

**UNIVERSIDADE FEDERAL DE UBERLÂNDIA**

**FACULDADE DE ENGENHARIA ELÉTRICA**

**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**



**MODELO NEURAL POR PADRÕES PROXIMAIS DE  
APRENDIZAGEM PARA AUTOMAÇÃO PERSONALIZADA DE  
CONTEÚDOS DIDÁTICOS**

**FRANCISCO RAMOS DE MELO**

**Orientadora:** Prof<sup>ª</sup> Dr<sup>a</sup> Edna Lúcia Flôres

Uberlândia

2012

**FRANCISCO RAMOS DE MELO**

**MODELO NEURAL POR PADRÕES PROXIMAIS DE  
APRENDIZAGEM PARA AUTOMAÇÃO PERSONALIZADA DE  
CONTEÚDOS DIDÁTICOS**

Tese apresentada ao Programa de Pós-Graduação Strictu  
Sensu da Faculdade de Engenharia Elétrica da  
Universidade Federal de Uberlândia, como recurso  
parcial para obtenção do título de **Doutor em Ciências**.

**Área de Concentração:** Engenharia Elétrica

**Linha de Pesquisa:** Processamento de Sinais

Uberlândia

2012

## **PAGINA DE APROVAÇÃO**

---

Edna Lucia Flôres, Dr<sup>a</sup> (UFU) – Orientadora

---

Carlos Roberto Lopes, Dr. (UFU)

---

Gilberto Arantes Carrijo, Dr. (UFU)

---

Elise Barbosa Mendes, Dr<sup>a</sup> (UFU)

---

Ricardo Antonio Gonçalves Teixeira, Dr. (UFG)

---

Rosa Maria Viccari, Dr<sup>a</sup> (UFRGS)

## **AGRADECIMENTOS**

Agradeço a Deus que no seu infinito amor me concedeu tantas bênçãos como a concessão deste trabalho e, ainda, me proporciona tanto e tantos a agradecer.

Agradeço a Nossa Senhora, nossa mãezinha do céu que tanto nos ama, incessantemente intercede por nós e a quem sempre sou consagrado “...como filho e propriedade vossa, amém”.

Tenho um agradecimento todo especial para a mais encantadora e especial das pessoas: Magda Ribeiro Machado Ramos de Melo, minha esposa que tanto amo (“não precisa lembrar...”). Amiga incondicional que engrandece todos os momentos da minha vida. Obrigado por todos os momentos, pela alegria, pela abnegação, pela compreensão, pelas broncas, pela conquista de tantos sonhos e por ter se desdobrado em tantos momentos durante a realização deste trabalho. Seu amor, compreensão e coragem tem sido o meu porto seguro nesta caminhada, como em tantas outras já ocorridas e em muitas outras que, se Deus quiser, teremos para trilhar sempre juntos. Obrigado por este cantinho tão aconchegante no seu coração.

Minha filha Duane Ribeiro Machado Ramos de Melo, um grande milagre a nós concedido por Deus, como um poema na forma de uma linda menina. Obrigado por compreender minhas muitas ausências, apoiar e torcer pelo sonho do seu pai. Sua luz e alegria entusiasmarão nossa caminhada.

Agradeço ao berço da minha família. Aos meus pais José Bezerra de Melo e Francisca Ramos de Melo que me educaram e conduziram com muito amor e carinho. Aos meus irmãos que tanto admiro e amo: Cícero Bezerra Ramos, Irení Bezerra Ramos e Luciano Bezerra Ramos. A vocês, obrigado pela fortaleza das minhas raízes.

Edna Lúcia Flôres, esta caminhada não teria sido possível sem a sua confiança, parceria e dedicação. Mais do que orientadora, você se tornou uma grande amiga. Obrigado por todos os momentos, ensinamentos, confiança, conversas e, em especial, a atenção com cada detalhe nas leituras e discussões que proporcionaram este trabalho.

Aos meus professores, iniciando com a Dona Mariana Lopes Pagliusi, todos que estiveram, estão e virão a estar em minha caminhada, como tutores e colegas. Aos

professores Weber Martins e Lauro Eugênio Guimarães Nalini, pela amizade e as indicações iniciais dos caminhos deste trabalho.

Ao companheiro Sirlon Diniz de Carvalho, mais uma vez, responsável pelo início desta jornada. Além da amizade e confiança, por meio dele quero agradecer a todos meus alunos, responsáveis por manter acesa a chama do entusiasmo em continuar aprendendo a apreender.

Aos meus familiares, tios, primos, sogros, cunhados, sobrinhos, afilhados e aos muitos amigos e colegas que, graças a Deus, são tantos. Obrigado pelo carinho, consideração, apoio e torcida.

Agradeço a todas as pessoas do programa de pós graduação em Engenharia Elétrica da UFU pelo apoio direto e indiretamente proporcionado. Aos professores do programa que iluminaram os caminhos desta tese: Edna Lúcia Flôres, Gilberto Arantes Carrijo e José Roberto Camacho. A todos, meu muito obrigado pela luz do conhecimento, descoberta e o despertar da paixão pela busca do conhecimento. Por meio da Cinara, quero agradecer a todos da secretaria do programa pela presteza, atenção e valiosa ajuda em todos os passos desta caminhada.

