes de ECA, com base na Tabela 6.1 geramos os quadros-resumo (Tabelas 6.3 e 6.4). Nestas Tabelas, os indicadores do Comportamento Navegacional e dos Tempos de Permanência foram tabulados tendo como referência a intensidade média de uso dos recursos didáticos e formas de apresentação, em cada classe de ECA, previamente classificadas como ALTA, MÉDIA e BAIXA. Cada uma destas categorias estão destacadas nas células através das cores 'preta', 'cinza-escuro' e 'cinza-claro', respectivamente.

A Tabela 6.3 resume os resultados, referentes à Intensidade Média de Uso dos recursos didáticos e das formas de apresentação por ECA.

Tabela 6.3: Mapa resumo dos percentuais médios da frequência relativa dos recursos didáticos e formas de apresentação, pelas classes de ECA, em um ambiente de aprendizagem na Web.

		AA	CG	DA	ASA	RS	
Amostra		10	7	8	7	3	
Média do Total de Páginas Visitadas até 1ª Prova		106	85	78	77	223	
Padrões de Ações Cognitivas		Conceito→ Exercício e Conceito→ Exemplo	Exercício →Conceito →Exemplo	Conceito →<recurso didático>	Conceito → Exercício	Conceito → Exemplo	
Frequência relativa do Recurso	Conceito	50,34%	39,81%	44,07%	37,47%	32,76%	
	Exercício	30,39%	24,40%	34,85%	43,48%	34,95%	
	Exemplo	13,02%	28,28%	13,16%	12,99%	28,40%	
Frequência relativa da Forma de Apresentação	Conceito	Só Textual	7,49%	3,67%	6,06%	3,84%	7,27%
		Textual c/ Figura	28,70%	23,52%	17,82%	22,28%	11,87%
		Esquema c/ Figura	14,15%	12,62%	20,18%	11,36%	13,62%
	Exercício	V ou F	2,92%	5,59%	7,88%	7,77%	4,27%
		Relacionar Colunas	3,86%	2,07%	4,56%	4,09%	5,38%
		Escolha Simples	8,55%	9,05%	5,34%	3,23%	12,19%
		Preencher Lacunas	2,27%	1,70%	5,38%	7,26%	4,76%
		Escolha Simples c/ Figura	12,80%	6,0%	11,68%	21,12%	8,35%
	Exemplo	Textual c/ Figura	7,42%	18,92%	6,42%	10,65%	20,11%
		Esquema c/ Figura	5,59%	9,35%	6,74%	2,34%	8,29%

Intensidade Alta
 Intensidade Média
 Intensidade Baixa

Os padrões dos tempos de permanência nos recursos didáticos e formas de apresentação

A Tabela 6.4 resume os resultados, referentes aos Tempos de Permanência Médios das classes de ECA nos recursos didáticos e nas formas de apresentação.

Tabela 6.4: Mapa resumo dos percentuais médios de permanência nos recursos didáticos e formas de apresentação, pelas classes de ECA, em um ambiente de aprendizagem na Web

		AA	CG	DA	ASA	RS	
Amostra		10	7	8	7	3	
Tempo médio de permanência até 1ª Prova		1:36:35	1:13:36	1:35:19	1:42:09	2:37:37	
Tempo de Permanência nos Recursos Didáticos	Conceito	36,37%	28,13%	31,24%	29,34%	24,19%	
	Exercício	27,45%	21,12%	25,07%	34,20%	44,42%	
	Exemplo	5,94%	11,43%	6,38%	8,08%	15,66%	
Tempo de Permanência nas Formas de Apresentação	Conceito	Somente Textual	7,70%	7,56%	4,81%	5,71%	7,86%
		Textual c/ Figura	21,41%	13,24%	15,75%	17,17%	9,59%
		Esquema c/ Figura	7,26%	7,32%	10,68%	6,45%	6,75%
	Exercício	V ou F	3,63%	5,91%	5,58%	7,77%	5,98%
		Relacionar Colunas	9,20%	3,81%	7,01%	4,09%	19,72%
		Escolha Simples	6,03%	4,86%	1,86%	3,23%	8,12%
		Preencher Lacunas	2,67%	3,08%	6,11%	7,26%	6,42%
		Escolha Simples c/ Figura	5,93%	3,47%	4,51%	21,12%	4,17%
	Exemplo	Textual c/ Figura	4,01%	8,57%	3,78%	6,83%	11,96%
		Esquema c/ Figura	1,94%	2,86%	2,60%	1,25%	3,71%

Tempo de Permanência Alto Tempo de Permanência Médio Tempo de Permanência Baixo

6.3.6 As Hipóteses Encontradas

A partir da análise exploratória, inferimos um conjunto de hipóteses sobre o comportamento dos ECA durante um processo de aprendizagem na Web, conforme apresentamos a seguir.

Estilo Analógico-Analítico

- Padrões de ações cognitivas: conceito → exemplo e conceito → exercício
- Intensidade de uso do recurso didático de ‘conceito’ é ALTA.

- Intensidade de uso das formas de apresentação textuais de ‘conceito’ é ALTA.

Estilo Concreto-Genérico

- Padrões de ações cognitivas: exercício → conceito → exemplo
- Intensidade de uso do recurso didático de ‘exercício’ é BAIXA.
- Intensidade de uso do recurso didático de ‘exemplo’ é ALTA.
- Intensidade de uso das formas de apresentação de ‘exemplo’ é ALTA.

Estilo Dedutivo-Avaliativo

- Padrões de ações cognitivas: sem padrão definido.
- Intensidade de uso do recurso didático de ‘conceito’ é MÉDIA.
- Intensidade de uso do recurso didático de ‘exercício’ é MÉDIA.
- Intensidade de uso do recurso didático de ‘exemplo’ é MÉDIA.
- O tempo de permanência na forma de apresentação de ‘conceito’ – ‘esquema c/ figura’ é ALTA.

Estilo Analítico-Sintético-Dedutivo

- Padrões de ações cognitivas: conceito → exercício
- Intensidade de uso do recurso didático de ‘conceito’ é BAIXA.
- Intensidade de uso do recurso didático de ‘exercício’ é ALTA.
- Intensidade de uso do recurso didático de ‘exemplo’ é BAIXA.
- O tempo de permanência na forma de apresentação de ‘exercício’ – ‘V ou F’ é ALTA.
- O tempo de permanência na forma de apresentação de ‘exercício’ – ‘escolha simples c/ figura’ é ALTA.

Estilo Relacional-Sintético

- Padrões de ações cognitivas: conceito → exemplo
- Intensidade de uso do recurso didático de ‘conceito’ é BAIXA.
- Intensidade de uso do recurso didático de ‘exercício’ é MÉDIA.
- Intensidade de uso do recurso didático de ‘exemplo’ é ALTA.
- O tempo de permanência na forma de apresentação de ‘exemplo’ – ‘esquema c/ figura’ é ALTA.

6.4 Avaliação Qualitativa dos Resultados

A partir dos resultados *quantitativos*, obtidos a partir da análise exploratória, prosseguimos com uma avaliação *qualitativa* dos resultados, que foi realizada juntamente com o especialista (Psicólogo Cognitivo). Neste momento, era necessário obter uma confirmação do especialista a respeito da nossa compreensão sobre o funcionamento cognitivo (*Trajetórias de Aprendizagem*) das classes de ECA sendo investigadas.

Para realizar a análise *qualitativa*, elaboramos um questionário. Este questionário era composto por um conjunto de afirmativas (hipóteses) sobre o comportamento do

aluno durante a execução do módulo de ensino experimental TDMA. Estas afirmativas estavam representando, até aquele momento, as crenças levantadas (ou padrões) sobre os indicadores que melhor discriminavam o comportamento dos estilos no Ambiente de Ensino e Aprendizagem na Web utilizado.

No questionário, as afirmativas estavam organizadas por classe de estilo cognitivo e pelo tipo de informação que elas continham, quais sejam:

- I. Padrões de Ações Cognitivas
- II. Intensidade de uso dos recursos didáticos
- III. Intensidade de uso das formas de apresentação
- IV. Tempo de permanência nos recursos didáticos
- V. Tempo de permanência nas formas de apresentação.

Ao especialista foi solicitado analisar, para cada uma das afirmativas, se ela explicava um possível funcionamento da classe de estilo cognitivo considerada. Para responder estas questões, o especialista era solicitado a indicar se ele concordava com a afirmativa e porquê, ou seja, ele deveria justificar a sua resposta. Além disso, o especialista também era solicitado a explicitar o seu *grau de crença* sobre a afirmativa em questão, bem como deveria explicitar a *base de sua crença*, para opinar sobre a afirmativa, conforme mostra a Tabela 6.5.

Tabela 6.5: Níveis de crença do especialista

Grau de Crença na Afirmativa	Base da Crença na Afirmativa
() Nada se pode afirmar	() Conhecimento
() Baixa	() Experiência
() Média Baixa	() Dados fornecidos suficientes
() Média	() Dados fornecidos insuficientes
() Média Alta	() Outra
() Alta	

A interpretação dos resultados obtidos está baseada nas principais características cognitivas das classes de ECA consideradas, descritas no Capítulo 5 e nos resultados da análise exploratória a respeito do comportamento das classes de ECA durante a execução do módulo de ensino experimental. Estes resultados refletem as tendências comportamentais dos ECAs, os quais são direcionados pelos seus processos cognitivos subjacentes.

A seguir, apresentamos uma breve discussão sobre o parecer do especialista, para cada uma das classes de ECA. A ordem em que aparecem as classes de ECA inicia pela classe de ECA que corresponde aquela com mais alto nível de abstração, seguindo em direção aquelas com menor nível de abstração.

Dedutivo-Avaliativo

Na análise que fizemos sobre o padrão de ações cognitivas adotadas pelo estilo DA (seção 6.3.5), interpretamos que a sua estratégia de busca da nova informação não apresentava um padrão específico de comportamento. Entretanto, de acordo com o especialista, os sujeitos desta classe apresentaram um padrão de comportamento que, conforme a definição do estilo DA, está de acordo com a capacidade cognitiva que este estilo apresenta para o uso do raciocínio dedutivo. Este padrão de comportamento

direciona o estilo DA na busca da compreensão dos conteúdos através do uso do recurso didático de ‘conceitos’. É através dos ‘conceitos’ que este estilo procura identificar uma lógica subjacente aos conteúdos, o que lhe facilita o processamento de novas informações. Uma vez obtido o padrão lógico, procuram testar o seu entendimento através do uso do recurso didático de ‘exercícios’. Em relação a este indicador, o especialista relatou que o grau de sua crença era ‘Alta’ e que ele se fundamentou no seu conhecimento, experiência e nos dados fornecidos.

Quanto à intensidade de uso dos recursos didáticos pelo estilo DA, na análise exploratória verificamos que os dados não apontaram para valores discriminativos em relação ao uso específico de cada um dos recursos por este estilo. Entretanto, o especialista salientou para o fato de que, 78% das páginas visitadas, em média, pelos sujeitos desta classe, correspondem ao uso combinado dos recursos didático de ‘conceito’ e ‘exercício’. É esta combinação que explica o funcionamento cognitivo do estilo. Em relação a este indicador, o especialista relatou que o grau de sua crença era ‘Média Alta’ e que ele se fundamentou no seu conhecimento e nos dados fornecidos.

Em relação à intensidade de uso das formas de apresentação de ‘conceitos’, este estilo demonstrou uma forte preferência pelo uso das formas esquemáticas. Segundo o especialista, a forma esquemática facilita a captação do padrão lógico do conteúdo, uma vez que é naturalmente didática e explicativa. Em relação a este indicador, o especialista relatou que o grau de sua crença era ‘Média Alta’ e que ele se fundamentou no seu conhecimento e nos dados fornecidos.

Embora os resultados da análise exploratória tenham indicado uma forte preferência pelas formas de apresentação de exercícios do tipo ‘V ou F’ e ‘Preencher Lacunas’, o especialista afirmou não ter elementos suficientes para concordar que isto explique um possível funcionamento do estilo DA.

Na análise exploratória, ainda observamos que o indicador tempo de permanência nos recursos didáticos não se mostrou discriminativo para esta classe de ECA. Sobre esta questão, o especialista não concordou, justificando que os dados fornecidos foram insuficientes. A análise exploratória também mostrou que o tempo de permanência na forma de apresentação ‘esquema c/ figura’ de conceito tende a ser alta para este estilo. Com relação a este resultado, o especialista apenas concordou com os dados fornecidos.

Analógico-Analítico

Sobre o padrão de ações cognitivas, na análise exploratória verificamos que o estilo AA tende a adotar os padrões ‘conceito-exercício’ e ‘conceito-exemplo’ ao abordar novas informações. O especialista concordou que estes padrões explicam o funcionamento deste estilo, uma vez que a sua principal habilidade está em perceber relações análogas e compreender as inter-relações entre as idéias. Segundo o especialista, os sujeitos desta classe ao se defrontarem com novas informações, tendem a buscar uma considerável profundidade no assunto, através de reflexão intensa. Em relação a este indicador, o especialista relatou que o grau de sua crença era ‘Alta’ e que ele se fundamentou no seu conhecimento, experiência e nos dados fornecidos.

Quanto ao uso dos recursos didáticos, verificamos que a intensidade de uso do recurso de ‘conceito’ tende a ser alta para este estilo. Pelos mesmos motivos, acima expostos, o especialista concordou que este resultado explica o funcionamento da classe de estilo AA. É através da intensa exploração do conteúdo teórico que propicia estes sujeitos a fazerem elaborações e fortes reflexões. Esta tendência evidencia-se também na preferência demonstrada por este estilo quanto ao uso das formas textuais de apresentação de ‘conceitos’. Na análise exploratória ainda verificamos que o uso da

forma de apresentação de exercício ‘escolha simples c/ figura’ tende a ser alta. O especialista apenas concordou com este resultado.

Relacional-Sintético

A interpretação dos resultados para esta classe de ECA, conforme o especialista, ficou muito comprometida em função do número limitado de sujeitos. Mesmo assim, em relação ao padrão de ações cognitivas adotado pelos sujeitos deste estilo, qual seja, ‘conceito-exemplo’, segundo o especialista, reflete a sua necessidade em relacionar os conceitos com situações práticas na tentativa de buscar um conhecimento sintético. Em relação a este indicador, o especialista relatou que o grau de sua crença era ‘Média Alta’ e que ele se fundamentou no seu conhecimento, experiência e nos dados fornecidos.

Em relação aos demais estilos, o estilo RS foi aquele que mais usou o recurso de ‘exemplo’, ou seja, a análise exploratória mostrou que a intensidade de uso deste recurso tende a ser alta para este estilo. O especialista concordou fortemente que este indicador reflete o funcionamento do estilo. Segundo este especialista, os sujeitos deste estilo trabalham com hipóteses associadas ao conteúdo e, fixam-se nos exemplos para confirmarem e/ou reformularem suas hipóteses, de forma semelhante ao tipo de processamento utilizado no raciocínio hipotético-dedutivo.

Em relação às formas de apresentação do recurso de ‘exercício’, a intensidade de uso foi alta para as formas: ‘relacionar colunas’ e ‘escolha simples’. O especialista concordou com este resultado, mas não deixa claro como este indicador explica o funcionamento desta classe. Quanto aos indicadores do tempo de permanência nos recursos didáticos de ‘exercício’ e ‘exemplo’, esta classe demonstrou forte tendência para intensidade alta. O especialista concordou que estes indicadores justificam o funcionamento do estilo, porque o tempo gasto nestes recursos é proporcional à intensidade de uso dos mesmos. Em relação a estes indicadores, o especialista relatou que o grau de sua crença era ‘Alta’ e que ele se fundamentou no seu conhecimento e nos dados fornecidos.

Concreto-Genérico

Sobre o padrão de ações cognitivas, na análise exploratória verificamos que o estilo CG tende a adotar o padrão ‘exercício-conceito-exemplo’ na abordagem de novas informações. Segundo o especialista, este indicador explica um possível funcionamento do estilo. Uma vez que os sujeitos desta classe caracterizam-se por serem ‘concretos’, eles tendem a evitar o contato mais sistemático com os conteúdos teóricos, no caso representados pelos ‘conceitos’. Em relação a este indicador, o especialista relatou que o grau de sua crença era ‘Alta’ e que ele se fundamentou no seu conhecimento, experiência e nos dados fornecidos.

Através da análise exploratória, também verificamos que a intensidade de uso do recurso didático de ‘exemplo’ por este estilo tende a ser alta. O especialista concorda plenamente, com alto grau de crença e fundamentado no seu conhecimento, experiência e nos dados fornecidos. Segundo ele, os sujeitos desta classe de estilo tentam generalizar os conhecimentos a partir de situações concretas e, secundariamente, através de exercícios. A constatação de que a intensidade de uso das formas de exemplo tende a ser alta para este estilo é consequência direta da sua preferência pelo uso do recurso de ‘exemplo’. Segundo o especialista, pela sua característica, os sujeitos CG exploram ao máximo este recurso em todas as suas formas de apresentação.

Em relação ao uso do tempo no processamento dos recursos didáticos e formas de apresentação dos mesmos, este estilo gastou um tempo maior no recurso didático de

‘exemplo’ e na forma de apresentação ‘textual com figura’. Para o especialista estes dados indicaram que o tempo foi proporcional à intensidade de uso do recurso e da forma de apresentação.

Analógico-Analítico-Avaliativo

Por construção, os sujeitos deste estilo se agruparam de maneira heterogênea. Isto significa que eles não apresentaram similaridade interna em relação ao desempenho nas habilidades e processos cognitivos subjacentes, avaliados no Teste Ross (seção 5.1.1). Conseqüentemente, a interpretação dos resultados da análise exploratória foi dificultada para o especialista explicar o funcionamento desta classe.

Mesmo assim, pela análise exploratória, pudemos observar algumas características estáveis para estes sujeitos. Quanto ao padrão de ações cognitivas adotado por este estilo, observamos que existe uma tendência deste em adotar o padrão ‘conceito-exercício’. O especialista concordou com este resultado, baseando-se fundamentalmente nos dados fornecidos. Considerando este indicador, o especialista comparou o seu funcionamento com o da classe DA, com a diferença de que a classe ASA demonstrou ter mais necessidade em testar suas hipóteses e compreensão. Acreditamos que a característica desta classe em apresentar predominância em uma habilidade ou processo, levou o especialista a detectar através dos dados fornecidos um funcionamento dessa classe semelhante ao estilo AA e DA.

No entanto, na análise exploratória, observamos diferentes indicadores que a caracterizam. Em relação ao uso dos recursos didáticos esta classe apresentou uma intensidade alta no uso dos exercícios, que de acordo com o especialista evidencia fortemente a sua característica de testar e avaliar a sua aprendizagem. Em relação à intensidade de uso das formas de apresentação de ‘exercícios’, este estilo usou intensamente as formas ‘V ou F’, ‘Preencher Lacunas’ e ‘Escolha Simples com Figura’. Para o especialista, estes indicadores confirmaram que o uso da testagem é o recurso de aprendizagem mais importante para esta classe. O indicador tempo de permanência foi maior no recurso didático de ‘exercício’, bem como nas suas formas de apresentação: ‘V ou F’ e ‘escolha simples com figura’. Estes indicadores foram confirmados pelo especialista como um modo de funcionamento do estilo, ou seja, o estilo tende a gastar mais tempo no recurso didático de ‘exercício’ (e suas respectivas formas) para se certificar sobre o seu aprendizado.

6.5 Mineração de Dados e a Busca de um Modelo de Classificação

O diagnóstico do ECA do aluno corresponde a um típico procedimento de classificação. Conforme Henery (1994), um dos importantes significados da classificação consiste em estabelecer uma regra a partir da qual se possa classificar novas observações em uma das classes, dado um conjunto de classes rotuladas e conhecidas.

Os métodos de classificação comumente praticados, e estudados pelos pesquisadores da área, na linha da aprendizagem através da experiência, podem ser agrupados sob três diferentes abordagens (MICHIE et al., 1994): (i) abordagem estatística (modelo probabilístico); (ii) aprendizagem de máquina-AM - (sentenças proposicionais e lógicas); e (iii) redes neurais. As abordagens estatísticas caracterizam-se por ter um modelo probabilístico explícito, que fornecem a probabilidade de ‘ser’ de cada uma das classes consideradas. A AM tem como meta gerar expressões simples o suficiente para

serem compreendidas facilmente por agentes humanos, ou seja, tentam imitar o raciocínio humano na tomada de decisão. Um exemplo típico deste método corresponde às *árvores de decisão*. Por fim, a abordagem correspondente às redes neurais, combina a complexidade de algumas técnicas estatísticas com o objetivo da AM de imitar a inteligência humana. Entretanto, isto é feito a um nível mais “inconsciente”, o que faz com que os conceitos aprendidos sejam transparentes ao usuário.

Nesta fase do processo de descoberta do conhecimento, investigamos o uso de algumas dessas técnicas, com os exemplos disponíveis a partir dos dados do arquivo de *log*, gerado durante a aplicação do módulo de ensino experimental – TDMA – a uma amostra da população-alvo. Especificamente, utilizamos duas técnicas estatísticas/probabilísticas para analisar o processo de indução do modelo de classificação: *Análise Discriminante (AD)* e *Classificadores Bayesianos Ingênuos (CBI)*, assim como também utilizamos a técnica de AM correspondente às chamadas *árvores de decisão*.

Em cada uma das tentativas realizadas, esbarramos na severa limitação referente ao tamanho da amostra dos exemplos disponíveis e na impossibilidade de reverter a situação junto à empresa de telecomunicações. A seguir, documentamos o trabalho realizado.

6.5.1 Análise Discriminante

Em estatística, a análise discriminante (AD) se refere à computação de diversas estatísticas relacionadas e é usada para estudar as diferenças entre duas ou mais classes e um conjunto de variáveis discriminantes (Figura 6.11).

A AD tem dois propósitos: *interpretação* e *classificação*. Na *interpretação* o seu uso possibilita que se estude a diferença entre duas ou mais classes e um conjunto de variáveis discriminantes. Neste caso, a variável classe é tratada como variável dependente e é medida de forma nominal. Na *classificação*, tanto as variáveis discriminantes, quanto as funções discriminantes canônicas são usadas para prever a classe mais provável ao qual pertence um novo caso. Nosso interesse na AD esteve relacionado principalmente com a *interpretação* dos resultados estatísticos.

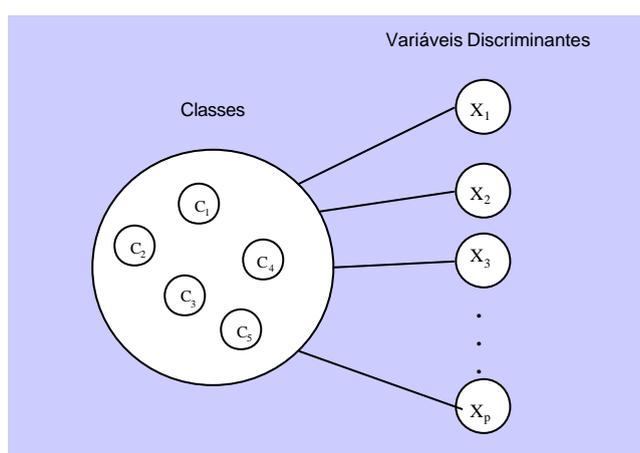


Figura 6.11:Relacionamento entre as classes e as variáveis discriminantes

De acordo com Klecka (1980), a aplicação da AD exige alguns requisitos matemáticos importantes, que ele resume da seguinte forma.

Sejam:

g = número de classes

p = número de variáveis discriminantes

n_i = número de casos na classe i

$n.$ = número total de casos

Então, deve ser considerado:

1. Duas ou mais classes: $g \geq 2$.
2. Pelo menos dois casos por grupo: $n_i \geq 2$.
3. Qualquer número de variáveis discriminantes, desde que o total de variáveis seja menor que o número de casos menos dois: $0 < p < (n. - 2)$.
4. As variáveis discriminantes devem ser medidas com valores intervalares, ou seja, devem ser passíveis de ser computada em uma fórmula matemática;
5. As variáveis discriminantes não podem ser uma combinação linear de outras. A proibição da combinação linear é resultado de certos requisitos matemáticos da técnica. De certa forma isto é intuitivo uma vez que a variável formada pela combinação linear não contém nenhuma informação nova, além daquelas contidas em suas componentes. Assim, ela seria redundante.
6. A matriz de covariância para cada classe deve ser (aproximadamente) igual, a menos que fórmulas especiais sejam usadas.
7. Cada classe deve ser formada a partir de uma população onde as variáveis discriminantes apresentam uma distribuição normal multivariada.

De modo a satisfazer os requisitos matemáticos, neste estudo procedemos a AD considerando, primeiramente, somente os indicadores relativos às preferências das classes de ECA pelos ‘recursos didáticos’ e, num segundo momento, consideramos somente os indicadores relativos às preferências pelas ‘formas de apresentação’. Excluímos os indicadores de tempo nos recursos didáticos e nas formas de apresentação destes uma vez que, ao realizar uma análise de correlação entre os indicadores que mediam preferência e aqueles que mediam tempo de permanência, observamos uma forte correlação entre eles. Na AD, isto corresponderia a uma redundância de informação e certamente estaria ‘mascarando’ possível resultado.

A AD foi realizada através do uso do pacote estatístico SPSS para Windows, versão 10.0. A técnica tenta identificar uma ou mais combinação linear das variáveis discriminativas, ou seja, define algumas funções discriminantes na forma:

$$D_i = d_{i1}Z_1 + d_{i2}Z_2 + \dots + d_{ip}Z_p$$

onde D_i corresponde ao escore da função discriminante i , os “ds” correspondem aos pesos dos coeficientes. Os “Zs” são os valores padrão das p variáveis discriminantes usadas na análise. O número máximo de funções que podem ser derivadas ou é uma a menos que a quantidade de grupos ou é igual ao número das variáveis discriminantes, se existirem mais grupos que variáveis. Idealmente, o escore de uma função discriminante D para os casos de um mesmo grupo é similar. Em qualquer taxa, as funções são formadas de modo a maximizar a separação entre os grupos. Uma vez que as funções tenham sido derivadas, é possível perseguir os propósitos de *interpretação* e *classificação*. A Tabela 6.6 mostra os principais resultados estatísticos desta análise.

Os resultados apresentados na Tabela 6.6 nos permitem interpretar o poder de classificação das funções discriminantes canônicas, aprendidas a partir da amostra de dados rotulados. O coeficiente de correlação canônica é uma medida valiosa para julgar

a utilidade da função discriminante. Se o coeficiente é alto⁵, então ele indica que existe uma forte correlação entre as classes e a função discriminante. Na Tabela 6.6, pode-se observar que estes coeficientes, tanto em relação aos recursos didáticos, quanto em relação às formas de apresentação, não são muito altos, mesmo para f1, a qual está representando o maior poder de discriminação.

Tabela 6.6: Resultados estatísticos gerados na AD

Estatísticas		Preferência pelos Recursos Didáticos	Preferência pelas Formas de Apresentação
Correlação canônica	f1	0,404	0,637
	f2	0,299	0,589
	f3	0,231	0,441
	f4	-	0,314
Wilk's Lambda		0,721	0,282
Qui-Quadrado		9,803	33,530
Significância		0,633	0,755
Nro. de classificações corretas		19	26
% de classificações corretas		54,3%	74,3%

O coeficiente Lambda (Λ) também é usado para o julgamento do poder de discriminação da função, mas é específico para quando os dados correspondem a uma amostra da população. Na verdade, este é o caso em questão. Wilks's Lambda é uma medida estatística multivariada das diferenças entre as classes em relação às variáveis discriminantes. Os valores de Lambda que estão próximos de zero denotam alto poder de discriminação, enquanto que à medida que ele cresce em direção ao valor 1, significa que não existe diferença entre as classes. Assim, analisando os resultados na Tabela 6.6, podemos observar que, tanto em relação às preferências pelos 'recursos didáticos', quanto pelas 'formas de apresentação', as classes de ECA não se diferenciam muito ($\Lambda = 0,721$ e $\Lambda = 282$, respectivamente). Estes resultados estão longe de zero.

Conforme Klecka (1980), o coeficiente Lambda pode ser convertido em um teste de significância. A significância de Lambda, por sua vez, pode ser convertida em uma aproximação do Qui-quadrado, que permite que se determine o nível de significância. Como os exemplos de nossa amostra de dados não resultaram de um processo de amostragem aleatório (foram selecionados os sujeitos mais típicos de cada classe de ECA), os testes Qui-quadrado e nível de significância não se aplicam. De qualquer forma, na Tabela 6.6, pode-se observar que os níveis de significância são muito altos, ou seja, as funções não são significantes estatisticamente.

Quanto aos resultados da classificação a partir das funções discriminantes canônicas, o resultado das classificações correta em relação à preferência das classes de ECA pelos 'recursos didáticos' foi de 54,3% dos casos, assim como o percentual de classificação em relação à preferência das classes de ECA pelas 'formas de apresentação' foi de 74,3% dos casos. Conseqüentemente, o erro para estes casos correspondeu, respectivamente a 45,7% (16 casos) e 25,7% (9 casos) de classificações incorretas. Considerando as estatísticas acima, estes valores ainda representam, matematicamente, um conhecimento incerto.

⁵ Coeficiente de correlação canônica: o valor zero denota nenhum relacionamento, enquanto que valores grandes (sempre positivos) representam um grau crescente de associação, onde o valor 1 corresponde ao valor máximo.

A Tabela 6.7 apresenta a *matriz de confusão* relativa à tentativa de discriminar as classes de ECA considerando apenas a preferência pelas ‘recursos didáticos’. Entre os três casos ‘AA’ classificados incorretamente, dois foram classificados como ‘CG’ e um como ‘RS’. Entre os quatro casos ‘CG’ classificados incorretamente, três foram classificados como ‘AA’ e um como ‘RS’. Entre os cinco casos ‘DA’ classificados incorretamente, dois foram classificados como ‘AA’, dois como ‘CG’ e um foi classificado como ‘RS’. Entre os quatro casos ‘ASA’ classificados incorretamente, dois foram classificados como ‘AA’, um como ‘CG’ e um como ‘DA’. Os três casos ‘RS’ foram classificados corretamente. Portanto, pela *matriz de confusão*, concluímos que através da AD somente as classes de ECA ‘AA’ e ‘RS’ tiveram um nível aceitável quanto ao desempenho de classificação.

Tabela 6.7: Resultado da classificação na análise discriminante considerando apenas a preferência das classes de ECA pelos ‘recursos didáticos’

ECA	Classes de ECA previstas					Total
	1	2	3	4	5	
Classes de ECA originais						
1	7		2		1	10
2	3	3			1	7
3	2	2	3		1	8
4	2	1	1	3		7
5					3	3
%						
1	70,0%		20,0%		10,0%	100,0%
2	42,86%	42,86%			14,28%	100,0%
3	25,0%	25,0%	37,5%	12,5		100,0%
4	28,57%	14,29%	14,29%	42,86%		100,0%
5					100,0%	100,0%

A Tabela 6.8 apresenta a *matriz de confusão* relativa à tentativa de discriminar as classes de ECA considerando apenas a preferência pelas ‘formas de apresentação’. Neste caso, um caso ‘AA’ foi classificado como ‘DA’; um caso ‘CG’ foi classificado como ‘AA’ e um caso ‘CG’ foi classificado como ‘DA’; apenas um caso ‘DA’ foi classificado como ‘AA’. Entre os dois casos ‘ASA’ classificados incorretamente, um foi classificado como ‘CG’ e o outro como ‘DA’. Finalmente, em relação ao estilo ‘RS’, todos os casos foram classificados corretamente. Portanto, pela *matriz de confusão*, concluímos que a AD apresentou um bom nível de classificação em relação às classes de ECA ‘AA’, ‘DA’ e ‘RS’, quando tentamos discriminá-las através de suas preferências pelas ‘formas de apresentação’.

A AD ainda permite a determinação da importância relativa de cada uma das variáveis consideradas, para a determinação dos coeficientes padronizados das funções discriminantes (Figura 6.12 e Figura 6.13).

Tabela 6.8: Resultado da classificação na análise discriminante considerando apenas a preferência das classes de ECA pelas 'formas de apresentação'

ECA	Classes de ECA previstas					Total
Classes de ECA originais	1	2	3	4	5	
1	9				1	10
2	1	4			2	7
3	2		6			8
4	3			4		7
5					3	3
%	1	90,0%			10,0%	100,0%
	2	14,3%	57,14%		28,57%	100,0%
	3	25,0%		75,0%		100,0%
	4	42,86%			57,14%	100,0%
	5				100,0%	100,0%

	Função		
	1	2	3
Conceito	2,293	4,083	3,745
Exercício	1,914	4,383	2,602
Exemplo	2,691	3,282	2,379

Figura 6.12: Discriminando as classes de ECA pelos Recursos Didáticos: coeficientes padrão das funções discriminantes canônicas

As funções f_1 , f_2 e f_3 na Figura 6.12 foram geradas em ordem de capacidade de discriminação das classes de ECA, ou seja, a f_1 foi a que mais discriminou, seguida pelas demais. Em relação aos coeficientes padronizados listados na Figura 6.12, ignorando o sinal, caso houvesse, a sua interpretação depende da sua magnitude. Quanto maior a sua magnitude, maior é a contribuição da variável. Na tentativa de discriminar as classes de ECA considerando a preferência pelos 'recursos didáticos', vimos que:

- f_1 discriminou especialmente pelo uso de 'Exemplo' (coeficiente = 2,691) e, em menor grau de importância, pelo uso de 'Conceito' (coeficiente = 2,293) e 'Exercício' (coeficiente = 1,914)
- f_2 discriminou especialmente pelo uso de 'Exercício' (coeficiente = 4,383), seguido em menor grau pelo uso de 'Conceito' (coeficiente = 4,083) e 'Exemplo' (coeficiente = 3,282).
- f_3 discriminou especialmente pelo uso de 'Conceito' (coeficiente = 3,745), seguido em menor grau pelo uso de 'Exercício' (coeficiente = 2,602), e 'Exemplo' (coeficiente = 2,379).

Em relação à tentativa de discriminar as classes de ECA pelas formas de apresentação (Figura 6.13), verificamos que:

- f_1 discriminou especialmente pelo uso da forma 'Preencher Lacunas' (coeficiente = 1,418) relativa ao recurso didático de 'Exercício', seguida em menor grau pelo uso das formas 'Só Textual' de 'Conceitos' (coeficiente =

1,246) e ‘Escolha Simples c/ Figura’ (coeficiente = 1,108), relativa ao recurso didático de ‘Exercício’.

- f_2 discriminou especialmente pelo uso combinado das formas ‘Textual c/ Figura’ (coeficiente = 3,924) de ‘Conceito’, ‘Textual c/ Figura’ (coeficiente = 3,445) de ‘Exemplo’ e ‘Escolha Simples c/ Figura’ (coeficiente = 3,330) de ‘Exercício’.
- f_3 discriminou, relativamente, pelo uso da forma ‘Só Textual’ (coeficiente = 0,845) de ‘Conceito’, seguida em menor grau pela forma ‘Esquema c/ Figura’ (coeficiente = 0,631) de ‘Exemplo’.
- f_4 discriminou, relativamente, pelo uso da forma ‘Textual c/ Figura’ (coeficiente = 0,645) de ‘Exemplo’, seguida pela forma ‘Esquema c/ Figura’ (coeficiente = 0,567) de ‘Conceito’.

	Função			
	1	2	3	4
Con-Só Textual	1,246	1,595	,845	,407
Con-Textual c/ Fig.	,411	3,924	,491	,012
Con-Esquema c/ Fig.	-,210	1,611	,037	,567
Exer-VouF	-,114	1,223	-,091	,288
Exer-Relac.Colunas	,092	,874	,279	,461
Exer-Escolha Simples	-,472	1,743	,406	,200
Exer-Preencher Lacunas	1,418	1,076	,115	,223
Exer-Escolha Simples c/ Fig.	1,108	3,330	,394	,412
Exem-Textual c/ Fig.	,415	3,445	-,265	,645
Exem-Esquema c/ Fig.	,301	1,059	,631	,457

Figura 6.13:Discriminando as classes de ECA pelas formas de apresentação: Coeficientes padrão das funções discriminantes canônicas

Finalmente, para a classificação de novos casos, os coeficientes das funções de classificação, para cada classe de ECA, são calculados pela técnica. Estes coeficientes determinam uma combinação linear das variáveis discriminantes, de forma a maximizar as diferenças das classes de ECA, enquanto a variação entre as classes é minimizada. Esta forma de classificar foi primeiramente proposta por (Fisher, 1936 apud Klecka, 1980).A função de classificação para cada uma das classes é dada pela expressão:

$$C_k = b_{k0} + b_{k1}x_1 + b_{k2}x_2 + \dots + b_{kp}x_p,$$

onde C_k é o escore para a classe k e os “bs” são os coeficientes que precisam ser derivados para a classificação. Um novo caso é classificado naquela classe que apresentou o maior escore (maior valor para C). Existe uma função diferente para cada classe de ECA.