Para as três grandes mulheres da minha vida

Duane, Magda e Francisca

# SUMÁRIO

LISTA DE FIGURAS .....	IV
LISTA DE TABELAS .....	VII
LISTA DE SIGLAS E ABREVIATURAS .....	VIII
RESUMO.....	IX
ABSTRACT.....	X
CAPÍTULO 1 - INTRODUÇÃO1	
1.1 - Introdução.....	1
1.2 – Tema .....	2
1.3 – Objetivos .....	3
1.4 – Motivação .....	4
1.5 – Justificativa .....	5
1.6 – Problema e Hipóteses.....	5
1.7 – Estrutura deste Trabalho .....	8
1.8 – Considerações Finais Deste Capítulo .....	9
PARTE I – FUNDAMENTAÇÃO TEÓRICA	
CAPÍTULO 2 - TRANSMISSÃO DE CONHECIMENTOS	
2.1 - Introdução.....	11
2.2 - Evolução Histórica do Ensino .....	12
2.3 – Padrões para a Personalização .....	15
2.3.1 – Zona proximal de desenvolvimento .....	20
2.4 – Componentes do Processo Ensino-aprendizagem .....	22
2.4.1 – Organização de conteúdos .....	23
2.4.2 – Apresentação do conteúdo didático .....	24
2.5 - Computadores na Educação .....	28
2.5.1 – Sistemas tutores inteligentes.....	31
2.6 – Considerações Finais Deste Capítulo .....	35
CAPÍTULO 3 – PADRÕES E REDES NEURAIIS	
3.1 - Introdução.....	36
3.2 – Reconhecimento de Padrões (RP).....	37
3.2.1 – Sistema de reconhecimento de padrões .....	38
3.2.2 – Projeto de sistemas de reconhecimento de padrões .....	41
3.3 - Redes Neurais Artificiais.....	43
3.3.1 – Inteligência artificial.....	43
3.3.2 – Histórico das Redes Neurais.....	44
3.3.3 – Visão geral de redes neurais .....	45

3.3.4 – O neurônio artificial.....	49
3.3.5 – Topologias de redes com neurônios artificiais .....	51
3.3.6 – Aprendizado computacional .....	52
3.3.7 – Regras para o ajuste de pesos .....	53
3.3.8 – O perceptron .....	55
3.3.9 – Perceptron de múltiplas camadas (MLP).....	57
3.3.10 – Treinamento de redes perceptron de múltiplas camadas .....	58
3.3.11 – Desenvolvimento de sistemas conexionistas .....	61
3.4 – Considerações Finais Deste Capítulo .....	63

## CAPÍTULO 4 – REPRESENTAÇÃO MATEMÁTICA DE MODELOS E MÉTODOS NUMÉRICOS

4.1 - Introdução .....	64
4.2 – Matemática e Representação de Modelos .....	65
4.3 - Métodos Numéricos.....	68
4.3.1 – Métodos de interpolação e aproximação de curvas .....	68
4.3.2 – Equações diferenciais .....	73
4.4 – Considerações Finais Deste Capítulo .....	77

## PARTE II – TRABALHO PROPOSTO

### CAPÍTULO 5 - MODELO PROPOSTO

5.1 - Introdução .....	79
5.2 – Composição do Modelo .....	80
5.2.1 - Conteúdo didático multinível .....	80
5.2.2 - Padrão proximal de aprendizagem .....	84
5.2.3 - Ajuste reativo da trajetória didática .....	88
5.3 - Estrutura do Sistema para a Personalização Reativa .....	94
5.4 – Considerações Finais Deste Capítulo .....	100

### CAPÍTULO 6 - EXPERIMENTOS E RESULTADOS OBTIDOS

6.1 - Introdução .....	102
6.2 – Metodologia do Experimento .....	102
6.2.1 – Tipos de tutores desenvolvidos para o experimento.....	103
6.3 – Realização do Experimento .....	104
6.3.1 – Formatação do conteúdo.....	104
6.3.2 – Definição do perfil do estudante.....	105
6.3.3 – Definição da rede neural.....	106
6.3.4 – Definição de regras de especialistas .....	109
6.3.5 – Sistemas de navegação e coleta de dados .....	110
6.3.6 – Recursos computacionais .....	116
6.4 – Análise dos Resultados Obtidos .....	117
6.4.1 – Teste de correlação do padrão proximal de aprendizagem.....	119
6.5 – Conclusões .....	123



## PARTE III– CONCLUSÕES

## CAPÍTULO 7 - CONCLUSÕES E CONTRIBUIÇÕES

7.1 – Introdução .....	125
7.2 – Conclusões .....	125
7.3 – Contribuições .....	127
7.4 – Trabalhos Futuros .....	128
7.5 – Publicações Originadas Neste Trabalho .....	129
7.6 – Considerações Finais Deste Capítulo .....	130
REFERÊNCIAS BIBLIOGRÁFICAS .....	131
ANEXO 1 - IDENTIFICAÇÃO DO PERFIL PESSOAL .....	140
ANEXO 2 - QUESTIONÁRIO DE HABILIDADES .....	155
ANEXO 3 - FORMULÁRIO DE ATUAÇÃO DOCENTE .....	156

# LISTA DE FIGURAS

Figura 2.1: Padrões de comportamento da mente humana	18
Figura 2.2: Exemplo de dicotomia	18
Figura 2.3: Modelo linear Myers-Briggs	19
Figura 2.4: Zona proximal de desenvolvimento	21
Figura 2.5: Tutorial clássico	26
Figura 2.6: Tutorial orientado por atividades	26
Figura 2.7: Tutorial customizado	26
Figura 2.8: Tutorial de avanço por conhecimento	27
Figura 2.9: Tutorial exploratório	27
Figura 2.10: Tutorial gerador de lições	28
Figura 2.11: Arquitetura tradicional de um STI	32
Figura 3.1: Sistema para reconhecimento de padrões	39
Figura 3.2: Modelo geral do sistema de reconhecimento	40
Figura 3.3: Representação do classificador	41
Figura 3.4: Etapas do projeto de um sistema de reconhecimento de padrões	41
Figura 3.5: Representação de um sistema inteligente	43
Figura 3.6: Estrutura do neurônio humano	46
Figura 3.7: Estrutura do neurônio artificial (MacCulloch e Pitts)	46
Figura 3.8: Rede neural artificial (RNA)	47
Figura 3.9: Neurônio Artificial	49
Figura 3.10: Funções de ativação	51
Figura 3.11: Algoritmo de treinamento do perceptron	56
Figura 3.12: Rede neural perceptron de múltiplas camadas (MLP)	57
Figura 3.13: Fases do treinamento da rede MLP	59
Figura 3.14: Algoritmo Back-Propagation	60

Figura 4.1: Representação gráfica da função “dobro”	67
Figura 4.2: Exemplos de interpolação simples	70
Figura 4.3: Interpolação utilizando funções Spline cúbicas	73
Figura 4.4: Diferenças finitas no plano bidimensional	75
Figura 4.5: Molécula da diferença no centro do plano x	75
Figura 4.6: Molécula da diferença no centro do plano y	76
Figura 4.7: Molécula da diferença no centro do plano bidimensional	77
Figura 5.1 – Ilustração do sistema proposto	80
Figura 5.2: Organização do tutorial clássico	81
Figura 5.3. Exemplo de organização do tutorial customizado	82
Figura 5.4: Exemplos de padrões proximais de aprendizagem $L_{\Omega}$	88
Figura 5.5: Sequência da trajetória didática do conteúdo convencional	90
Figura 5.6: Sequência da trajetória didática no conteúdo multinível	90
Figura 5.7: Distribuição do conceito multinível	91
Figura 5.8: Formalização do conceito multinível	91
Figura 5.9: Correção no eixo dos níveis principais	92
Figura 5.10: Correção no eixo dos níveis e auxiliares	92
Figura 5.11: Correção da trajetória didática	93
Figura 5.12: Estrutura do conteúdo multinível do sistema proposto	94
Figura 5.13: Exemplo de questão com diferentes graus de acerto	95
Figura 5.14: Estrutura para definir o padrão proximal de aprendizagem $L_{\Omega}$	95
Figura 5.15: Exemplo de regras de especialistas	97
Figura 5.16: Mecanismo do padrão de decisão probabilística	98
Figura 5.17: Estrutura do sistema proposto para personalização de conteúdos didáticos	99
Figura 6.1 – Organização do experimento realizado neste trabalho	103
Figura 6.2: Estruturação do perfil do estudante	105

Figura 6.3: Detalhe da curva de treinamento da RNA selecionada	108
Figura 6.4: Estrutura da RNA selecionada para o experimento deste trabalho	109
Figura 6.5: Representação de incoerência na navegação	111
Figura 6.6: Estrutura do sistema tutor livre	112
Figura 6.7: Tela do navegador do tutor livre	113
Figura 6.8: Curva de desempenho de notas das navegações	114
Figura 6.9: Estrutura do sistema inteligente	115
Figura 6.10: Estrutura do sistema aleatório	116
Figura 6.11: Correlação do Nível Facilitado	120
Figura 6.12: Correlação do Nível Médio/Próximo	121
Figura 6.13: Correlação do Nível Exemplos	121
Figura 6.14: Correlação do Nível FAQs	122

## LISTA DE TABELAS

Tabela 5.1: Regras de Indicações Locais	95
Tabela 6.1: Organização das alternativas dos exercícios do Tutor	111
Tabela 6.2: Recursos computacionais utilizados neste trabalho	116
Tabela 6.3: Análise descritiva dos dados	118
Tabela 6.4: Comparativo do desempenho médio das navegações	119
Tabela 6.5: Correlação de Pearson RNA X Observado	122

## LISTA DE SIGLAS E ABREVIATURAS

AVA	-	Ambientes Virtuais de Aprendizagem
CAI	-	Instrução Assistida por Computador (do Inglês <i>Computer-Assisted Instruction</i> )
EAD	-	Educação a Distância
EDO	-	Equação diferencial ordinária
EDP	-	Equação diferencial parcial
FAQ	-	Perguntas e respostas (do inglês: <i>Frequently Asked Questions</i> – Questões mais frequentes)
IA	-	inteligência artificial
ICAI	-	Instrução Inteligente Assistida por Computador (do Inglês <i>Intelligent Computed Assisted Instruction</i> )
IP	-	Instrução Programada
MLP	-	Perceptron de Múltiplas Camadas (do inglês <i>Multi Layer Perceptron</i> )
RNA	-	Rede neural artificial
RP	-	Reconhecimento de padrões
STI	-	Sistema tutor inteligente
TICs		Tecnologias de Informação e Comunicação
UFU	-	Universidade Federal de Uberlândia
ZPD	-	Zona proximal de desenvolvimento