A Figura 6.14 apresenta os coeficientes das funções de classificação, para cada uma das classes de ECA, considerando as preferências destas pelos ‘recursos didáticos’.

	ECA				
	1	2	3	4	5
Conceito	6,505	6,442	6,368	6,463	6,655
Exercício	6,203	6,143	6,084	6,195	6,369
Exemplo	6,589	6,574	6,455	6,558	6,796
(Constant)	-302,133	-297,721	-290,255	-299,939	-319,283

Fisher's linear discriminant functions

Figura 6.14: Recursos Didáticos: coeficientes das funções de classificação

Por exemplo, para a obtenção do escore C em um novo caso, seria necessário calcular:

$$C_1 = 6,505 * tdpcon + 6,203 * tdpexer + 6,589 * tdpexem - 302,133$$

$$C_2 = 6,442 * tdpcon + 6,143 * tdpexer + 6,455 * tdpexem - 297,721$$

$$C_3 = 6,368 * tdpcon + 6,084 * tdpexer + 6,455 * tdpexem - 290,255$$

$$C_4 = 6,463 * tdpcon + 6,195 * tdpexer + 6,558 * tdpexem - 299,939$$

$$C_5 = 6,655 * tdpcon + 6,369 * tdpexer + 6,796 * tdpexem - 319,283$$

onde *tdpcon*, *tdpexer* e *tdpexem* corresponderiam aos valores percentuais de uso dos recursos de 'Conceito', 'Exercício' e 'Exemplo', respectivamente, do novo caso considerado. O maior valor de C corresponderia a maior probabilidade do novo caso 'ser' da classe de ECA correspondente.

A Figura 6.15 apresenta os coeficientes das funções de classificação, para cada uma das classes de ECA, considerando as preferências destas pelas formas de apresentação. Para o diagnóstico de um novo caso, seria necessário calcular os valores de C_1 , C_2 , ..., C_5 , cujas funções correspondentes seriam construídas com base nos coeficientes apresentados na Figura 6.15.

	ECA				
	1	2	3	4	5
Con-Só Textual	10,153	9,655	9,709	10,268	10,612
Con-Textual c/ Fig.	8,072	8,011	7,776	8,079	8,300
Con-Esquema c/ Fig.	7,144	7,172	6,973	7,130	7,345
Exer-V ou F	7,609	7,648	7,404	7,618	7,837
Exer-Relac. Colunas	7,450	7,389	7,253	7,425	7,698
Exer-Escolha Simples	7,163	7,183	6,874	7,061	7,366
Exer-Preencher Lacunas	7,653	7,282	7,433	7,958	8,008
Exer-Escolha Simples c/ Fig.	7,793	7,685	7,538	7,854	8,047
Exem-Textual c/ Fig.	9,094	9,079	8,758	9,177	9,477
Exem-Esquema c/ Fig.	6,844	6,723	6,661	6,807	7,028
(Constant)	-373,196	-366,862	-349,230	-376,633	-399,752

Fisher's linear discriminant functions

Figura 6.15: Formas de Apresentação: coeficientes das funções de classificação

6.5.2 Classificador Bayesianos Ingênuo

Os classificadores Bayesianos ingênuos (CBI), que têm uma abordagem probabilística, têm sido considerados como uma abordagem eficiente e eficaz para

muitos problemas de modelagem de usuário (ou aluno), especialmente devido à sua rapidez de aprendizagem e o baixo custo computacional (STERN et al., 1999; MITCHELL, 1997; MICHIE et al., 1994). Estas características são críticas em sistemas de modelagem *on-line* do aluno. Conforme Stern et al., na abordagem tradicional de modelagem do aluno, existe pelo menos duas grandes limitações: (i) O especialista do domínio deve determinar, *a priori*, sobre quais características do domínio são importantes para serem rastreadas no modelo do aluno. Este processo implica em um consumo de tempo significativo e normalmente envolve a análise de uma tarefa cognitiva; e (ii) As características que compõem o modelo do aluno são estáticas. Sobre esta questão, o interessante é dispor de um modelo no qual tanto as características, quanto os relacionamentos não observados *a priori* pelo especialista do domínio possam ser descobertos pelo sistema e incluídos no mesmo. De forma similar, também é possível que algumas características sejam removidas.

As questões postas por Stern et al. (1999) podem ser gerenciadas através do uso de alguma técnica de AM. Isto significa que o sistema pode ‘aprender’ sobre o usuário a partir das interações com este. Por outro lado, a AM tem algumas limitações. A primeira delas está relacionada com a necessidade de uma quantidade substancial de dados, antes de se considerar que houve alguma aprendizagem. Com o aluno *on-line*, é necessário que a aprendizagem inicie com poucas interações. Em segundo lugar, normalmente, é necessária uma quantidade de tempo substancial antes que a aprendizagem ocorra. Estas limitações são significativas quando consideramos a modelagem do usuário. Na modelagem *on-line* do aluno, espera-se que o procedimento seja realizado em tempo real, durante as interações com o mesmo.

Existem pelo menos quatro vantagens em relação ao uso de um CBI no que se refere à modelagem do usuário: (i) Técnica bastante intuitiva e simples de ser usada; (ii) Retorna uma probabilidade, que é mais simples do que utilizar uma escala arbitrária; (iii) Não requer grande quantidade de dados antes que a aprendizagem inicie; (iv) É computacionalmente rápida na tomada de decisão.

Um CBI pode ser aplicado na aprendizagem de tarefas onde cada instância x é descrita através de um conjunto de valores de atributos, e onde a função de classificação $f(x)$ pode assumir qualquer valor a partir de um conjunto finito V . Deve-se dispor de um conjunto de exemplos para o treinamento da função $f(x)$ e uma nova instância é apresentada, descrita através de uma tupla de valores de atributos $\langle a_1, a_2, \dots, a_n \rangle$. A abordagem Bayesiana para classificar uma nova instância consiste em associar o valor de $f(x)$ mais provável, v_{map} , dado os valores dos atributos $\langle a_1, a_2, \dots, a_n \rangle$ que descrevem a instância.

$$v_{map} = \arg \max P(v_j | a_1, a_2 \dots a_n), \text{ com } v_j \in V \quad (6.1)$$

Usando o Teorema de Bayes, a expressão (6.1) pode ser re-escrita como:

$$v_{map} = \arg \max \frac{P(a_1, a_2 \dots a_n | v_j)P(v_j)}{P(a_1, a_2 \dots a_n)}, \text{ com } v_j \in V \quad (6.2)$$

$$= \arg \max P(a_1, a_2, \dots, a_n | v_j)P(v_j) \in V \quad (6.3)$$

Agora, é necessário estimar os dois termos da equação (6.3), baseado nos dados de treinamento. É fácil estimar cada um dos $P(v_j)$. Basta contar a frequência com que cada valor v_j ocorre nos dados de treinamento. Entretanto, para estimar os diferentes termos $P(a_1, a_2, \dots, a_n | v_j)$ nesta forma é praticamente impossível, a menos que se tenha um conjunto de dados de treinamento muito grande. O problema é que, com um conjunto de

dados muito grande, o número de termos é igual ao número das possíveis instâncias multiplicado pelo número dos possíveis valores v_j .

Na verdade, um CBI está baseado no pressuposto da simplificação de que, dado um valor v_j , os valores dos atributos tornam-se condicionalmente independentes entre si. Em outras palavras, o pressuposto consiste em: dado um valor v_j da instância, a probabilidade de se observar a conjunção a_1, a_2, \dots, a_n é dada somente pelo produto das probabilidades dos atributos, individualmente: $P(a_1, a_2, \dots, a_n | v_j) = \tilde{O}_i P(a_i | v_j)$. Substituindo esta equação em (6.3), temos a abordagem de um CBI, ou seja:

$$v_{CBI} = \arg \max P(v_j) \prod_i P(a_i | v_j) \quad (6.4)$$

onde v_{CBI} denota o valor de saída fornecido pelo CBI. Podemos observar que, para um CBI, o número de termos distintos $P(a_i | v_j)$ que devem ser estimados a partir dos dados de treinamento é exatamente igual ao número dos valores dos atributos multiplicado pelo número dos valores das probabilidades, o que representa um número muito menor em relação aos termos $P(a_1, a_2, \dots, a_n | v_j)$, anteriormente mostrados.

Resumindo, o método de aprendizagem CBI envolve uma etapa de aprendizagem, na qual os vários termos $P(v_j)$ e $P(a_i | v_j)$ são estimados, baseados em suas frequências sobre os dados de treinamento. O conjunto destas estimativas corresponde à hipótese a ser aprendida. Esta hipótese é então usada para classificar cada uma das novas instâncias, aplicando a equação descrita em (6.4).

A aplicação da técnica CBI, a geração do modelo de classificação e a “validação” foram desenvolvidos com o auxílio da ferramenta ARBAYES, desenvolvida pelo “Grupo de Pesquisa em Inteligência Artificial da UnB – GIA – UnB”, o qual mantém intercâmbio de pesquisa com o GIA – UFRGS. Uma representação gráfica do CBI gerado para classificar as classes de ECA a partir da análise das preferências destas classes pelos ‘recursos didáticos’ pode ser vista na Figura 6.16.

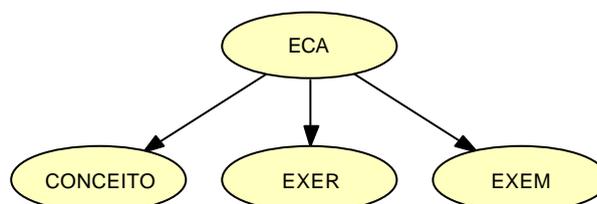


Figura 6.16: Representação gráfica do CBI para classificar um novo caso a partir da análise de suas preferências pelos 'recursos didáticos'

Associado a este CBI existe um conjunto de tabelas de probabilidades, correspondentes a $P(v_j)$ e $P(a_i | v_j)$. Por exemplo, a Tabela 6.9 corresponde às probabilidades *a priori* de um novo caso ‘ser’ de cada uma das classes de ECA. As Tabelas 6.10, 6.11 e 6.12 correspondem às tabelas de probabilidade condicionais relativas a $P(\text{Conceito} | \text{ECA})$, $P(\text{Exercício} | \text{ECA})$ e $P(\text{Exemplo} | \text{ECA})$, respectivamente.

Tabela 6.9: Tabela de probabilidades *a priori* de ser de uma classe de ECA

ECA = 'AA'	ECA = 'CG'	ECA = 'DA'	ECA = 'ASA'	ECA = 'RS'
0,25641	0,205128	0,230769	0,205128	0,102564

Tabela 6.10:Tabela de probabilidades condicionais para o uso de 'Conceito'

Intensidade de uso de 'Conceitos'	ECA = 'AA'	ECA = 'CG'	ECA = 'DA'	ECA = 'ASA'	ECA = 'RS'
Alta	0,583333	0,3	0,27	0,2	0,166667
Média	0,25	0,3	0,454545	0,4	0,333333
Baixa	0,166667	0,4	0,272727	0,4	0,5

Tabela 6.11:Tabela de probabilidades condicionais para o uso de 'Exercício'

Intensidade de uso de 'Exercício'	ECA = 'AA'	ECA = 'CG'	ECA = 'DA'	ECA = 'ASA'	ECA = 'RS'
Alta	0,166667	0,4	0,363636	0,4	0,333333
Média	0,333333	0,1	0,363636	0,4	0,5
Baixa	0,5	0,5	0,272727	0,2	0,166667

Tabela 6.12:Tabela de probabilidades condicionais para o uso de 'Exemplo'

Intensidade de uso de 'Exemplo'	ECA = 'AA'	ECA = 'CG'	ECA = 'DA'	ECA = 'ASA'	ECA = 'RS'
Alta	0,25	0,4	0,272727	0,2	0,666667
Média	0,416667	0,4	0,454545	0,4	0,166667
Baixa	0,333333	0,2	0,272727	0,4	0,166667

Na fase de treinamento do CBI, procedemos de forma idêntica à aplicação da AD, ou seja, num primeiro momento isolamos os indicadores relativos às preferências das classes de ECA pelos 'recursos didáticos' e, num segundo momento, consideramos somente os indicadores relativos às preferências pelas 'formas de apresentação'. Antes de proceder a aprendizagem da rede, realizamos a discretização dos dados, conforme descrito na seção 6.1.

Considerando que dispúnhamos de um conjunto de exemplos rotulados severamente limitado, utilizamos a forma extrema da validação cruzada múltipla, conhecida como o *método deixe um de fora* (HAYKIN, 2001). Neste caso, $(n - 1)$ exemplos são usados para treinar o modelo, e o modelo é validado testando-o sobre o exemplo deixado de fora. O experimento é repetido para um total de n vezes, cada vez deixando de fora um exemplo diferente para a validação. A seguir, apresentamos a *matriz de confusão*, correspondente aos resultados obtidos, referentes à preferência das classes de ECA pelos 'recursos didáticos' (Tabela 6.13).

Conforme o previsto, os resultados foram muito pouco satisfatórios. Apenas uma das classes de ECA (1-'AA') foi aceitavelmente discriminada. Quanto às demais, nada se pode afirmar. O erro ficou em 74,28%, ou seja, dos 35 sujeitos da amostra, 26 foram classificados incorretamente.

Da mesma forma que na situação anterior, no teste realizado com o CBI, levando em consideração apenas as preferências das classes de ECA pelas 'formas de apresentação', utilizamos o método *deixe um de fora*. Os resultados na *matriz de confusão* são mostrados na Tabela 6.14. Neste caso, nenhuma das classes de ECA foi discriminada adequadamente, considerando apenas estas variáveis-atributo. Apenas 25,71% dos casos foram classificados corretamente.

Tabela 6.13: Resultados da classificação através do CBI considerando apenas as preferências pelos 'recursos didáticos'

ECA	Classes de ECA previstas					Total
	1	2	3	4	5	
Classes de ECA originais						
1	6	1	1	1	1	10
2	2	1	2	1	1	7
3	2	1	0	4	1	8
4	1	1	3	1	1	7
5	0	1	1	0	1	3
%						
1	60,0%	10,0%	10,0%	10,0%	10,0%	100,0%
2	28,6%	14,3%	28,6%	14,3%	14,3%	100,0%
3	25,0%	12,5%	0,0%	50,0%	12,5%	100,0%
4	14,3%	14,3%	42,8%	14,3%	14,3%	100,0%
5	0,0%	33,3%	33,3%	0,0%	33,3%	100,0%

Tabela 6.14: Resultado da classificação através do CBI considerando apenas as preferências pelas 'formas de apresentação'

ECA	Classes de ECA previstas					Total
	1	2	3	4	5	
Classes de ECA originais						
1	3	2	3		2	10
2	2	2	1		2	7
3	1	1	1	4	1	8
4		1	3	2	1	7
5	1			1	1	3
%						
1	30,0%	20,0%	30,0%		20,0%	100,0%
2	28,57%	28,57%	14,28%		28,57%	100,0%
3	12,50%	12,50%	12,50%	50,0%	12,50%	100,0%
4		14,28%	42,86%	28,57%	14,28%	100,0%
5	33,33%			33,33%	33,3%	100,0%

6.5.3 Árvores de Decisão

A indução de uma árvore de decisão corresponde a um dos algoritmos de aprendizagem mais simples e que apresentam bons resultados (RUSSEL & NORVIG, 1995). O algoritmo de aprendizagem usa como entrada um vetor de valores das variáveis-atributos, juntamente com o valor da variável-classe (conjunto de aprendizagem). O problema genérico da técnica consiste em encontrar uma expressão simbólica que prediz a classe de um novo caso (conjunto de teste), selecionado aleatoriamente a partir da mesma população (FENG & MICHIE, 1994). A exatidão do método é medida a partir dos resultados obtidos, ou seja, considerando o número de casos classificados corretamente. O pressuposto básico é de que tanto o conjunto de dados de treinamento, quanto o conjunto de dados de teste sejam aleatoriamente selecionados a partir da mesma fonte de dados.

A aplicação da técnica, a geração do modelo de classificação e a “validação” foram realizados com o auxílio da ferramenta ‘See5’, disponível por <http://www.rulequest.com/see5-info.html>. Os resultados são expressos como uma árvore

de decisão e como um conjunto de regras do tipo ‘Se ... Então ... ‘. A análise dos resultados da classificação através da árvore de decisão gerada é realizada através de alguns parâmetros estatísticos associados.

Com base nos valores das variáveis-atributo fornecidas pelo conjunto de dados de treinamento, a árvore de decisão gerada mapeia, em direção às folhas, a designação de uma das classes consideradas. Cada folha da árvore é seguida por uma anotação do tipo (n) ou (n/m) , onde n corresponde ao número de casos no arquivo de dados que foram mapeados nessa folha e, m , se aparecer, corresponde ao número de casos que foram classificados incorretamente pela folha.

A avaliação da árvore de decisão gerada a partir dos dados de treinamento é dada pelo número de folhas e pelo erro. O erro, por sua vez, é dado pelo número de casos classificados incorretamente e pelo percentual correspondente. A *matriz de confusão* mostra a tabela de classificação e define exatamente o tipo dos erros cometidos.