# RESUMO

Este trabalho apresenta uma modelagem para a organização personalizada de conteúdos didáticos para ambientes de estudos individuais. Para muitos estudantes a disponibilização do conteúdo em formato generalizado pode não ser eficiente. É proposta uma estrutura multinível de conceitos para proporcionar o desenvolvimento de diferentes combinações para a apresentação do mesmo conteúdo. O trabalho mostra que é possível personalizar o conteúdo de forma a favorecer outros estudantes com o uso de padrões proximais de aprendizagem. Estes padrões são obtidos da análise da ação de estudantes, com resultados positivos na organização individual do conteúdo. A representação formal estabelece a definição do perfil do estudante, o conteúdo multinível, o plano de distribuição dos conceitos e a correção da trajetória didática. A estruturação da trajetória didática do estudante é formalmente estabelecida pelo método das diferenças finitas. O sistema utiliza técnicas de inteligência artificial para organizar e personalizar reativamente o conteúdo. A personalização é proporcionada por uma rede neural artificial que possibilita a classificação do perfil do estudante e associa esse perfil a um padrão proximal de aprendizagem. Para mediar e ajustar o conteúdo de forma reativa foi inserido no sistema um conjunto de regras de especialistas em docência. O experimento realizado mostrou a aplicabilidade e a adequação da modelagem proposta. Os resultados indicaram a adequação da abordagem, automatizando a organização personalizada do conteúdo de forma adaptativa e reativa. O sistema inteligente ao estabelecer a estruturação personalizada do conteúdo a ser apresentado foi considerado eficiente, proporcionando ao estudante um melhor aproveitamento do conteúdo, com maior média final e menor tempo de estudo e conteúdo apresentado.

**Palavras chave:** Sistema tutor inteligente conexionista; padrões proximais de aprendizagem; conteúdo didático multinível; Método das diferenças finitas; Educação a distância.

# ABSTRACT

This study presents a model for the organization of educational content customized for environments of individual studies. For many students the availability of content in general form can not be efficient. It proposed a multilevel structure of concepts to provide the development of different combinations to show the same content. The work shows that it is possible to customize the content in order to encourage other students with the use of proximal learning standards. These patterns are obtained from the analysis of the action of students with positive results in the individual organization of the content. The formal representation establishes the definition of the student profile, multi-level content, the distribution plan of correction of concepts and teaching career. The structure of the trajectory of student teaching is formally established by the method of finite differences. The system uses artificial intelligence techniques to organize and personalize content reactively. Customization is provided by an artificial neural network that enables the classification of the student profile and assign that profile to a standard proximal learning. To mediate and adjust the contents of a reactive system was inserted into a set of rules from experts in teaching. The experiment showed the applicability and appropriateness of the proposed model. The results indicated the suitability of the approach by automating the organization's custom content so adaptive and reactive. The intelligent system to establish the structure of the custom content to be presented was considered efficient, giving the student a better use of the content, with higher and lower final average study time and content presented.

**Keywords:** Connectionist intelligent tutoring systems; proximal learning patterns; multilevel didactic content; finite differences method; distance education.



# CAPÍTULO 1

## INTRODUÇÃO

### 1.1 - Introdução

A organização tradicional de um modelo de construção de conhecimentos em sala de aula pode considerar três elementos básicos e suas relações multilaterais: o educador como o agente mediador do conhecimento, o educando como o agente interessado pelo conhecimento e o conteúdo que contém o assunto a ser aprendido.

O educando é o agente para quem todo o processo educacional deve ser direcionado. É para ele que deve ser organizado o processo de aquisição de conhecimento. Assim é importante estabelecer alguns pontos como elemento de identificação do educando, tais como: sua forma de aprender, suas reações ao que está sendo discutido, etc.

O conteúdo é o elemento que contém o conhecimento a ser apresentado, discutido e apreendido. Esse conteúdo pode conter um ou mais conceitos relacionados ao conhecimento. Para a sua apresentação, é importante estabelecer elementos que favoreçam a interação de aproximação com o educando.

O educador é o elemento que estabelece o diálogo entre o conhecimento construído historicamente e o educando. Para isto, organiza os conceitos, sua forma de apresentação e estabelece a interação com os educandos, em uma relação dialógica. Esta interação suscita o enriquecimento da formação do conteúdo proposto, em um processo de construção individual e coletiva.

Em ambientes de estudo individual, objeto de interesse do presente estudo, a interação com o conteúdo é realizada por formas diferenciadas de apresentação. A diferenciação na apresentação de um texto, por exemplo, pode ocorrer com uma apresentação em linguagem mais simples ou mais rebuscada, em um processo de adequação ao público interessado. As diferentes formas de organização ou adaptações na exposição dos conteúdos, podem prever e minimizar dificuldades que o estudante pode ter durante o estudo. No estudo individual, a

ausência do professor no momento em que ocorrem as dificuldades impede, muitas vezes, a compreensão, dificultando o avanço nos estudos.

Sistemas computacionais incorporando alguma espécie de inteligência foram desenvolvidos para auxiliar os aprendizes no processo de assimilação de conhecimentos. Dentre esses destaca-se os Sistemas Tutores Inteligentes (STIs) que empregam técnicas de inteligência artificial.