Outra facilidade da ferramenta ‘See5’ é o seu mecanismo de converter árvores em coleções de regras. Cada regra do conjunto consiste de:

- Número da regra: serve para a sua identificação.
- Estatística: $(n, lift\ x)$ ou $(n/m, lift\ x)$ – serve para analisar o desempenho da regra. O valor de ‘ n ’ corresponde ao número de casos cobertos pela regra e ‘ m ’, se aparecer, mostra quantos casos não pertenciam à classe predita pela regra. A exatidão da regra é estimada pela razão de Laplace $(n - m + 1) / (n + 2)$. A medida ‘ $lift\ x$ ’ é o resultado da divisão da exatidão da regra pela frequência relativa da classe predita no conjunto de treinamento. Este resultado nos diz o quão informativa é a regra em relação ao conhecimento prévio.
- Uma ou mais condições que devem ser satisfeitas se a regra é aplicável.
- A classe predita pela regra.
- Um valor entre 0 e 1 que indica a confiança com que a predição foi feita.

Na fase de treinamento, procedemos de forma idêntica à aplicação da AD e do CBI, ou seja, num primeiro momento isolamos os indicadores relativos às preferências das classes de ECA pelos ‘recursos didáticos’ e, num segundo momento, consideramos somente os indicadores relativos às preferências pelas ‘formas de apresentação’.

A Figura 6.17 mostra os resultados da classificação quando consideramos apenas as preferências das classes de ECA pelos ‘recursos didáticos’. Neste caso, observamos que a árvore gerada possui nove (9) folhas e que, em todas elas, pelo menos um (1) caso não foi classificado corretamente, com n variando entre 2 e 6 casos. O erro foi de 37,1% dos casos. Isto demonstra a dificuldade da técnica para separar as classes de ECA considerando apenas as preferências pelos ‘recursos didáticos’, a partir do conjunto de dados de treinamento fornecidos.

Quanto à análise da *matriz de confusão* gerada neste caso, observamos que entre as cinco classes de ECA, a árvore de decisão gerada classificou um caso ‘AA’ como ‘ASA’; um caso ‘CG’ como ‘AA’; nenhum caso ‘DA’ foi classificado como ‘DA’; dois casos ‘ASA’ foram classificados como ‘AA’; e, finalmente, um caso ‘RS’ foi classificado como ‘CG’. Portanto, a conclusão a que se chega é que a classe ‘DA’ não foi discriminada pela técnica, considerando apenas os indicadores da preferência pelos ‘recursos didáticos’.

Quanto à análise do conjunto de regras, à exceção da regra 7, todas as demais são pouco informativas em relação ao conhecimento prévio, dado pela frequência relativa

de 'ser de uma classe de ECA'. Em relação ao nível de confiança das regras geradas, todos eles estão em torno de 50%, o que de certa forma é baixo dentro de uma escala de 0% a 100%.

```
See5 [Release 1.13]      Sun Nov 23 12:48:13 2003
Options:
  Generating rules
Class specified by attribute `ECA'
Read 35 cases (4 attributes) from eca.data
Decision tree:
EXER > 46.33:
: ... CON <= 25.41: 1 (2/1)
:   CON > 25.41: 4 (4/1)
EXER <= 46.33:
: ... EXER > 40.16: 2 (5/2)
:   EXER <= 40.16:
:     ... EXER <= 18.06:
:       ... EXEM <= 21.62: 1 (6/3)
:         EXEM > 21.62: 2 (4/1)
:       EXER > 18.06:
:         ... EXEM <= 27.05:
:           ... EXER <= 37.71: 1 (5/1)
:             EXER > 37.71: 4 (4/2)
:           EXEM > 27.05:
:             ... EXEM <= 30.37: 5 (3/1)
:               EXEM > 30.37: 1 (2/1)
Extracted rules:
Rule 1: (2/1, lift 1.7)
  CON <= 25.41
  EXER > 46.33
  -> class 1 [0.500]
Rule 2: (24/15, lift 1.3)
  EXER <= 40.16
  -> class 1 [0.385]
Rule 3: (4/1, lift 3.3)
  EXER <= 18.06
  EXEM > 21.62
  -> class 2 [0.667]
Rule 4: (5/2, lift 2.9)
  EXER > 40.16
  EXER <= 46.33
  -> class 2 [0.571]
Rule 5: (4/1, lift 3.3)
  CON > 25.41
  EXER > 46.33
  -> class 4 [0.667]
Rule 6: (4/2, lift 2.5)
  EXER > 37.71
  EXER <= 40.16
  -> class 4 [0.500]
Rule 7: (3/1, lift 7.0)
  EXEM > 27.05
  EXEM <= 30.37
  -> class 5 [0.600]

Default class: 1
E
valuation on training data (35 cases):
      Decision Tree          Rules
-----
      Size      Errors      No      Errors
-----
      9      13(37.1%)      7      13(37.1%)  <<
-----
      (a)      (b)      (c)      (d)      (e)      <-classified as
-----
      9
      1          6
      3          2
      2          5
          1          2
          (a): class 1
          (b): class 2
          (c): class 3
          (d): class 4
          (e): class 5
```

Figura 6.17:Árvore de Decisão gerada e os resultados obtidos quando consideramos apenas as preferências das classes de ECA pelos 'recursos didáticos'

A Figura 6.18 mostra os resultados da classificação, levando em consideração apenas as preferências das classes de ECA pelas 'formas de apresentação'.

```
See5 [Release 1.13]      Sun Nov 23 12:55:55 2003
Options:
  Generating rules
Class specified by attribute `ECA'
Read 35 cases (11 attributes) from eca.data
Decision tree:
V301 > 15.57:
: ... V101 <= 4.49: 2 (4/1)
:   V101 > 4.49: 5 (3)
V301 <= 15.57:
: ... V204 > 7.94:
```

```

: ...V101 <= 3.87: 3 (3/1)
: V101 > 3.87: 4 (2)
V204 <= 7.94:
: ...V201 <= 3.37:
: ...V203 > 0: 1 (6)
: V203 <= 0:
: ...V101 <= 0: 1 (2/1)
: V101 > 0: 3 (5/2)
V201 > 3.37:
: ...V103 > 14.67: 2 (2)
: V103 <= 14.67:
: ...V202 <= 1.39: 4 (3)
: V202 > 1.39:
: ...V205 <= 10.66: 1 (3/1)
: V205 > 10.66: 3 (2)

Extracted rules:
Rule 1: (28/18, lift 1.3)
V301 <= 15.57
-> class 1 [0.367]
Rule 2: (2, lift 3.7)
V103 > 14.67
V201 > 3.37
V204 <= 7.94
-> class 2 [0.750]
Rule 3: (4/1, lift 3.3)
V101 <= 4.49
V301 > 15.57
-> class 2 [0.667]
Rule 4: (8/3, lift 2.6)
V101 > 0
V203 <= 0
V204 <= 7.94
-> class 3 [0.600]
Rule 5: (3/1, lift 2.6)
V101 <= 3.87
V204 > 7.94
-> class 3 [0.600]
Rule 6: (3, lift 4.0)
V103 <= 14.67
V201 > 3.37
V202 <= 1.39
V301 <= 15.57
-> class 4 [0.800]
Rule 7: (2, lift 3.7)
V101 > 3.87
V204 > 7.94
-> class 4 [0.750]
Rule 8: (3, lift 9.3)
V101 > 4.49
V301 > 15.57
-> class 5 [0.800]

Default class: 1

Evaluation on training data (35 cases):
-----
Decision Tree          Rules
-----
Size      Errors      No      Errors      <<
-----
11      6(17.1%)      8      6(17.1%)
-----
(a)      (b)      (c)      (d)      (e)      <-classified as
-----
9
1      5      1
1      7
      1      1      5
      3
      (a): class 1
      (b): class 2
      (c): class 3
      (d): class 4
      (e): class 5

```

Figura 6.18:Árvore de Decisão gerada e os resultados obtidos considerando apenas as preferências das classes de ECA pelas ‘formas de apresentação’

Neste caso, observamos que a árvore gerada possui onze (11) folhas e o erro foi 17,1% dos casos. Apesar de ainda ser alto, neste caso o erro foi bem inferior à situação anterior. Isto demonstra que tanto em relação à preferência das classes de ECA pelos ‘recursos didáticos’, quanto pelas ‘formas de apresentação’, existiu dificuldade para a técnica separar as classes de ECA a partir do conjunto de dados de treinamento fornecidos.

A matriz de confusão correspondente à árvore de decisão gerada a partir dos indicadores da preferência das classes de ECA pelas ‘formas de apresentação’ mostrou que, um caso ‘AA’ foi classificado como ‘DA’; entre os dois casos ‘CG’ classificados incorretamente, um foi classificado como ‘AA’ e o outro como ‘DA’; um caso ‘DA’ foi classificado como ‘AA’; entre os dois casos ‘ASA’ classificados incorretamente, um foi

classificado como ‘CG’ e o outro como ‘DA’; e finalmente, todos os casos ‘RS’ foram classificados corretamente.

Quanto à análise do conjunto de regras, observamos que para este caso, de um modo geral, todas as regras se mostraram um pouco mais informativas em relação ao conhecimento prévio, assim como o nível de confiança das regras, de um modo geral, são superiores a 50%.

6.6 Considerações sobre o Uso das Técnicas de Classificação

Após a investigação das técnicas de aprendizado supervisionado (ou classificação): *Análise Discriminante (AD)*, *Classificador Bayesiano Ingênuo (CBI)* e *Árvores de Decisão*, o próximo passo corresponde a avaliação comparativa dessas técnicas, com o objetivo de decidir sobre aquela que melhor se adequaria à solução do problema de diagnosticar o ECA do aluno a partir da observação de sua TA durante uma sessão de estudo na Web.

A avaliação comparativa dessas técnicas passa pela análise da exatidão na classificação e pela estimativa das taxas de erro. Neste trabalho, essa análise ficou prejudicada, dado a severa limitação do tamanho da amostra de dados disponível, usada na aprendizagem. Os parâmetros estatísticos associados a cada uma dessas técnicas mostraram isso, conforme é apresentado a seguir.

Na AD, tanto o coeficiente Lambda, quanto o nível de significância das funções discriminantes, não se mostraram estatisticamente significantes, ou seja, no caso do coeficiente Lambda, os resultados não permitem que se refute a hipótese de que não existem diferenças entre as classes de ECA. Isto vale tanto considerando os indicadores da preferência das classes de ECA pelo ‘recursos didáticos’, quanto considerando os indicadores da preferência pelas ‘formas de apresentação’. Quanto aos níveis de significância, os valores obtidos, tanto num caso, quanto no outro, também não permitem que se refute a hipótese de que não existem diferenças entre as classes de ECA.

Em relação à técnica CBI, a capacidade de classificação foi muito baixa e, conseqüentemente, a taxa de erro muito alta. Observamos que apenas a classe ‘AA’ foi medianamente discriminada a partir a partir das variáveis discriminantes usadas e do conjunto de dados de aprendizagem disponíveis. Por ser uma técnica que enfoca a abordagem probabilística, temos especial interesse na mesma, uma vez que o problema de diagnosticar o ECA do aluno *on-line* a partir da observação de sua TA durante uma sessão de aprendizagem certamente não é uma tarefa trivial e determinística. Ela exige que se conviva com um conhecimento incerto por envolver a modelagem em computador de uma característica pedagógica individual de um agente humano.

Em relação à técnica usada em AM, ou seja, árvore de decisão, conforme já era esperado, os parâmetros estatísticos não apontaram em direção à exatidão na classificação, e também aparecem associados a altas taxas de erro.

A Tabela 6.15 apresenta o mapa-resumo relativo ao desempenho das técnicas de aprendizagem supervisionada (classificação) analisadas neste trabalho. Os valores estão representando o erro na classificação dos casos, a partir dos dados de treinamento fornecidos. Na Tabela, a informação sobre o erro é apresentada por classe de ECA e pela situação analisada, ou seja, como a técnica classifica os casos considerando, separadamente, as preferências das classes de ECA pelos ‘recursos didáticos’ e, depois, pelas ‘formas de apresentação’. Conforme foi mencionado anteriormente, esta divisão

dos indicadores da preferência das classes de ECA foi utilizada para evitar, especialmente, o viés da redundância. A análise das técnicas através desta divisão dos indicadores também nos permitiu identificar melhor aquela categoria de indicadores que melhor discriminava as classes de ECA.

Tabela 6.15: Mapa-resumo do desempenho das técnicas de classificação analisadas

ECA	Análise Discriminante		CBI		Árvores de Decisão	
	Recursos Didáticos	Formas de Apresentação	Recursos Didáticos	Formas de Apresentação	Recursos Didáticos	Formas de Apresentação
AA	30,0%	10,0%	40,0%	70,0%	10,0%	10,0%
CG	57,1%	42,9%	85,7%	71,4%	14,3%	26,6%
DA	62,5%	25,0%	100,0%	87,5%	100,0%	12,5%
ASA	57,1%	42,9%	85,7%	71,4%	28,6%	28,6%
RS	0,0%	0,0%	66,6%	66,6%	33,3%	0,0%

Pela análise deste mapa-resumo (Tabela 6.15), podemos observar que a árvore de decisão foi a técnica que melhor classificou os casos. Através desta técnica observamos que o ECA ‘AA’ se discriminou tanto pelo uso que fez dos ‘recursos didáticos’, quanto pelo uso que fez das ‘formas de apresentação’. O ECA ‘CG’ se discriminou melhor pelo uso que fez dos ‘recursos didático’. O ECA ‘DA’ se discriminou somente pelo uso que fez das ‘formas de apresentação’. O uso que esta classe fez dos ‘recursos didáticos’ não a discrimina. O ECA ‘ASA’ foi o que apresentou maior dificuldade de ser discriminado. Na análise qualitativa, o especialista achou semelhança entre o comportamento desta classe com a classe ‘DA’. Finalmente, o ECA ‘RS’ foi completamente discriminado pelo uso que fez das ‘formas de apresentação’.

A análise do conjunto de regras, por sua vez, nos permitiu identificar os indicadores das preferências das classes de ECA que de fato as discriminaram, pelo menos em relação ao conjunto de dados de aprendizado disponível. Por exemplo, a classe ‘AA’, que foi discriminada pelo uso que fez dos ‘recursos didáticos’, as regras que a discriminou levaram em consideração, especialmente, o uso que a classe fez do recurso de ‘Exercício’ (Figura 6.17, Regras 1 e 2). A classe ‘CG’ que foi discriminada, especialmente, pelo uso que fez dos ‘recursos didáticos’, as regras que a discriminou levaram em consideração o uso que esta classe fez dos recursos de ‘Exercício’ e ‘Exemplo’ (Figura 6.17, Regras 3 e 4).

Por outro lado, em relação a classe ‘DA’ que não foi discriminada pelo uso que fez dos ‘recursos didáticos’ e sim pelo uso que fez das ‘forma de apresentação’, observamos que as regras que a discriminou levaram em consideração o uso da forma textual de apresentação de ‘Conceitos’, a falta de uso do ‘Exercício’ de escolha simples e a alta intensidade com que usou o ‘Exercício’ na forma de ‘preencher lacunas’ (Figura 6.18, Regras 4 e 5).

Infelizmente, a comparação destes resultados com os resultados da análise qualitativa realizada pelo especialista não foi possível, uma vez que os parâmetros utilizados em uma e outra são diferentes. Na análise qualitativa, os parâmetros relativos a preferência das classes de ECA pelos ‘recursos didáticos’ e ‘formas de apresentação’ correspondiam a valores médios das classes. Na técnica *árvore de decisão*, estes parâmetros são analisados considerando todos os casos de cada uma das classes.

7 CONCLUSÕES E TRABALHOS FUTUROS

Nesta tese apresentamos a metodologia quase-experimental, com o objetivo de modelar o ECA do aluno. Esta metodologia compreendeu duas fases: (i) geração das classes de ECA a partir da aplicação de um teste psicológico em uma amostra da população-alvo; e (ii) desenvolvimento do módulo de ensino experimental e estudo das TAs-padrão das classes de ECA, a partir da observação de seus comportamentos durante a execução de uma sessão de estudo na Web. A primeira fase foi descrita através de análises estatísticas, pela aplicação das técnicas de *Análise Fatorial* e *Análise de Cluster*. A segunda fase foi descrita como um processo de descoberta de conhecimento, conforme aquele apresentado por Fayyad et al. (1996). Este processo incluiu desde a compreensão do sistema de conhecimento a ser desenvolvido, até a compreensão e interpretação dos resultados obtidos.

Neste Capítulo, apresentamos algumas conclusões, avaliamos as contribuições do trabalho, as limitações do contexto estudado e as alternativas de trabalhos futuros.

7.1 Conclusões

O processo de descoberta de conhecimento descrito nesta tese teve como objetivo modelar uma característica individual humana qual seja, o *Estilo Cognitivo de Aprendizagem* (ECA), a partir da observação da trajetória de aprendizagem durante uma sessão de estudo na Web. No contexto considerado, o ECA do aluno representa um construto psicopedagógico, que reflete o seu estágio de desenvolvimento cognitivo, de acordo com a taxonomia de Bloom.

O que diferencia este estudo daqueles encontrados na literatura é a forma como o ECA do aluno é modelado. Nossa proposta de modelagem para esta característica individual baseia-se na análise das interações do aluno com o ambiente, ao invés de utilizar questionários ou testes psicológicos. Essas práticas (questionários ou testes) normalmente aborrecem os seus usuários, especialmente quando o número de questões é grande, o tempo de resposta é controlado e o nível de atenção exigido naquele momento é fundamental. Além disso, e especialmente por isso, o acesso do sistema de ensino ao ECA do aluno permitirá ao mesmo acompanhar e facilitar ao aluno o desenvolvimento de suas habilidades cognitivas, das mais simples (conhecimento) as mais abstratas (capacidade para realizar análise e síntese), tornando o seu processo de aprendizagem mais efetivo e eficaz.

A descoberta de conhecimento sobre como as classes de ECA interagem com os recursos pedagógicos durante uma sessão de estudo na Web não é uma tarefa trivial e nem observável diretamente a partir do *log* de navegação. Ela envolveu uma atividade de aprendizagem cognitiva e uma atividade de aprendizagem de máquina. Os dados usados foram gerados a partir das interações de uma amostra de alunos, selecionados na

população-alvo. Estes dados, que foram computados de acordo com a Tabela 4.2, foram gerados durante uma sessão de estudo, onde estes alunos executaram o módulo de ensino experimental – TDMA – desenvolvido especialmente para este fim.

Cada caso no arquivo de dados de treinamento dos algoritmos de aprendizagem correspondeu a um sujeito da amostra, e as informações nele contidas corresponderam aos: (i) conjunto de variáveis, indicadoras das preferências das classes de ECA pelos ‘recursos didáticos’ e ‘formas de apresentação’; e (ii) conjunto de variáveis, indicadoras da velocidade de processamento das classes de ECA nos ‘recursos didáticos’ e ‘formas de apresentação’. O arquivo de treinamento era formado por 35 entradas, com 26 valores relativos às variáveis-atributo, e com o valor do ECA correspondente, relativo à variável-classe.

No estudo que fizemos, consideramos três técnicas de classificação: Análise Discriminante, Classificador Bayesiano Ingênuo e Árvores de Decisão. Os resultados preliminares do nosso estudo foram apresentados na Tabela 6.15.

Até o presente momento, estivemos preocupados com a descoberta de conhecimento sobre o domínio considerado (comportamento das classes de ECA) e com a escolha daquele algoritmo com a melhor resposta para a realização do diagnóstico do ECA do aluno *on-line*. Embora os resultados não tenham se mostrado muito relevantes, especialmente considerando a severa limitação em relação ao número de casos no arquivo de aprendizagem, nossa meta consiste em continuar investigando este domínio, através do desenvolvimento de um laboratório de teste, que implemente mais de uma técnica para a realização do diagnóstico do ECA do aluno.

O laboratório de teste será desenvolvido no contexto do Projeto AdaptWeb⁶ (FREITAS, 2002). A cada novo curso implementado no ambiente AdaptWeb, seus alunos-usuários terão suas interações com o ambiente monitoradas e registradas em arquivos de *log*, para posterior análise do comportamento e técnicas de mineração de dados para a modelagem de perfis cognitivos de aprendizagem na Web.

7.2 Discussão das Contribuições

Apresentamos a discussão das contribuições desta tese através dos resultados obtidos e de como estes resultados responderam as nossas questões de pesquisa, enumeradas no Capítulo 4. Para respondê-las, iniciamos pela segunda questão, seguida da primeira e terceira.

Questão de pesquisa 2: quais são os indicadores (ou parâmetros) de uma trajetória de aprendizagem que melhor discriminam a trajetória típica de cada uma das classes de ECA consideradas?

A investigação sobre estes indicadores demandou a realização de uma análise exploratória para a busca e aquisição do conhecimento sobre COMO as classes de ECA aprendem na Web. Ao invés de estudar O QUE o aluno aprendeu, nosso maior interesse foi investigar COMO ele aprende, a partir da observação do seu comportamento. A aquisição deste conhecimento era essencial para possibilitar o diagnóstico *on-line* do aluno remoto.

A análise exploratória (Capítulo 6) nos permitiu inferir um conjunto de hipóteses sobre as trajetórias de aprendizagem, típicas de cada uma das classes de ECA consideradas. Através deste conjunto de hipóteses identificamos os principais

⁶ Homepage <http://www.inf.ufrgs.br/~tapejara/adaptweb>.

indicadores, que melhor poderiam discriminar as classes de ECA para a população-alvo, conforme é descrito na Seção 6.3.7. Até o presente momento, obtivemos uma validação apenas *qualitativa*, junto ao especialista, deste conjunto de hipóteses, conforme é descrito na seção 6.5.

Além da análise exploratória, ainda obtivemos pistas importantes sobre estes indicadores, especialmente quando analisamos as *árvores de decisão*, para a classificação das classes de ECA, na Seção 6.5.3. Esta técnica tem a grande vantagem de permitir a interpretação do modelo obtido. Através dela identificamos os indicadores que melhor discriminam cada uma das classes de ECA.

Questão de pesquisa 1: como automatizar o diagnóstico on-line do Estilo Cognitivo de Aprendizagem do aluno remoto a partir da observação e análise da sua trajetória de aprendizagem em um Ambiente de Ensino e Aprendizagem na Web?

Mesmo partindo de uma avaliação *qualitativa* sobre o conhecimento adquirido ao longo deste trabalho, foi possível delinear o *modelo de conhecimento* necessário à execução do diagnóstico cognitivo do ECA do aluno, para a população-alvo, de forma *independente* de implementação.

Conforme mencionado anteriormente, realizar o diagnóstico cognitivo *on-line* do ECA do aluno remoto é uma típica tarefa de *classificação*. Schreiber et al. (2000) descreveram a tarefa de classificação como uma atividade de caracterização de um objeto (neste caso o aluno remoto), em termos da classe que ele pertence (neste caso as classes de ECA consideradas). O conhecimento adquirido sobre as classes de ECA provê, para cada uma delas, as restrições sobre os valores das características a elas associadas (neste caso, as características correspondem as variáveis indicadoras associadas às TAs-padrão de cada classe).

A automatização do diagnóstico deve incluir procedimentos automatizados, que realizem:

- O processo de limpeza e transformação dos dados do arquivo de *log*;
- O processo de pré-processamento dos dados;
- O processo de treinamento e geração do mecanismo de classificação;
- A atualização do modelo do aluno.

A modelagem computacional do ECA do aluno está sendo pensada de forma integrada ao *modelo do aluno*, conforme apresentamos a seguir (Figura 7.1).

Questão de pesquisa 3: como automatizar a aquisição do conhecimento necessário para realizar o diagnóstico on-line (ou classificação) do ECA do aluno remoto?

Em um Sistema de Conhecimento, o conhecimento necessário para implementar alguma tarefa, i.é, *classificação, diagnóstico, avaliação*, etc., conforme aquelas mencionadas em Schreiber et al. (2000), pode ser obtido a partir do especialista, ou a partir de um agente artificial que aprende através da experiência. No primeiro caso, o especialista fornece a informação necessária para a execução da tarefa, com base no conhecimento do domínio já estabelecido e organizado. No segundo caso, Russel & Norvig (1995) comentam que, “*sempre que o projetista do Sistema de Conhecimento dispuser de conhecimento incompleto sobre o ambiente, a aprendizagem de máquina (AM) é a única forma de que um agente artificial tem para adquirir aquilo que ele precisa conhecer*” (página 523).

Considerando que não dispúnhamos do conhecimento necessário para realizar a tarefa de classificação do ECA do aluno a partir da observação de sua TA, nos restava a segunda alternativa, ou seja, induzir o conhecimento a partir de exemplos. Entretanto,

como os exemplos disponíveis eram muito limitados em relação ao tamanho da amostra, buscamos um mínimo de compreensão sobre o domínio a ser modelado através da análise exploratória e investigação de algumas técnicas de aprendizagem supervisionada. O estudo que fizemos nos conduziu ao conhecimento mínimo necessário para induzir, automaticamente, o modelo de classificação a partir de exemplos. A automatização deste processo é essencial, uma vez que a investigação manual consome muito tempo e, mais do que isto se restringe aos dados disponíveis no momento em que ela é realizada.

Portanto, neste caso, fica plenamente justificável o uso das técnicas de AM que têm sido utilizadas com sucesso, especialmente aquelas que se baseiam no paradigma de aprendizagem indutiva através de exemplos. Assim, até o presente momento, podemos afirmar que, através do trabalho realizado, foi possível vislumbrar uma solução para a terceira questão. A partir deste ponto, nosso trabalho deve continuar através da coleta de mais exemplos rotulados, ou seja, submeter ao módulo de ensino experimental um número substancial de sujeitos que tenham seu ECA já identificado através do Teste Ross e, a partir de então, tornar possível o sucesso da aplicação de algoritmos de aprendizagem supervisionada.

7.3 As Limitações do Contexto Estudado

- O estudo desenvolvido neste trabalho enfocou uma população específica, de técnicos e engenheiros, funcionários de uma empresa de telecomunicações, parceira no Projeto Tapejara.
- O teste Ross, que acessa o estágio de desenvolvimento das habilidades cognitivas superiores do pensamento humano, ou seja, habilidades de *análise*, *síntese* e *avaliação*, apresenta uma série de limitações em relação à sua aplicação: (i) é muito extenso e exaustivo uma vez que contém 105 questões, que exigem a leitura e interpretação atenta, com tempo de resposta controlado; (ii) deve ser aplicado somente por professores certificados, orientadores, psicólogos escolares ou qualquer pessoa qualificada para tal; (iii) o teste não pode ser aplicado via computador, o que dificulta bastante o trabalho de leitura e digitação das respostas, de modo que as mesmas possam ser lidas diretamente por um pacote estatístico.
- O instrumento usado para estudar as TAs, ou módulo de ensino experimental TDMA foi construído, sob o ponto de vista pedagógico, de forma um tanto alheia às habilidades cognitivas sendo avaliadas.
- O conjunto de exemplos disponibilizados pelo experimento não foi significativo ou suficiente para explicar os padrões de comportamento das classes de ECA, de forma compreensível a partir do uso de técnicas de AM.

7.4 Trabalhos Futuros

Acreditamos que o conhecimento adquirido neste estudo nos permitirá avançar em direção a construção de um Ambiente Adaptativo de Ensino e Aprendizagem na Web, que efetivamente possa apoiar o professor, de forma *on-line*, na difícil tarefa de assistir o processo de aprendizagem do aluno remoto, estimulando o desenvolvimento de suas habilidades cognitivas.

Os principais requisitos para implementar o modelo de adaptação estão relacionados a três dimensões do conhecimento que o sistema precisa conhecer, relacionadas a um processo de aprendizagem: (i) organização de conteúdos (*o que ensinar*); (ii) comportamento de aprendizagem do aluno (ou trajetória de aprendizagem que forneçam pistas sobre *como ensinar*); e (iii) estratégias pedagógicas (*como ensinar* um aluno que pertence a uma específica classe de ECA).

Sobre a dimensão *organização de conteúdos*, em sua elaboração precisamos levar em consideração não somente os níveis de conhecimento do aluno sobre os conteúdos, mas também as habilidades e processos cognitivos conforme a taxonomia de Bloom. Sobre a dimensão *comportamento de aprendizagem do aluno*, precisamos refinar e aprofundar os estudos sobre os indicadores de aprendizagem a serem usados no reconhecimento automático do ECA do aluno remoto, assim como precisamos analisar as técnicas de AM e classificação que melhor se ajustam aos requisitos de implementação do módulo de diagnóstico do ECA do aluno. Finalmente, sobre a dimensão *estratégias pedagógicas*, é necessário especificar e modelar computacionalmente estratégias que possibilitem ao aluno o desenvolvimento de suas habilidades cognitivas, tanto em profundidade, quanto em extensão.

A modelagem computacional do ECA do aluno está sendo pensada de forma integrada ao *modelo do aluno* (Figura 7.1).

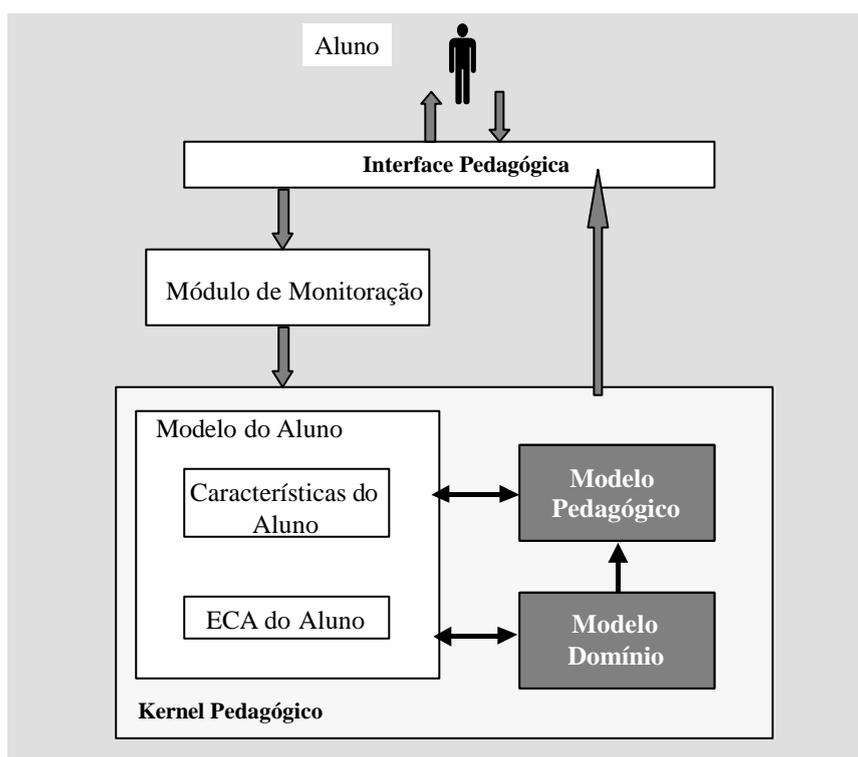


Figura 7.1: O estilo cognitivo de aprendizagem no modelo do aluno

A interface pedagógica faz a mediação entre todas as interações do aluno com o Ambiente de Ensino e Aprendizagem. O módulo de monitoração registra no arquivo de log todas as informações relacionadas às interações do aluno com o ambiente. Além disso, o módulo de monitoração extrai do arquivo de *log* o conjunto dos indicadores de aprendizagem, necessários para compor a TA realizada por um aluno. Uma TA pode compreender uma ou mais sessões de estudo.

A TA de um aluno representa o seu comportamento cognitivo observável durante uma sessão de estudo. Conforme mencionado anteriormente, este comportamento é concretamente observável através de um conjunto de *indicadores* de aprendizagem os quais, por sua vez, representam as preferências do aluno pelos ‘recursos didáticos’ e ‘formas de apresentação’, a velocidade de processamento e suas ações cognitivas (Figura 7.2).

Trajetória de Aprendizagem		
Preferências	Velocidade de Processamento	Ações Cognitivas

Figura 7.2: O modelo de uma *Trajetória de Aprendizagem* (TA)

O módulo de monitoração repassa os indicadores de aprendizagem ao kernel pedagógico, o qual implementa o algoritmo de classificação. No estudo que fizemos sobre as técnicas de aprendizagem supervisionada, por restrições de contexto, enfocamos somente a discriminação das classes de ECA considerando as preferências pelos ‘recursos didáticos’ e pelas ‘formas de apresentação’ (Seção 6.5). Da forma como foi controlada, a *velocidade de processamento* não foi considerada. Entretanto, como trabalhos futuros, é importante que se investigue melhor este conjunto de indicadores de aprendizagem, uma vez que eles podem refletir possíveis dificuldades do aluno, assim como podem refletir problemas com os conteúdos pedagógicos.

Até o presente momento, identificamos na análise exploratória as ações cognitivas típicas de cada uma das classes de ECA consideradas. Elas refletem padrões cognitivos sequenciais de como as classes de ECA abordam um processo de aprendizagem. Neste estudo, induzimos estes padrões, para cada uma das classes de ECA a partir da análise dos padrões sequências modal dos sujeitos pertencentes a uma delas. Identificar as ações cognitivas de um novo aluno é outra importante função do kernel pedagógico a ser implementado.

Uma vez identificado o ECA do aluno, o kernel pedagógico seleciona a estratégia de aprendizagem apropriada e a sugere ao aluno através da interface pedagógica. Considerando que o ECA do aluno corresponde ao nível de suas habilidades cognitivas, a decisão sobre a estratégia a ser sugerida depende do seu objetivo de aprendizagem. Por exemplo, o sistema adaptativo pode sugerir ao aluno uma atividade didática visando uma aprendizagem em profundidade sobre as habilidades cognitivas relativas aos conteúdos sendo estudado, ou pode sugerir uma atividade didática visando a ampliação de suas habilidades cognitivas.

A modelagem do ECA do aluno foi concebida para funcionar de modo complementar à modelagem de outras características do aluno, como por exemplo, o seu nível de conhecimento sobre os conteúdos sendo estudados.

Após o refinamento dos indicadores que compõem as trajetórias de aprendizagem padrão dos ECAs considerados, o próximo passo deste estudo corresponde ao projeto e implementação de um módulo computacional que realize o diagnóstico cognitivo *on-line* do aluno, de forma integrada com o módulo pedagógico que irá prover a adaptação dos conteúdos pedagógicos ao aluno remoto. A implementação deste módulo irá acontecer no ambiente AdaptWeb, conforme foi anteriormente mencionado.

REFERÊNCIAS

ANDERSON, L. W. et al. **A taxonomy for learning, teaching and assessing: a revision of Bloom's taxonomy of educational objectives**. New York: Longman, 2001. 302 p.

AÏMEUR, E. et al. CLARISSE: a machine learning tool to initialize student models. In: THE INTERNATIONAL CONFERENCE ON INTELLIGENT TUTORING SYSTEMS, 6., 2002, Biarritz. **Proceedings ...** Heidelberg: Springer-Verlag, 2002. p. 718 – 727.

BAJRAKTAREVIC, N.; HALL, W.; FULLICK, P. Incorporating learning styles in hypermedia environment: Empirical evaluation In: WORKSHOP ON ADAPTIVE HYPERMEDIA AND ADAPTIVE WEB-BASED SYSTEMS, 2003, Nottingham. **Proceedings ...** Hidelberg: Springer-Verlag, 2003.

BATISTA, G.E.A.P. **Pre-processamento de dados em aprendizado de máquina supervisionado**. 2003. Tese (Doutorado) - ICMC – USP, São Paulo.

BERCHT, M. **Em direção a agentes pedagógicas com dimensões afetivas**. 2001. Tese (Doutorado em Ciência da Computação) – Instituto de Informática, UFRGS, Porto Alegre.

BICA, F. et al. Metodologia de Construção do material instrucional em um Ambiente de Ensino Inteligente na Web. In: SIMPÓSIO BRASILEIRO DE INFORMÁTICA NA EDUCAÇÃO, 12., 2001. Vitória. **Anais ...** Vitória: SBC-UFES, 2001.

BLOOM, B. **Taxonomia dos objetivos educacionais: domínio cognitivo**. Porto Alegre: Globo, 1972.

BORGES, J.; LEVENE, M. **Data Mining of user navigation patterns**. Disponível em: <<http://citeseer.nj.nec.com/308898.html>>. Acesso em: 10 nov. 2003.

BRUSILOVSKY, P. Methods and techniques of adaptative hypermedia. In: BRUSILOVSKY, P. et al. (Ed.). **Adaptative Hypertext and Hypermedia**. Netherlands: Kluwer Academic, 1995. p. 1-43.