Os STIs objetivam implementar estratégias para personalizar o processo de transmissão de conhecimento. Adicionalmente, o STI pode apresentar técnicas que proporcionam ação à reatividade do estudante. De alguma maneira, as técnicas dos STIs procuram desenvolver mecanismos computacionais que reproduzam alguma tecnologia educacional consolidada no ensino presencial.

O sistema proposto neste trabalho procura reproduzir, em modelos simplificados, as diferentes ações de um professor para conduzir o ensino presencial. Especificamente, o trabalho pretende reproduzir formas diferenciadas de reapresentar, em um processo de assimilação, o mesmo conteúdo diante das reações do estudante mediante suas respostas aos elementos disponibilizados na exposição do conceito.

Este capítulo apresenta uma contextualização geral do trabalho proposto e sua estrutura. São apresentados os objetivos e as hipóteses para a solução do problema apresentado que é a organização personalizada de conteúdos. Finalmente, são realizadas as considerações finais deste capítulo.

## **1.2 – Tema**

Um dos propósitos do emprego de técnicas de Inteligência Artificial em Sistemas Tutores Inteligentes é a busca de um comportamento semelhante ao tutor humano, capaz de oferecer um ensino adaptativo, reativo, flexível e personalizado. Com esse objetivo pesquisadores adotaram as mais diversas abordagens.

Neste trabalho, é discutido elementos para o desenvolvimento de um sistema tutor inteligente conexionista. É proposta uma estruturação de conteúdo em vários níveis, elementos para propiciar a apresentação personalizada do conteúdo e a definição de padrões proximais de aprendizagem. Foi organizado, nesse sentido, um experimento para avaliar o modelo. Para comprovar a eficiência do sistema proposto, são apresentados os resultados

obtidos no estudo, comparando a execução de um tutor inteligente com outros tutores sem essa característica.

O tema deste trabalho é o desenvolvimento de sistemas tutores inteligentes conexionistas, cuja delimitação é a sua aplicação no âmbito da educação em suas diferentes modalidades e usos.

### **1.3 – Objetivos**

O objetivo geral do trabalho é a representação de um modelo para o desenvolvimento de sistemas tutores conexionistas e a demonstração de sua capacidade de promover um ambiente favorável de estudo de maneira geral e, mais especificamente, para estudantes com algum tipo de dificuldade em estabelecer uma estratégia satisfatória de estudo. Para tanto, procura-se estabelecer um mecanismo didático, auxiliado por sistema computacional, que promova estratégias na formação do indivíduo no processo de aprendizagem em ambiente de estudo individual não presencial. Esse mecanismo pressupõe o auxílio na apresentação personalizada de conteúdos, em que a organização dos conceitos interage com o conhecimento interno e o desenvolvimento do aprendiz no processo de aquisição do conhecimento objetivado.

Para atender ao objetivo geral proposto, analisa-se os fatores constituintes e as relações entre os atores do processo (professor e estudante) com o emprego de sistemas tutores inteligentes conexionistas, evidenciando o processo de desenvolvimento e avaliação do processo formativo do estudante. Desta forma, é importante avaliar o potencial e a capacidade que a ferramenta computacional pode oferecer no processo e, assim, estudar os elementos que possam sustentar a importância do sistema no processo inclusivo em ambientes de tutoria não presencial ou mediada, em conformidade com a aplicação.

Os objetivos específicos buscam estabelecer:

- A organização de um conteúdo que possibilite uma apresentação personalizada e reativa (resposta às ações do estudante);
- O mecanismo para a correção da trajetória didática diante das reações do estudante, nos momentos de estudo individual, sem a necessidade da presença de um professor ou tutor;
- A representação e a identificação do modelo do estudante;

- A representação e o modelo de organização do conteúdo;
- A organização da estrutura de técnicas computacionais de inteligência artificial para a implementação do sistema de tutoria para a apresentação do conteúdo;
- A definição do experimento para o estudo do modelo;
- A análise dos dados coletados no experimento; e
- A validação da aplicabilidade do modelo.

Não é objetivo deste trabalho comprovar a existência direta entre as características do perfil psicológico do estudante e uma determinada forma de aprender. O trabalho procura demonstrar que o modelo proposto tem capacidade de estabelecer ligações entre as características selecionadas pelo professor e as estratégias que podem favorecer o educando em um ambiente virtual de aprendizagem.

#### **1.4 – Motivação**

A Educação a Distância (EAD) é uma modalidade de ensino, cujos conhecimentos são apresentados em grande parte de forma assíncrona quanto a presença do professor e do estudante no local em que ocorre o processo de ensino-aprendizagem. Nesse sentido, o professor e o estudante não precisam ocupar simultaneamente o mesmo espaço e tempo. Esta situação transfere ao estudante grande parte da responsabilidade pela condução do próprio aprendizado. Assim, espera-se um estudante com perfil disciplinado e autônomo, capaz de gerenciar a aprendizagem. O auxílio na aprendizagem pode estar no esforço do professor em organizar conteúdos que procuram minimizar dificuldades. Entretanto, essa organização pode não ser a mais adequada quanto a aceitação por outros estudantes.

Várias tecnologias são desenvolvidas na busca de soluções para prover o ensino adaptativo, contextualizado, direcionado e flexível em ambientes virtuais de aprendizagem (AVA). O sistema tutor inteligente (STI) é uma das mais proeminentes tecnologias computacionais para a adaptabilidade da transmissão de conhecimentos em ambientes EAD. O desenvolvimento de STIs normalmente emprega técnicas de inteligência artificial clássica, na qual o conhecimento para a estruturação do sistema é estabelecido conforme o entendimento do especialista e a qualidade de comunicação deste com o desenvolvedor.

A inteligência artificial conexionista é uma linha onde a organização do conhecimento é estabelecida por exemplos, conforme as características consideradas. Uma das técnicas predominantes nesta área são as redes neurais artificiais.

A utilização de uma abordagem fundamentada em redes neurais com a perspectiva de poder contribuir técnica e cientificamente para a construção de sistemas tutores inteligentes motivou o desenvolvimento deste trabalho.

### **1.5 – Justificativa**

A intenção de realizar um estudo sobre os elementos que constituem um processo de tutoria personalizável mediado por computadores em ambiente de tutoria com propósito não presenciais de aprendizagem (AVA) é justificada pela necessidade de criar mecanismos que possibilitem a condução do conhecimento justamente para evitar o processo de exclusão (inadequação do perfil para AVAs) daqueles que, por razões adversas, não tem disponibilidade de acesso a um tutor humano na mediação do processo de assimilação de seus conhecimentos. Tais mecanismos devem considerar que cada indivíduo tem um perfil particular de inteligência e relações distintas com o mundo.

### **1.6 – Problema e Hipóteses**

Nas últimas décadas, o sistema educacional tem presenciado o enorme crescimento das tecnologias de informação e comunicação (TICs) e admitido o computador como potencial ferramenta de apoio ao processo de ensino e de aprendizagem. Vários projetos têm sido voltados para essa área, desde cursos presenciais, realizados nos computadores, até cursos a distância, muitos deles utilizando redes de computadores, proporcionando a educação "on-line".

O êxito nos cursos *on-line* depende da forma como as pessoas se preparam e organizam para atingir seus objetivos. Isto aumenta a responsabilidade dos ambientes de ensino, pois a qualidade e a forma como o processo de ensino é conduzido podem ser decisivas no alcance do sucesso objetivado.

A crescente necessidade de aperfeiçoamento e a dificuldade em conciliar a disponibilidade dos professores com a dos estudantes, proporcionou o aumento da procura

pelos cursos não presenciais. Se esses cursos oferecem uma melhor adequação às necessidades individuais dos aprendizes, por outro lado ainda não conseguem contextualizar as necessidades do indivíduo em sua condução no conteúdo exposto. Em geral, independente da mídia, os sistemas conduzem o processo de ensino como se fosse um livro, no qual o aprendiz escolhe aprender aleatoriamente ou sequencialmente o conteúdo apresentado. Com isto, muitos conteúdos podem não ser adequadamente apreendidos conforme a subjetividade empregada ou devido à necessidade de seguir uma sequência empregada sem considerar a individualidade/inteligência própria de cada aprendiz.

No modelo de ensino não presencial, o estudante passou a ter a possibilidade de acessar o conhecimento e controlar a sua disponibilidade e ritmo. Esse modelo tem sido alvo de muitas pesquisas e estudos. Um grande problema desse modelo consiste em administrar individualidades [Horton, 2000]. Um livro, por exemplo, é uma forma de ensino não presencial. Independente do leitor, o formato do livro é o mesmo com a mesma sequência de páginas e capítulos. É tarefa do leitor seguir a sequência original do livro ou, então, construir uma que julgue mais adequada, alterando a forma de folheá-lo.

A maioria dos sistemas de ensino a distância não oferecem um ensino adaptativo ao perfil individual do estudante. Alguns sistemas empregam recursos para promover maior interação e individualização, entretanto eles mantêm sua característica principal: a distribuição de conteúdo estático e linear.

Um grande problema do ensino a distância é a personalização da interação do aprendiz com o sistema tutor e o atendimento das suas necessidades no momento em que essas ocorrem [Park, 1987; Giraffa, 1997; Horton, 2000; Vicari, 2005].

A organização e a apresentação do conteúdo têm grande relevância nos processos de transmissão de conhecimento. Sua relevância aumenta em ambientes de ensino não presencial, o que justifica o desenvolvimento de várias tecnologias nesse âmbito. A inserção de computadores eletrônicos no processo tem apresentado importantes contribuições ao estudante. Grande parte das aplicações computacionais desenvolvidas consiste em uma versão eletrônica mais sofisticada dos livros. O desenvolvimento de tecnologias computacionais empregando inteligência artificial (IA) propiciou soluções de interação na modalidade não presencial. Os sistemas tutores inteligentes (STI) fazem parte das soluções que empregam IA para aplicações educacionais. Os STIs são desenvolvidos buscando formas de estabelecer ligações entre o objeto de aprendizagem e a estrutura cognitiva do estudante. Um grande esforço no desenvolvimento de um STI é a busca de um mecanismo que possa compensar a

ausência do professor na condução didática do conteúdo a ser apresentado [Park, 1987; Giraffa, 1997; Horton, 2000; Vicari, 2005].