BULL, S. et al. User modeling in I-Help: what, why, when and how. In: INTERNATIONAL CONFERENCE IN USER MODELING, 8., 2001. **Proceedings ...** New York: Springer Wien, 2001.

BURNS, H. L.; CAPPS, C. G. Foundations of Intelligent Tutoring Systems: An Introduction. In: **Foundations of Intelligent Tutoring Systems**. Hillsdale: Lawrence Erlbaum Associates, 1988.

CARBONELL, J. G. Introduction: Paradigms for machine learning. In: CARBONELL, J. G. (Ed.). **Machine Learning Paradigms and Methods**. Cambridge: MIT Press, 1990. p. 1-9.

CARVER, C.A. et al. Enhancing student learning by incorporating learning styles into adaptive hypermedia. In: WORLD CONFERENCE ON EDUCATIONAL MULTIMEDIA AND HYPERMEDIA, Boston, 1996. **Proceedings ...** [S.l.], 1996. p.118-123.

COOLEY, R.; MOBASHER, B.; SRIVASTAVA, J. Web mining: information and pattern discovery on the World Wide Web. In: INTERNATIONAL CONFERENCE ON TOOLS WITH ARTIFICIAL INTELLIGENCE, 9., 1997, Newport Beach. **Proceedings ...** New York: IEEE Computer Society, 1997.

COOLEY, R.; MOBASHER, B.; SRIVASTAVA, J. Data preparation for mining World Wide Web browsing patterns. **Journal of Knowledge and Information Systems**, [S.l.], v. 1, n. 1, p. 1-27, 1999.

D'AMICO, C. B. **Aprendizagem estática e dinâmica em ambientes multiagentes de ensino-aprendizagem** 1999. Tese (Doutorado em Ciência da Computação) – Instituto de Informática, UFRGS, Porto Alegre.

DUFRESNE, A.; TURCOTTE, S. Cognitive style and its implications for navigations strategies. In: WORLD CONFERENCE ON ARTIFICIAL INTELLIGENCE IN EDUCATION, 8., 1997, Kobe. **Artificial Intelligence in Education**. Amsterdam: IOS, 1997.

FAYYAD, U. M. et al. From Data Mining to Knowledge Discovery: An Overview. In: FAYYAD, U. M. et al. **Advances in Knowledge Discovery and Data Mining**. Menlo Park: AAAI, 1996. p. 1-34.

FELDER, R.M.; SILVERMAN, L.K. Learning and Teaching Styles in Engineering Education. **Journal of Engineering in Education**, Washington, v. 78, n. 7, p. 674-681, 1988.

FENG, C; MICHIE, D. Machine Learning of Rules and Trees. In: MICHIE, D.; SPIEGELHALTER, D. J.; TAYLOR, C.C. (Ed.). **Machine Learning, Neural and Statistical Classification**. London: Ellis Horwood, 1994. p. 50-83.

FERREIRA, A. B. de H. **Novo Dicionário da Língua Portuguesa**. Rio de Janeiro: Nova Fronteira, 1986.

FORD, N.; CHEN, S.Y. Individual Differences, Hypermedia Navigation, and Learning: an Empirical Study. **Journal of Educational Multimedia and Hypermedia**, [S.l.], v. 9, n. 4, p. 281-311, 2000.

FREITAS, V. et al. AdaptWeb: an adaptive web-based courseware. In: INTERNATIONAL CONFERENCE ON INFORMATION AND COMMUNICATION TECHNOLOGIES IN EDUCATION, 2002. Badajoz. **Proceedings ...** [S.l.: s. n.], 2002. p. 131-134.

GAUDIOSO, E.; BOTICARIO, J. G. User data management and usage model acquisition in an adaptive educational collaborative environment. In: INTERNATIONAL CONFERENCE IN ADAPTIVE HYPERMEDIA SYSTEMS AND ADAPTIVE WEB SYSTEMS, 2., 2002, Málaga. **Proceedings ...** Heidelberg: Springer-Verlag, 2002.

- GRIGORIADOU, M. et al. INSPIRE: na INtelligent System for Personalised Instruction in a Remote Environment. In: INTERNATIONAL WORKSHOP ON ADPTIVE HYPERTEXT AND HYPERMEDIA, 3., 2001, Sonthfen. **Proceedings ...** [S.l.: s.n.], 2001. p. 13-24.
- HAYKIN, S. **Redes neurais: princípios e prática**. Porto Alegre: Bookman. 2001. 900 p.
- HENERY, R. J. Classification. In: MICHIE, D.; SPIEGELHALTER, D. J.; TAYLOR, C.C. (Ed.). **Machine Learning, Neural and Statistical Classification**. London: Ellis Horwood, 1994. p. 6-16.
- KELLY, D.; TANGNEY, B. Incorporating Learning Characteristics into an Intelligent Tutor. In: THE INTERNATIONAL CONFERENCE ON INTELLIGENT TUTORING SYSTEMS, 6., 2002, Biarritz. **Proceedings ...** Hidelberg: Springer-Verlag, 2002. p. 729 – 738.
- KLECKA, W. R. **Discriminant analysis**. Newbury: Sage Publications, 1980. 70 p.
- LEVENE, M. **The navigation problem in the World-Wide-Web**. Disponível em: <http://www.dcs.bbk.ac.uk/~mark/download/gfkl_web.pdf>. Acesso em: 10 nov. 2003.
- MACGREGOR, S. K. Hypermedia navigation profiles: cognitive characteristics and information processing strategies. **Journal of Educational Computing Research**, [S.l.], v. 20, n. 2, p.189-206, 1999.
- MADEIRA, M. et al. **Modelação cognitiva do aluno-aprendiz em um ambiente inteligente de ensino baseado em modo não-tutorial**. São Leopoldo: Curso de Psicologia da UNISINOS, 2000. CNPq/ProTem - Relatório de Pesquisa.
- MADEIRA, M. et al. Geração de Estilos Cognitivos de Aprendizagem de Negociadores Empresariais para Adaptação de Ensino Tutorializado na Web. **Paidéia**, Ribeirão Preto, v. 12, n. 23, p. 133-147, 2002.
- MARTINEZ, M.; BUNDERSON, V. Building interactive World Wide Web (Web) learning environments to match and support individual learning differences. **Journal of Interactive Learning Research**, [S.l.], v.11, n. 3, p. 163-195, 2000.
- MAYO, M.; MITROVIC, A. Optimising ITS behaviour with bayesian networks and decision theory. **International Journal of Artificial Intelligence and Education**, [S.l.], 2000.
- MCMANUS, T.F. Individualizing instruction in a web-based hypermedia-learning environment: no linearity, advance organizers, and self-regulated learners. **Journal of Interactive Learning Research**, [S.l.], v. 11, n. 3, p. 219-251, 2000.
- MICHIE, D.; SPIEGELHALTER, D.J.; TAYLOR, C.C. Machine learning, neural and statistical classification. In: MICHIE, D.; SPIEGELHALTER, D. J.; TAYLOR, C.C. (Ed.). **Machine Learning, Neural and Statistical Classification**. London: Ellis Horwood, 1994. p. 1-5.
- MITCHELL, J.M. Classical Statistical Methods. In: MICHIE, D. ; SPIEGELHALTER, D. J.; TAYLOR, C.C. (Ed.). **Machine Learning, Neural and Statistical Classification**. London: Ellis Horwood, 1994. p. 17-28.
- MOLINA, R. et al. Modern Statistical Techniques. In: MICHIE, D.; SPIEGELHALTER, D. J.; TAYLOR, C.C. (Ed.). **Machine Learning, Neural and Statistical Classification**. London: Ellis Horwood, 1994. p. 29-49.

- MORALES, R.; PAIN, H. **Modelling of novices' control skills with machine learning**. Disponível em: <<http://citeseer.nj.nec.com/268485.html>>. Acesso em: 10 nov. 2003.
- REED, W.M.; OUGHTON, J.M. Computer experience and interval based hypermedia navigation. **Journal of Research on Computing in Education**, [S.l.], v. 30, p. 38–52, 1997.
- RENZULLI, J.; DAI, D.Y. Abilities, Interests and Styles as Aptitudes for Learning. In: STERNBERG, R.J.; ZHANG, L. (Ed.). **Perspectives on Thinking, Learning, and Cognitive Styles**. London: Lawrence Erlbaum Associates, 2001.
- RIDING, R.; CHEEMA, I. Cognitive styles - an overview and integration. **Educational Psychology**, [S.l.], v. 11, n. 3-4, p.193-215, 1991.
- RIDING, R.; RAYNER, S. **Cognitive styles and learning Strategies** – understanding style differences in learning and behavior. London: David Fulton Publishers, 2000.
- ROSS, J. D.; ROSS, C. M. **Teste Ross dos Processos Cognitivos**. São Paulo, Brasil: Instituto Pieron de Psicologia Aplicada, 1997.
- RUSSELL, S.; NORVIG, P. **Artificial intelligence: a modern approach**. New Jersey: Prentice-Hall, 1995.
- SCHMECK, R. R. **Learning strategies and learning styles**. New York: Plenum Press, 1988.
- SCHREIBER, A. et al. **Knowledge engineering and management: the common KADS methodology**. Massachusetts: Institute of Technology (MIT), 2000.
- SOLDATO, T.; BOULAY, B. Implementation of Motivational Tactics in Tutoring Systems. **Journal of Artificial Intelligence in Education**, Charlottesville, v. 6, n. 4, p.337-378, 1995.
- SOUTO, M. A. et al. Modelo de Ensino Adaptativo na Internet Baseado em Estilos Cognitivos de Aprendizagem. In: SIMPÓSIO BRASILEIRO DE INFORMÁTICA NA EDUCAÇÃO, 11., 2000, Maceió. **Anais ...** Maceió:SBC-UFAL, 2000.
- SOUTO, M.A. et al. Metodologia de construção do material instrucional em um Ambiente de Ensino Inteligente na Web. In: SIMPÓSIO BRASILEIRO DE INFORMÁTICA NA EDUCAÇÃO, 12., 2001, Vitória. **Anais ...** Vitória: SBC-UFES, 2001.
- SOUTO, M.A. et al. Towards an Adaptive Web Training Environment based on Cognitive Style of Learning: an Empirical Approach. In: INTERNATIONAL CONFERENCE IN ADAPTIVE HYPERMEDIA SYSTEMS AND ADAPTIVE WEB SYSTEMS, 2., 2002, Málaga. **Proceedings ...** Hidelberg: Springer-Verlag, 2002a.
- SOUTO, M.A. et al. Um estudo empírico dos comportamentos de navegação por estilo cognitivo de aprendizagem em um ambiente de treinamento na Web. In: SIMPÓSIO BRASILEIRO DE INFORMÁTICA NA EDUCAÇÃO, 13., 2002, São Leopoldo. **Anais ...** São Leopoldo: SBC-UNISINOS, 2002b.
- SOUTO, M.A. et al. Web adaptive training system based on cognitive student style. In: IFIP WORLD COMPUTER CONGRESS, 17., Montreal, 2002. **Proceedings ...** [S.l.], 2002c.

SPILIOPOULOU, M. The laborious way from data mining to web log mining. **International Journal of Computer Systems, Science & Engineering**, [S.l.], p. 113-126, 1999. (Special Issue on Semantics of the Web).

STERN, M. K.; BECK, J. E.; WOOLF, B. P. Naïve Bayes classifiers for user modeling. In: INTERNATIONAL CONFERENCE ON USER MODELING, 7., 1999, Banff. **Proceedings ...** New York: Springer Wien, 1999.

STERN, M. K., WOOLF, B. P. Adaptive content in an online lecture system. In: INTERNATIONAL CONFERENCE ON ADAPTIVE HYPERMEDIA AND ADAPTIVE WEB-BASED SYSTEMS, 2000, Trento. **Proceedings ...** Heidelberg: Springer-Verlag, 2000. p. 225-238.

STERNBERG, R. J.; ZHANG, L. **Perspectives on Thinking, Learning, and Cognitive Styles**. London: Lawrence Erlbaum Associates, 2001.

TRIANAFILLOU, E. et al. The design and the formative evaluation of an adaptive educational system based on cognitive styles. **Computers & Education**, Oxford, v. 41, p. 87-103, 2003.

VANLEHN, K. Student Modeling. In: POLSON, M.C.; RICHARDSON, J.J. (Ed.). **Foundations of Intelligent Tutoring Systems**. New Jersey: Lawrence Erlbaum Associates, 1988. p.55-78.

WOODS, P.; WARREN, J. Rapid Prototyping of an intelligent tutorial system (RAPITS). In: THE ANNUAL CONFERENCE OF THE AUSTRALIAN SOCIETY FOR COMPUTERS IN LEARNING , 12., Melbourne, 1995. **Proceedings ...** [S.l.], 1995. p. 557-563.

ZAIANE, O. R.; XIN, M.; HAN, J. Discovering Web Access Patterns and Trends by Applying OLAP and Data Mining Technology on Web Logs. In: THE IEEE FORUM ON RESEARCH AND TECHNOLOGY ADVANCES IN DIGITAL LIBRARIES, 1998, Santa Barbara. **Proceedings...** [S.l.: s.n.], 1998. p. 19-29.

ZAIANE, O. R.; LUO, J. Towards evaluating learners' behaviour in a web-based distance learning environment. In: INTERNATIONAL CONFERENCE ON ADVANCED LEARNING TECHNOLOGIES, 2001, Madison. **Proceedings...** New York: IEEE, 2001.

ZAIANE, O. R. **Web Usage Mining for a Better Web-Based Learning Environment**. Disponível em: [HTTP://www.cs.ualberta.ca/people/faculty/zaiane.html](http://www.cs.ualberta.ca/people/faculty/zaiane.html). Acesso em: 31 jul 2003.

ANEXO A

EXEMPLOS DE PÁGINAS WEB DO CURSO EXPERIMENTAL TDMA

Páginas Web de 'Conceitos'

[Recursos](#)
[Formas](#)
[Avaliação](#)

TDMA
X

Conceito - Texto Destacado com Figuras

TDMA

Cada intervalo de tempo **de 30 ms** é dividido no **subcanal M** (para sinalização e controle) e **no subcanal VID** (usado para o transporte efetivo dos bits de para o usuário. Há uma diferenciação quanto ao sinal gerado pela estação Rádio Base (airborne transmission) e o sinal gerado pelo aparelho móvel (ground transmission). E se dá no subcanal M que é menor na Estação Rádio Base e maior para o aparelho móvel.

No **subcanal M** o campo **sync** é usado para **transmitir a palavra de sincronismo** (alinhamento) deste subcanal, **acontecendo o mesmo** com relação ao mesmo campo do **subcanal VID**. Já o campo **system data** é usado para **passar informações de sinalização e controle** (tais como número do assinante discado e o número de série do aparelho móvel) este campo é **menor para a ERB** do que para o **aparelho móvel**.

No **subcanal VID** o campo **Header** é usado para **controlar os bits do canal de voz comprimida** (protocolo PVP - Packetized Voice Protocol). O campo **User Information** é usado para o **transporte da informação do usuário**.

[Anterior](#)

X

Recursos

TDMA

Formas

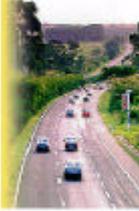
Conceito - Texto com Figuras Comparativo

Avaliação

TDMA



Um sistema de transmissão que não utiliza nenhuma técnica de multiplexação poderia ser comparado com um "corredor de ônibus", utilizado em sistema de transporte coletivo das grandes Metrópoles. Dentro de um corredor passa somente um ônibus por vez (uma informação, por exemplo), pois só há uma pista. Se a pista ao lado, destinada a veículos estiver congestionada, e a dos ônibus estiver livre, ela não poderá ser utilizada. Pois ela é dedicada somente a esse tipo de veículo (informação), causando um desperdício na utilização das pistas (meio físico, por exemplo).



Por outro lado se formos analisar um sistema de transmissão que utiliza a técnica de multiplexação ele poderia ser comparado a uma estrada (meio físico) com vários veículos (informações), sendo transportados. A estrada tem capacidade de transportar simultaneamente, vários tipos de veículos (informações), como motocicletas, carros, ônibus e caminhões. Os veículos poderão se posicionar nas pistas (faixas de frequência) conforme a sua velocidade (banda de transmissão), ou seja, um caminhão que é veículo mais lento (informação de dados) poderá ficar com uma pista menor (pista da direita) para acomodar o seu tráfego. Já os veículos mais rápidos (voz, vídeo) poderão utilizar as pistas da esquerda (faixas de frequência maiores) para um transporte mais rápido.

[Anterior](#)

X

Recursos

TDMA

Formas

Conceito - Esquema com Perguntas

Avaliação

TDMA

Quais as Características da figura TDMA Frame?

- No caso o intervalo de tempo de 120 ms é dividido em 4 intervalos de 30 ms cada.
- Cada intervalo de tempo possui um usuário alocado.
- Cada intervalo de tempo é constituído de um subcanal M para controle e sinalização e um subcanal V/D para informação de usuário.

[Anterior](#) [Próxima](#)

Páginas Web de 'Exercícios'

Recursos
 Formas
 Avaliação

Marque Verdadeiro(V) ou Falso (F):

X

T D M A

V F

- O objetivo do acesso de estações móveis da técnica TDMA é multiplexar em frequência e tempo.
- Quadro de tempo multiplexado no espectro é uma fatia de tempo de um quadro TDM.
- A velocidade associada à cada canal TDMA é de 31,5Kbps na versão com 3 canais.
- Sobre a técnica TDMA, o acesso de estações móveis tem como meta aumentar a capacidade de usuários atendidos por uma ERB.
- O quadro TDM é formado por intervalos de tempo.
- A técnica de aumentar a capacidade do meio de transmissão é a multiplexação.
- Os quadros de cada canal são dependentes entre si.
- O campo System Data leva informações de sinalização e de gerência no subcanal V/D.
- O subcanal M é usado para transmitir voz comprimida do usuário.
- TDMA é uma técnica de multiplexação híbrida no domínio da frequência e do tempo.