Nas pesquisas de STI observa-se um grande esforço no desenvolvimento de técnicas para a apresentação de um conteúdo personalizado e reativo ao estudante [Dastbaz, 2006; Duque, 2006, Jimenez, 2006; Méndez, 2008]. O desenvolvimento de STIs, normalmente emprega técnicas de IA simbólica [Kaplan, 1995; Giraffa, 1997; Vicari, 2005; Méndez, 2008; Fontenla, 2010]. Nestas técnicas os processos de conhecimento são abstraídos e organizados em regras ou estruturas equivalentes que possibilitam a manipulação automatizada por um sistema.

Uma alternativa de desenvolvimento de trabalhos com STIs buscou simplificar a representação do conhecimento com técnicas de IA conexionista [Alencar, 2000; Carvalho, 2002; Melo, 2003; Martins, 2004; Fonseca, 2007; Quinderé, 2008; Melo 2011; Melo, 2012]. No conexionismo o conhecimento é abstraído, organizado e manipulado na forma de padrões. Os trabalhos apresentaram bons resultados, porém foram desenvolvidos empiricamente, sem formalismo matemático. A formalização matemática consolida o modelo, facilita seu entendimento e possibilita a concepção e o desenvolvimento de novos trabalhos, além de proporcionar direções lógicas e assertivas em conformidade com a parametrização. Trabalhos apresentados em diferentes áreas do conhecimento mostraram a capacidade de descrição da formalização matemática [Cruz, 2005; Barros, 2005; Teixeira, 2007; Vargas, 2008; Cereda, 2008; Barajas, 2010].

A hipótese principal deste trabalho é:

- O trabalho parte da hipótese de que é possível estabelecer uma representação formal para a modelagem de sistemas tutores conexionistas.

As hipóteses secundárias são:

- Conteúdos podem ser reestruturados para proporcionar alternativas de apresentação do mesmo conteúdo;
- Um padrão proximal de aprendizagem pode proporcionar a personalização do conteúdo para o estudante;

- A organização do sistema é responsável pela melhoria na aprendizagem do estudante; e
- A organização do sistema pode proporcionar a exposição de menor quantidade de conteúdos expositivos e ocupar o usuário por menos tempo.

## **1.7 – Estrutura deste Trabalho**

Este trabalho constitui-se de três partes principais. A primeira delas apresenta a fundamentação teórica (Capítulos 2, 3 e 4). Na segunda parte, é descrito o sistema proposto e, na última parte, são apresentados o experimento do sistema proposto e a análise dos dados coletados.

O Capítulo 2 apresenta uma revisão bibliográfica dos processos de transmissão de conhecimentos. Assim, são apresentadas as modalidades de transmissão do conhecimento, os elementos para a personalização, a organização dos conteúdos, as estruturas de apresentação dos conteúdos e o emprego de computadores no ensino. Finalmente, são realizadas as considerações finais desse capítulo.

O Capítulo 3 apresenta uma breve revisão bibliográfica sobre os padrões e as redes neurais artificiais, o modelo de rede neural Perceptron de Múltiplas Camadas (MLP, do inglês Multi Layer Perceptron) utilizado no sistema proposto neste trabalho. Finalmente, são realizadas as considerações finais desse capítulo.

O Capítulo 4 apresenta uma breve revisão bibliográfica sobre a representação matemática de modelos e os métodos numéricos. São apresentados os conceitos necessários da representação matemática para a formalização de um modelo. O método das diferenças finitas é descrito por proporcionar a fundamentação necessária na representação da organização da apresentação do conteúdo. Nesse capítulo são mostrados os elementos necessários para a fundamentação da modelagem matemática do modelo proposto neste trabalho. Finalmente, são realizadas as considerações finais desse capítulo.

O Capítulo 5 apresenta o modelo proposto, descrito formalmente em sua estrutura e organização. Nesse capítulo são mostrados os elementos essenciais na definição do conteúdo multinível, a identificação do estudante, a associação do padrão proximal de aprendizagem e a



organização da apresentação do conteúdo. Finalmente, são realizadas as considerações finais desse capítulo.

No Capítulo 6, é apresentado o experimento do modelo proposto e os resultados obtidos. É descrita a metodologia e a forma de realização do experimento ao mesmo tempo em que são apresentadas as soluções de implementação do modelo proposto. No final do capítulo são apresentados os resultados obtidos e a análise dos dados. Finalmente, são realizadas as conclusões desses resultados.

O Capítulo 7 apresenta as conclusões e as contribuições desta tese, os trabalhos futuros que poderão ser desenvolvidos a partir desta tese e as publicações originadas neste trabalho. Finalmente, são realizadas as considerações finais deste capítulo.

## **1.8 – Considerações Finais Deste Capítulo**

Neste Capítulo foi apresentada uma contextualização geral do trabalho proposto e sua estrutura. Foram apresentados os objetivos e as hipóteses para a solução do problema apresentado que é a organização personalizada de conteúdos.

Este trabalho busca estabelecer a representação para o desenvolvimento de STIs connexionistas. Desta forma, ele procura estabelecer os aspectos que fazem parte do processo de ensino empregando Sistemas Tutores Inteligentes Connexionistas que consideram a capacidade cognitiva individual para a apresentação do conteúdo a ser transmitido.