X
Recursos
Formas
Avaliação

Relacionar Colunas

T
D
M
A

(1) TDMA	<input type="checkbox"/>	É compartilhado no tempo com os outros dois canais.
(2) Domínio Tempo	<input type="checkbox"/>	30 ms
(3) Domínio Frequência	<input type="checkbox"/>	4 slots
(4) Os canais alocados no eixo das frequências	<input type="checkbox"/>	Carrega informações do usuário (voz e dados)
(5) A voz é comprimida	<input type="checkbox"/>	Na Estação Rádio Base é de 16 bits.
(6) Canal AMPS	<input type="checkbox"/>	Multiplexação no domínio da frequência e do tempo.
(7) Slot	<input type="checkbox"/>	120 ms
(8) Subcanal M	<input type="checkbox"/>	Serve para alocação no espectro de Rádio Frequência
(9) Subcanal V/D	<input type="checkbox"/>	Para compartilhar cada canal AMPS.
(10) System Data	<input type="checkbox"/>	Gerência e sinalização.
	<input type="checkbox"/>	Possui 4 campos (Ramp, Sync, Header, User Information)
	<input type="checkbox"/>	Subdividido em subcanal M e subcanal V/D
	<input type="checkbox"/>	Serve para compartilhar um canal com vários usuários.
	<input type="checkbox"/>	No aparelho móvel é de 32 bits.
	<input type="checkbox"/>	Possui 3 campos (Ramp, Sync e System Data)

X
Recursos
Formas
Avaliação

Múltipla Escolha

T
D
M
A

1) Para que serve o TDMA?

- Multiplicação da capacidade de atendimento de assinantes por uma única antena
- Para fazer um compartilhamento de um canal (no espectro) por várias ERB's
- Faz um compartilhamento de um canal por divisão de frequência por vários canais
- O TDMA serve para fazer o gerenciamento e controle de tráfego bem como a detecção e correção de erros em um canal compartilhado
- Todas as afirmações acima estão corretas

2) A faixa de frequência utilizada pela tecnologia TDMA em uma ERB é:

- 824 - 849 Mhz
- 850 - 875 Mhz
- 832 - 857 Mhz
- 869 - 894 Mhz
- n.d.a

Teste a Informação
Próxima

X
Recursos
Formas
Avaliação

Preencher Lacunas

T
D
M
A

1) TDMA é uma técnica que consiste numa mistura de no domínio da e no domínio .

2) A da capacidade de cada com o compartilhamento no domínio do tempo, se deve pelo compartilhamento na linha do tempo com outros dois canais.

3) O limite de uso das bandas A e B de celulares é de 3 canais compartilhando no tempo o mesmo alocado em frequência.

4) Para o ser compartilhado com outros a voz deve ser comprimida para 13,8 ou 5,3 Kbps.

5) Cada de tempo com 30ms está subdividido em subcanal M e subcanal VD.

6) O é utilizado para fazer o controle e sinalização.

7) O é utilizado para as informações dos usuários.

8) O na Estação de Rádio Base é de 16 bits, já no aparelho móvel é de 32 bits.

Teste a Informação

X

Recursos
Formas
Avaliação

Múltipla Escolha com Figuras

T
D
M
A

1.

a) Considerando um sistema de comunicação de dados, que utiliza o sistema TDM (Time Division Multiplex), qual das figuras abaixo exemplifica melhor essa característica?









b) Considerando um sistema de transmissão de dados, que não utiliza os recursos de multiplexação, qual das figuras abaixo exemplifica melhor essa característica?









Teste a Informação

Próxima

Páginas Web de 'Exemplos'

Recursos
Formas
Avaliação

TDMA

Exemplo - Texto com Figuras

MULTIPLEXAÇÃO NO DOMÍNIO DA FREQUÊNCIA

Esta é a técnica que aloca diversos sinais, individualmente ocupando a mesma banda passante, em posições do espectro multiplexado, de forma tal que não percam a sua identidade. A figura abaixo mostra um diagrama em blocos de um multiplexador FDM (Frequency Division Multiplex), para acessar um sistema celular analógico.

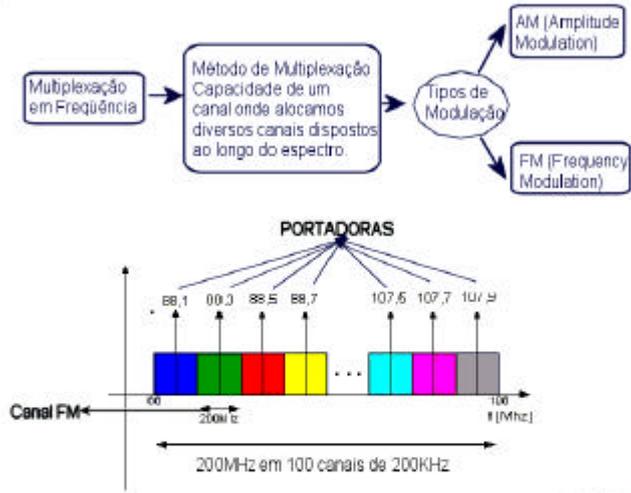
Próxima

Recursos
 Formas
 Avaliação

TDMA

Exemplo - Esquema com Figuras Comparativo

T
D
M
A



Próxima

ANEXO B

EXEMPLOS DE QUESTÕES DO TESTE ROSS

APÊNDICE A
QUESTIONÁRIO DE AVALIAÇÃO QUALITATIVA

- CPGC -
PROGRAMA DE PÓS-GRADUAÇÃO EM COMPUTAÇÃO

Modelagem Cognitiva de um aprendiz remoto:
Levantamento do Funcionamento dos Estilos Cognitivos em um
Ambiente de Aprendizagem na Web

- QUESTIONÁRIO PARA PREENCHIMENTO -

POR:

MARIA APARECIDA M. SOUTO

PROF. DR. JOSÉ PALAZZO M. DE OLIVEIRA

PROFA. DRA. ROSA MARIA VICARI

ORIENTADORES

Porto Alegre, Março de 2003

1 DADOS DE IDENTIFICAÇÃO DO ESPECIALISTA

1. Sexo: () Masculino; () Feminino

2. Idade: _____ anos.

3. Formação acadêmica:

▪ Graduação:

▪ Especialização:

▪ Mestrado:

▪ Doutorado:

4. Área de pesquisa:

5. Profissão:

6. Tempo de experiência: _____

7. Local de Trabalho:

8. Qual é o seu grau de familiaridade com o assunto desta pesquisa?

Não Familiar						Muito Familiar
	1	2	3	4	5	

2 APRESENTAÇÃO

Prezado (a) Professor (a)

Gostaríamos de contar com sua colaboração, no sentido de participar da validação do **Modelo Cognitivo do Aprendiz Remoto**, a partir da análise do funcionamento do seu *estilo cognitivo* na Web, durante a execução de um *processo de aprendizagem*, realizado através de um *módulo de ensino experimental*, especialmente projetado para levar a cabo este objetivo.

Este estudo faz parte da Tese de Doutorado da solicitante, cujo tema abrange as áreas de ‘Sistemas de Informação’, ‘Inteligência Artificial’ e ‘Ensino a Distância na Internet’. A motivação deste trabalho teve início com a participação da solicitante no Projeto Tapejara - Sistemas de Treinamento Inteligente via Internet – formado pelo consórcio entre as universidades UFRGS e UNISINOS, e pela companhia de Telecomunicações – CRT Telecom, e suportado pelo CNPq – ProTem-CC, no período de novembro de 1999 a novembro de 2001.

Os principais objetivos desta Tese referem-se à *modelagem do aprendiz remoto* e a geração de um *agente computacional inteligente* (protótipo), cuja função é realizar o diagnóstico cognitivo do aprendiz remoto. A realização do diagnóstico do *estilo cognitivo* do aprendiz remoto por um agente computacional inteligente possibilitará, futuramente, a adaptação, *on-line*, dos recursos pedagógicos de um curso via Web, às demandas psicopedagógicas deste aprendiz, de modo a *facilitar* e tornar mais *eficaz* o seu processo de aprendizagem a distância.

Neste momento, nossos esforços estão voltados ao processo de *aquisição de conhecimento*, necessário à modelagem cognitiva / computacional do aprendiz remoto. Para alcançar este objetivo, estamos lhe enviando o “Questionário para Preenchimento”, por nós desenvolvido, e que é composto por um conjunto de *afirmativas* a respeito do comportamento cognitivo do aprendiz remoto, durante o experimento realizado no

contexto do Projeto Tapejara. Estas *afirmativas* foram elaboradas a partir dos resultados da análise exploratória dos dados do experimento, realizada pela solicitante.

Em anexo, segue o ‘Material de Consulta’, onde está descrito a metodologia utilizada no experimento. Acreditamos que este material contenha todas as informações necessárias para a realização de sua contribuição. De qualquer forma, estamos ao seu inteiro dispor, para sanar possíveis dúvidas durante o seu trabalho.

Até a divulgação da Tese de Doutorado da solicitante, solicita-se sigilo do ‘Material de Consulta’, pois o mesmo será incorporado à mencionada Tese, em futuro próximo. Se assim o desejar, nos prontificamos a lhe enviar uma cópia do volume final.

Você está sendo convidado a participar deste trabalho por sua formação experiência e competência reconhecida nesta área. A sua opinião é muito importante para que possamos ter mais clareza sobre a sua área de conhecimento, para a qual estamos pretendendo fazer a nossa contribuição. Embora o material a ser preenchido pareça um tanto extenso, e cientes de sua carga de atribuições e responsabilidades, solicitamos, encarecidamente, que você nos retorne o material em no máximo quinze (15) dias. Para entregar-me o questionário preenchido, fico a disposição para pegá-lo consigo; caso contrário, coloque-o dentro do envelope endereçado e selado, tomando o cuidado de fechar (colar) o mesmo, e deposite em alguma caixa de correio.

Contando com a gentileza de sua colaboração, agradecemos, desde já, sua atenção no preenchimento e envio do “Questionário para Preenchimento”.

Atenciosamente,

Profa. Maria Aparecida M. Souto, MSc.

Universidade Federal do Rio Grande do Sul - Instituto de Informatica
Av. Bento Goncalves 9500, bloco IV - Caixa Postal 15064
91501-970 Porto Alegre RS - Brasil
Voice +55 51 3316 6110 - Fax +55 51 3316 7308
souto@inf.ufrgs.br - www.inf.ufrgs.br/~souto

3 O QUESTIONÁRIO

O questionário a ser preenchido é composto por: (i) *afirmativas* a respeito do comportamento cognitivo observado dos *estilos cognitivos* considerados neste estudo; e (ii) conjunto de *três questões*, a serem preenchidas pelo especialista, conforme detalhamos a seguir.

3.1 Afirmativas sobre o comportamento dos estilos cognitivos

As *afirmativas* sobre o comportamento dos estilos cognitivos foram construídas a partir dos resultados da Análise Exploratória, descrita na seção 5 do ‘Material de Consulta’. Estes resultados estão sendo tratados, neste estudo, como *tendências* comportamentais dos estilos cognitivos considerados. Estas afirmativas irão representar as crenças levantadas, até o momento, sobre os indicadores que melhor discriminam o comportamento dos estilos no Ambiente de Ensino e Aprendizagem na Web utilizado. As crenças funcionarão como referência para a construção do agente computacional inteligente, cujo objetivo é realizar o diagnóstico cognitivo do aprendiz remoto.

No questionário, as afirmativas sobre o comportamento cognitivo dos estilos estão organizadas por classe de estilo cognitivo e pelo tipo de informação que elas contém, quais sejam:

- | | |
|------|--|
| I. | Padrões de Ações Cognitivas |
| II. | Intensidade de uso dos recursos didáticos |
| III. | Intensidade de uso das formas de apresentação |
| IV. | Tempo de permanência nos recursos didáticos |
| V. | Tempo de permanência nas formas de apresentação. |

3.2 Instruções de preenchimento do questionário

Solicita-se que você analise, para cada uma das *afirmativas*, se ela explica um possível funcionamento da classe de *estilo cognitivo* considerada, justificando a sua resposta. Solicita-se também, que você identifique no questionário qual é o grau de crença que você tem sobre a afirmativa em questão, bem como identifique em que você se baseou para opinar sobre esta afirmativa.

Atenção, em sua análise, além da sua formação e experiência, é FUNDAMENTAL que você considere, para o preenchimento do questionário, as definições e informações contidas no “Material de Consulta”:

- 1) a conceituação dos construtos: *estilos cognitivos de aprendizagem e trajetórias de aprendizagem utilizados neste estudo* (Seção 1, pág. 3);
- 2) a origem e a definição dos estilos cognitivos considerados neste estudo (Seção 2, pág. 5);
- 3) dados sobre o experimento realizado (Seções 3 e 4, págs. 13 e 16, respectivamente);
- 4) análise exploratória das trajetórias de aprendizagem (Seção 5, pág. 19);
- 5) Anexo I, com exemplos das páginas Web dos recursos didático e formas de apresentação dos conteúdos do módulo de ensino experimental (pág. 47);
- 6) Anexo II, com as Tabelas de Correlações de *Pearson* entre os indicadores monitorados no experimento, e geradas através do pacote estatístico SPSS (pág.54).

Caso seja necessário, colocamos uma folha em branco após as *afirmativas* de cada classe de estilo, para observações adicionais.

3.2.1 Funcionamento cognitivo na Web do estilo *Analógico-Analítico*

Itens para preenchimento → Afirmativas ↓	Funcionamento cognitivo na Web <small>(nesta coluna, indicar se a afirmativa explica um possível funcionamento do estilo).</small>	Grau de Crença na afirmativa	Base da sua crença na afirmativa
I. Movimentos do Aprendiz na Web			
a) o estilo AA tende a adotar o padrão conceito-exercício e conceito-exemplo na busca de novas informações.	<input type="checkbox"/> Sim <input type="checkbox"/> Não Por quê? _____ _____ _____ _____ _____	<input type="checkbox"/> Nada se pode afirmar <input type="checkbox"/> Baixa <input type="checkbox"/> Média baixa <input type="checkbox"/> Média <input type="checkbox"/> Média alta <input type="checkbox"/> Alta	<input type="checkbox"/> Conhecimento <input type="checkbox"/> Experiência <input type="checkbox"/> Dados fornecidos suficientes <input type="checkbox"/> Dados fornecidos insuficientes <input type="checkbox"/> Outra: _____ _____ _____
II. Intensidade de uso dos 'Recursos Didáticos'			
b) a intensidade média de uso do recurso didático de 'conceitos' pelo estilo AA tende a ser ALTA.	<input type="checkbox"/> Sim <input type="checkbox"/> Não Por quê? _____ _____ _____ _____ _____	<input type="checkbox"/> Nada se pode afirmar <input type="checkbox"/> Baixa <input type="checkbox"/> Média baixa <input type="checkbox"/> Média <input type="checkbox"/> Média alta <input type="checkbox"/> Alta	<input type="checkbox"/> Conhecimento <input type="checkbox"/> Experiência <input type="checkbox"/> Dados fornecidos suficientes <input type="checkbox"/> Dados fornecidos insuficientes <input type="checkbox"/> Outra: _____ _____ _____
III. Intensidade de uso das 'Formas de Apresentação'			
c) a intensidade média de uso das formas de apresentação de 'conceitos': textual c/ figura e somente textual pelo estilo AA tende a ser ALTA.	<input type="checkbox"/> Sim <input type="checkbox"/> Não Por quê? _____ _____ _____ _____ _____	<input type="checkbox"/> Nada se pode afirmar <input type="checkbox"/> Baixa <input type="checkbox"/> Média baixa <input type="checkbox"/> Média <input type="checkbox"/> Média alta <input type="checkbox"/> Alta	<input type="checkbox"/> Conhecimento <input type="checkbox"/> Experiência <input type="checkbox"/> Dados fornecidos suficientes <input type="checkbox"/> Dados fornecidos insuficientes <input type="checkbox"/> Outra: _____ _____ _____

<p>d) a intensidade média de uso da forma de apresentação de 'exercício' 'escolha simples c/ figura' pelo estilo AA tende a ser ALTA.</p>	<p>() Sim () Não Por quê? _____ _____ _____ _____</p>	<p>() Nada se pode afirmar () Baixa () Média baixa () Média () Média alta () Alta</p>	<p>() Conhecimento () Experiência () Dados fornecidos suficientes () Dados fornecidos insuficientes () Outra: _____ _____ _____</p>
---	---	---	--

IV. Tempo de permanência nos 'Recursos Didáticos'

<p>e) observamos que este indicador não é discriminativo para esta classe de estilo cognitivo.</p>	<p>() Sim () Não Por quê? _____ _____ _____ _____</p>	<p>() Nada se pode afirmar () Baixa () Média baixa () Média () Média alta () Alta</p>	<p>() Conhecimento () Experiência () Dados fornecidos suficientes () Dados fornecidos insuficientes () Outra: _____ _____ _____</p>
--	---	---	--

V. Tempo de permanência nas 'Formas de Apresentação'

<p>f) observamos que este indicador não é discriminativo para esta classe de estilo cognitivo.</p>	<p>() Sim () Não Por quê? _____ _____ _____ _____</p>	<p>() Nada se pode afirmar () Baixa () Média baixa () Média () Média alta () Alta</p>	<p>() Conhecimento () Experiência () Dados fornecidos suficientes () Dados fornecidos insuficientes () Outra: _____ _____ _____</p>
--	---	---	--

Observações adicionais (utilize este espaço e a página seguinte, caso seja necessário):

3.2.2 Funcionamento cognitivo na Web do estilo *Concreto-Genérico*

Itens para preenchimento → Afirmativas ↓	Funcionamento cognitivo na Web (nesta coluna, indicar se a afirmativa explica um possível funcionamento do estilo).	Grau de Crença na afirmativa	Base da sua crença na afirmativa
I. Movimentos do Aprendiz na Web			
g) o estilo CG tende a adotar o padrão exercício-conceito-exemplo na busca de novas informações.	<input type="checkbox"/> Sim <input type="checkbox"/> Não Por quê? _____ _____ _____ _____ _____	<input type="checkbox"/> Nada se pode afirmar <input type="checkbox"/> Baixa <input type="checkbox"/> Média baixa <input type="checkbox"/> Média <input type="checkbox"/> Média alta <input type="checkbox"/> Alta	<input type="checkbox"/> Conhecimento <input type="checkbox"/> Experiência <input type="checkbox"/> Dados fornecidos suficientes <input type="checkbox"/> Dados fornecidos insuficientes <input type="checkbox"/> Outra: _____ _____ _____
II. Intensidade de uso dos 'Recursos Didáticos'			
h) a intensidade média de uso do recurso didático de exemplo pelo estilo CG tende a ser ALTA.	<input type="checkbox"/> Sim <input type="checkbox"/> Não Por quê? _____ _____ _____ _____ _____	<input type="checkbox"/> Nada se pode afirmar <input type="checkbox"/> Baixa <input type="checkbox"/> Média baixa <input type="checkbox"/> Média <input type="checkbox"/> Média alta <input type="checkbox"/> Alta	<input type="checkbox"/> Conhecimento <input type="checkbox"/> Experiência <input type="checkbox"/> Dados fornecidos suficientes <input type="checkbox"/> Dados fornecidos insuficientes <input type="checkbox"/> Outra: _____ _____ _____
III. Intensidade de uso das 'Formas de Apresentação'			
i) a intensidade média de uso das formas de apresentação de 'exemplos': textual c/ figura e esquema c/ figura pelo estilo CG tende a ser ALTA.	<input type="checkbox"/> Sim <input type="checkbox"/> Não Por quê? _____ _____ _____ _____ _____	<input type="checkbox"/> Nada se pode afirmar <input type="checkbox"/> Baixa <input type="checkbox"/> Média baixa <input type="checkbox"/> Média <input type="checkbox"/> Média alta <input type="checkbox"/> Alta	<input type="checkbox"/> Conhecimento <input type="checkbox"/> Experiência <input type="checkbox"/> Dados fornecidos suficientes <input type="checkbox"/> Dados fornecidos insuficientes <input type="checkbox"/> Outra: _____ _____ _____

IV. Tempo de permanência nos 'Recursos Didáticos'			
j) O tempo médio de permanência no recurso didático de ' exemplo ' pelo estilo CG tende a ser ALTO.	<input type="checkbox"/> Sim <input type="checkbox"/> Não Por quê? _____ _____ _____ _____ _____	<input type="checkbox"/> Nada se pode afirmar <input type="checkbox"/> Baixa <input type="checkbox"/> Média baixa <input type="checkbox"/> Média <input type="checkbox"/> Média alta <input type="checkbox"/> Alta	<input type="checkbox"/> Conhecimento <input type="checkbox"/> Experiência <input type="checkbox"/> Dados fornecidos suficientes <input type="checkbox"/> Dados fornecidos insuficientes <input type="checkbox"/> Outra: _____ _____ _____
V. Tempo de permanência nas 'Formas de Apresentação'			
k) O tempo médio de permanência na forma de apresentação de 'exemplo': textual c/ figura pelo estilo CG tende a ser ALTA.	<input type="checkbox"/> Sim <input type="checkbox"/> Não Por quê? _____ _____ _____ _____ _____	<input type="checkbox"/> Nada se pode afirmar <input type="checkbox"/> Baixa <input type="checkbox"/> Média baixa <input type="checkbox"/> Média <input type="checkbox"/> Média alta <input type="checkbox"/> Alta	<input type="checkbox"/> Conhecimento <input type="checkbox"/> Experiência <input type="checkbox"/> Dados fornecidos suficientes <input type="checkbox"/> Dados fornecidos insuficientes <input type="checkbox"/> Outra: _____ _____ _____

Observações adicionais (utilize este espaço e a página seguinte, caso seja necessário):

3.2.3 Funcionamento cognitivo na Web do estilo *Dedutivo-Avaliativo*

Itens para preenchimento → Afirmativas ↓	Funcionamento cognitivo na Web (nesta coluna, indicar se a afirmativa explica um possível funcionamento do estilo).	Grau de Crença na afirmativa	Base da sua crença na afirmativa
I. Movimentos do Aprendiz na Web			
l) o estilo DA tende a explorar todos os recursos que lhe são oferecidos, sem adotar nenhum padrão específico de repetição, na busca de novas informações.	<input type="checkbox"/> Sim <input type="checkbox"/> Não Por quê? _____ _____ _____ _____ _____	<input type="checkbox"/> Nada se pode afirmar <input type="checkbox"/> Baixa <input type="checkbox"/> Média baixa <input type="checkbox"/> Média <input type="checkbox"/> Média alta <input type="checkbox"/> Alta	<input type="checkbox"/> Conhecimento <input type="checkbox"/> Experiência <input type="checkbox"/> Dados fornecidos suficientes <input type="checkbox"/> Dados fornecidos insuficientes <input type="checkbox"/> Outra: _____ _____ _____
II. Intensidade de uso dos ‘Recursos Didáticos’			
m) observamos que este indicador não é discriminativo para esta classe de estilo cognitivo.	<input type="checkbox"/> Sim <input type="checkbox"/> Não Por quê? _____ _____ _____ _____ _____	<input type="checkbox"/> Nada se pode afirmar <input type="checkbox"/> Baixa <input type="checkbox"/> Média baixa <input type="checkbox"/> Média <input type="checkbox"/> Média alta <input type="checkbox"/> Alta	<input type="checkbox"/> Conhecimento <input type="checkbox"/> Experiência <input type="checkbox"/> Dados fornecidos suficientes <input type="checkbox"/> Dados fornecidos insuficientes <input type="checkbox"/> Outra: _____ _____ _____
III. Intensidade de uso das ‘Formas de Apresentação’			
n) a intensidade média de uso da forma de apresentação de ‘conceitos’: esquema c/ figura pelo estilo DA tende a ser ALTA.	<input type="checkbox"/> Sim <input type="checkbox"/> Não Por quê? _____ _____ _____ _____ _____	<input type="checkbox"/> Nada se pode afirmar <input type="checkbox"/> Baixa <input type="checkbox"/> Média baixa <input type="checkbox"/> Média <input type="checkbox"/> Média alta <input type="checkbox"/> Alta	<input type="checkbox"/> Conhecimento <input type="checkbox"/> Experiência <input type="checkbox"/> Dados fornecidos suficientes <input type="checkbox"/> Dados fornecidos insuficientes <input type="checkbox"/> Outra: _____ _____ _____

<p>o) a intensidade média de uso das formas de apresentação de 'exercício': 'V ou F' e 'Preencher Lacunas' pelo estilo DA tende a ser ALTA.</p>	<p>() Sim () Não Por quê? _____ _____ _____ _____</p>	<p>() Nada se pode afirmar () Baixa () Média baixa () Média () Média alta () Alta</p>	<p>() Conhecimento () Experiência () Dados fornecidos suficientes () Dados fornecidos insuficientes () Outra: _____ _____ _____</p>
<p>p) a intensidade média de uso da forma de apresentação de 'exercício': 'Escolha Simples c/ Figura' pelo estilo DA tende a ser BAIXA.</p>	<p>() Sim () Não Por quê? _____ _____ _____ _____</p>	<p>() Nada se pode afirmar () Baixa () Média baixa () Média () Média alta () Alta</p>	<p>() Conhecimento () Experiência () Dados fornecidos suficientes () Dados fornecidos insuficientes () Outra: _____ _____ _____</p>
<p>IV. Tempo de permanência nos 'Recursos Didáticos'</p>			
<p>q) observamos que este indicador não é discriminativo para esta classe de estilo cognitivo.</p>	<p>() Sim () Não Por quê? _____ _____ _____ _____</p>	<p>() Nada se pode afirmar () Baixa () Média baixa () Média () Média alta () Alta</p>	<p>() Conhecimento () Experiência () Dados fornecidos suficientes () Dados fornecidos insuficientes () Outra: _____ _____ _____</p>
<p>V. Tempo de permanência nas 'Formas de Apresentação'</p>			
<p>r) o tempo médio de permanência na forma de apresentação de 'Conceito': esquema c/ figura pelo estilo DA tende a ser ALTA.</p>	<p>() Sim () Não Por quê? _____ _____ _____ _____</p>	<p>() Nada se pode afirmar () Baixa () Média baixa () Média () Média alta () Alta</p>	<p>() Conhecimento () Experiência () Dados fornecidos suficientes () Dados fornecidos insuficientes () Outra: _____ _____ _____</p>

3.2.4 Funcionamento cognitivo na Web do *Estilo-Indefinido*

Itens para preenchimento → Afirmativas ↓	Funcionamento cognitivo na Web (nesta coluna, indicar se a afirmativa explica um possível funcionamento do estilo).	Grau de Crença na afirmativa	Base da sua crença na afirmativa
I. Movimentos do Aprendiz na Web			
s) o estilo EI tende a adotar o padrão conceito-exercício na busca de novas informações.	<input type="checkbox"/> Sim <input type="checkbox"/> Não Por quê? _____ _____ _____ _____ _____	<input type="checkbox"/> Nada se pode afirmar <input type="checkbox"/> Baixa <input type="checkbox"/> Média baixa <input type="checkbox"/> Média <input type="checkbox"/> Média alta <input type="checkbox"/> Alta	<input type="checkbox"/> Conhecimento <input type="checkbox"/> Experiência <input type="checkbox"/> Dados fornecidos suficientes <input type="checkbox"/> Dados fornecidos insuficientes <input type="checkbox"/> Outra: _____ _____ _____
II. Intensidade de uso dos 'Recursos Didáticos'			
t) a intensidade média de uso do recurso didático de 'exercício' pelo estilo EI tende a ser ALTA.	<input type="checkbox"/> Sim <input type="checkbox"/> Não Por quê? _____ _____ _____ _____ _____	<input type="checkbox"/> Nada se pode afirmar <input type="checkbox"/> Baixa <input type="checkbox"/> Média baixa <input type="checkbox"/> Média <input type="checkbox"/> Média alta <input type="checkbox"/> Alta	<input type="checkbox"/> Conhecimento <input type="checkbox"/> Experiência <input type="checkbox"/> Dados fornecidos suficientes <input type="checkbox"/> Dados fornecidos insuficientes <input type="checkbox"/> Outra: _____ _____ _____
III. Intensidade de uso das 'Formas de Apresentação'			
u) a intensidade média de uso das formas de apresentação de 'exercício': 'V ou F', 'Preencher Lacunas' e 'escolha simples c/ figura' pelo estilo EI tende a ser ALTA.	<input type="checkbox"/> Sim <input type="checkbox"/> Não Por quê? _____ _____ _____ _____ _____	<input type="checkbox"/> Nada se pode afirmar <input type="checkbox"/> Baixa <input type="checkbox"/> Média baixa <input type="checkbox"/> Média <input type="checkbox"/> Média alta <input type="checkbox"/> Alta	<input type="checkbox"/> Conhecimento <input type="checkbox"/> Experiência <input type="checkbox"/> Dados fornecidos suficientes <input type="checkbox"/> Dados fornecidos insuficientes <input type="checkbox"/> Outra: _____ _____ _____
IV. Tempo de permanência nos 'Recursos Didáticos'			

v) o tempo médio de permanência no recurso didático de 'Exercício' pelo estilo EI tende a ser ALTO.	<input type="checkbox"/> Sim <input type="checkbox"/> Não Por quê? _____ _____ _____ _____ _____ _____	<input type="checkbox"/> Nada se pode afirmar <input type="checkbox"/> Baixa <input type="checkbox"/> Média baixa <input type="checkbox"/> Média <input type="checkbox"/> Média alta <input type="checkbox"/> Alta	<input type="checkbox"/> Conhecimento <input type="checkbox"/> Experiência <input type="checkbox"/> Dados fornecidos suficientes <input type="checkbox"/> Dados fornecidos insuficientes <input type="checkbox"/> Outra: _____ _____ _____ _____
---	---	---	---

V. Tempo de permanência nas 'Formas de Apresentação'

w) o tempo médio de permanência nas formas de apresentação dos 'Exercícios': ' V ou F ' e ' escolha simples c/ figura ' pelo estilo EI tende a ser ALTO.	<input type="checkbox"/> Sim <input type="checkbox"/> Não Por quê? _____ _____ _____ _____ _____ _____	<input type="checkbox"/> Nada se pode afirmar <input type="checkbox"/> Baixa <input type="checkbox"/> Média baixa <input type="checkbox"/> Média <input type="checkbox"/> Média alta <input type="checkbox"/> Alta	<input type="checkbox"/> Conhecimento <input type="checkbox"/> Experiência <input type="checkbox"/> Dados fornecidos suficientes <input type="checkbox"/> Dados fornecidos insuficientes <input type="checkbox"/> Outra: _____ _____ _____ _____
--	---	---	---

Observações adicionais (utilize este espaço e a página seguinte, caso seja necessário):

3.2.5 Funcionamento cognitivo na Web do estilo *Relacional-Sintético*

Itens para preenchimento → Afirmativas ↓	Funcionamento cognitivo na Web (nesta coluna, indicar se a afirmativa explica um possível funcionamento do estilo AA).	Grau de Crença na afirmativa	Base da sua crença na afirmativa
I. Movimentos do Aprendiz na Web			
x) o estilo RS tende a adotar o padrão conceito-exemplo na busca de novas informações.	<input type="checkbox"/> Sim <input type="checkbox"/> Não Por quê? _____ _____ _____ _____ _____	<input type="checkbox"/> Nada se pode afirmar <input type="checkbox"/> Baixa <input type="checkbox"/> Média baixa <input type="checkbox"/> Média <input type="checkbox"/> Média alta <input type="checkbox"/> Alta	<input type="checkbox"/> Conhecimento <input type="checkbox"/> Experiência <input type="checkbox"/> Dados fornecidos suficientes <input type="checkbox"/> Dados fornecidos insuficientes <input type="checkbox"/> Outra: _____ _____ _____
II. Intensidade de uso dos ‘Recursos Didáticos’			
y) a intensidade média de uso do recurso didático de ‘exemplo’ pelo estilo RS tende a ser ALTA.	<input type="checkbox"/> Sim <input type="checkbox"/> Não Por quê? _____ _____ _____ _____ _____	<input type="checkbox"/> Nada se pode afirmar <input type="checkbox"/> Baixa <input type="checkbox"/> Média baixa <input type="checkbox"/> Média <input type="checkbox"/> Média alta <input type="checkbox"/> Alta	<input type="checkbox"/> Conhecimento <input type="checkbox"/> Experiência <input type="checkbox"/> Dados fornecidos suficientes <input type="checkbox"/> Dados fornecidos insuficientes <input type="checkbox"/> Outra: _____ _____ _____
III. Intensidade de uso das ‘Formas de Apresentação’			
z) a intensidade média de uso das formas de apresentação de ‘exercícios’: relacionar colunas e escolha simples pelo estilo RS tende a ser ALTA.	<input type="checkbox"/> Sim <input type="checkbox"/> Não Por quê? _____ _____ _____ _____ _____	<input type="checkbox"/> Nada se pode afirmar <input type="checkbox"/> Baixa <input type="checkbox"/> Média baixa <input type="checkbox"/> Média <input type="checkbox"/> Média alta <input type="checkbox"/> Alta	<input type="checkbox"/> Conhecimento <input type="checkbox"/> Experiência <input type="checkbox"/> Dados fornecidos suficientes <input type="checkbox"/> Dados fornecidos insuficientes <input type="checkbox"/> Outra: _____ _____ _____

aa) a intensidade média de uso da forma de apresentação de 'exemplo': textual c/ figura pelo estilo RS tende a ser ALTA.	<input type="checkbox"/> Sim <input type="checkbox"/> Não Por quê? _____ _____ _____ _____	<input type="checkbox"/> Nada se pode afirmar <input type="checkbox"/> Baixa <input type="checkbox"/> Média baixa <input type="checkbox"/> Média <input type="checkbox"/> Média alta <input type="checkbox"/> Alta	<input type="checkbox"/> Conhecimento <input type="checkbox"/> Experiência <input type="checkbox"/> Dados fornecidos suficientes <input type="checkbox"/> Dados fornecidos insuficientes <input type="checkbox"/> Outra: _____ _____ _____
---	---	---	--

IV. Tempo de permanência nos 'Recursos Didáticos'

bb) o tempo médio de permanência nos recursos didáticos de 'Exercício' e 'Exemplo' pelo estilo RS tende a ser ALTO.	<input type="checkbox"/> Sim <input type="checkbox"/> Não Por quê? _____ _____ _____ _____	<input type="checkbox"/> Nada se pode afirmar <input type="checkbox"/> Baixa <input type="checkbox"/> Média baixa <input type="checkbox"/> Média <input type="checkbox"/> Média alta <input type="checkbox"/> Alta	<input type="checkbox"/> Conhecimento <input type="checkbox"/> Experiência <input type="checkbox"/> Dados fornecidos suficientes <input type="checkbox"/> Dados fornecidos insuficientes <input type="checkbox"/> Outra: _____ _____ _____
---	---	---	--

V. Tempo de permanência nas 'Formas de Apresentação'

cc) o tempo médio de permanência nas formas de apresentação de 'Exercícios': escolha simples pelo estilo RS tende a ser ALTA.	<input type="checkbox"/> Sim <input type="checkbox"/> Não Por quê? _____ _____ _____ _____	<input type="checkbox"/> Nada se pode afirmar <input type="checkbox"/> Baixa <input type="checkbox"/> Média baixa <input type="checkbox"/> Média <input type="checkbox"/> Média alta <input type="checkbox"/> Alta	<input type="checkbox"/> Conhecimento <input type="checkbox"/> Experiência <input type="checkbox"/> Dados fornecidos suficientes <input type="checkbox"/> Dados fornecidos insuficientes <input type="checkbox"/> Outra: _____ _____ _____
--	---	---	--

dd) o tempo médio de permanência nas formas de apresentação de 'Exemplos': textual c/ figura e esquema c/ figura pelo estilo RS tende a ser ALTA.	<input type="checkbox"/> Sim <input type="checkbox"/> Não Por quê? _____ _____ _____ _____	<input type="checkbox"/> Nada se pode afirmar <input type="checkbox"/> Baixa <input type="checkbox"/> Média baixa <input type="checkbox"/> Média <input type="checkbox"/> Média alta <input type="checkbox"/> Alta	<input type="checkbox"/> Conhecimento <input type="checkbox"/> Experiência <input type="checkbox"/> Dados fornecidos suficientes <input type="checkbox"/> Dados fornecidos insuficientes <input type="checkbox"/> Outra: _____ _____ _____
--	---	---	--