O próximo capítulo apresenta uma revisão bibliográfica dos processos de transmissão de conhecimentos. São apresentadas as modalidades de transmissão do conhecimento, os elementos para a personalização, a organização dos conteúdos, as estruturas de apresentação dos conteúdos e o emprego de computadores no ensino. Finalmente, são realizadas as considerações finais do capítulo.

# PARTE I

---

## Fundamentação Teórica

## CAPÍTULO 2

### TRANSMISSÃO DE CONHECIMENTOS

#### 2.1 - Introdução

A transmissão de conhecimentos é, provavelmente, um diferencial da sociedade humana. As diferentes modalidades e formas de ensino proporcionam o desenvolvimento do indivíduo na sociedade.

A própria evolução dos processos de transmissão de conhecimento tem sido uma constante desde os primórdios da humanidade. Durante esse processo de evolução foram desenvolvidas técnicas, metodologias e ferramentas para aperfeiçoamento do processo. O desenvolvimento de uma nova modalidade de ensino denominada Educação a Distância (EAD), impulsionou transformações e novos desenvolvimentos tecnológicos de apoio aos processos de ensino-aprendizagem. As metodologias proporcionaram um aumento da abrangência de pequenos grupos para grandes contingentes populacionais. As barreiras do espaço de desenvolvimento do processo foram expandidas de curtas para grandes distâncias. A comunicação entre os participantes do processo (educador e educando) mudou de um tempo inflexível dependente para um tempo flexível independente. As ferramentas evoluíram do discurso às sofisticadas soluções computacionais com avançadas técnicas de realidade virtual e inteligência artificial.

Um importante componente no processo de transmissão de conhecimento é o conteúdo disponibilizado para proporcionar o conhecimento. Em modalidades de ensino presencial, as dificuldades do estudante na assimilação do conteúdo são ajustadas de forma imediata e interativa pela ação do docente condutor do processo. Na modalidade EAD, geralmente, o espaço e o tempo não são simultâneos entre o estudante e o professor. A demora na ação docente pode possibilitar prejuízos de entendimento ou desenvolvimento do processo.

Para minimizar os problemas de sincronia em ambientes EAD, ferramentas computacionais tem sido desenvolvidas para proporcionar formas de personalizar o conteúdo e proporcionar respostas para dificuldades ou ações do estudante.

O processo de personalização tem diferentes abordagens, desde a adoção de técnicas diferenciadas até técnicas mais refinadas que proporcionam a identificação do perfil do estudante e a relação de técnicas aplicáveis a cada ação desse perfil. As pesquisas desenvolvidas na área da Psicologia, proporcionam ferramentas e métodos que possibilitam formas de identificação de perfil e associação com ações pessoais [Giraffa, 1997; Horton, 2000; Vicari, 2005].

As diferentes técnicas de transmissão de conhecimentos aliadas a uma identificação do perfil do estudante podem possibilitar caminhos para proporcionar um conteúdo personalizado e reativo em ambientes EAD. Um conteúdo personalizado, mais próximo das preferências pessoais individuais, pode proporcionar uma melhor relação entre o estudante e o objeto de estudo. Essa melhor relação pode resultar em um maior acesso e democratização do ensino, proposto como desejável no desenvolvimento da modalidade EAD.

Este capítulo apresenta os conceitos contidos no processo de transmissão de conhecimentos, os métodos e as ferramentas computacionais para o processo de apresentação de conteúdos e as possibilidades de estabelecer uma identificação do estudante para proporcionar uma personalização da apresentação do conteúdo. Finalmente, são realizadas considerações finais deste capítulo

## **2.2 - Evolução Histórica do Ensino**

Desde os primórdios da humanidade, o conhecimento — sua aquisição e sua transmissão — tem sido o instrumento utilizado para promover e garantir a sobrevivência humana, a evolução pessoal e social e a soberania das nações [Dewey, 1900; Thorndyke, 1921; Thorndyke, 1931]. Como decorrência, os processos de aquisição e de transmissão do conhecimento têm sido objeto de muitos questionamentos e pesquisas, assim como têm induzido progressos tecnológicos ao longo da história evolutiva humana [Barlow, 1961; Gage, 1963; Schramm, 1964; Skinner, 1968; Lee, 2000; Horton, 2000; Rosenberg, 2001].

O modo de transmissão de conhecimentos mais antigo e ainda vigente é o denominado “presencial”. Esse modo é caracterizado pela presença simultânea do agente transmissor (professor, instrutor, orientador, etc.) e dos interessados pela informação no ambiente físico

em que ocorre esse processo. Deficiências e limitações estruturais do modelo têm sido apontadas: restrições temporais, altos custos de implementação e necessidade de espaço físico e mobiliário adequados [Horton, 2000].

Com a evolução dos serviços de correios na Europa, no começo do século passado, e, mais formalmente, com a expansão das tecnologias de rádio e de televisão, a partir de meados dos anos de 1930, outra forma de ensino se diferenciou, principalmente no contexto da educação norte-americana e européia [Jonassen, 2001; Vasileva, 2001; Phelan, 2002].

Frente às possibilidades decorrentes da expansão tecnológica e pressionados pela necessidade de levar instrução a contingentes populacionais cada vez maiores e mais diversos com arranjos de custo reduzido, educadores e psicólogos desenvolveram, a partir de 1940, alternativas instrucionais baseadas na idéia de que parcela significativa do processo ensino-aprendizagem poderia dispensar a presença física do agente transmissor junto aos aprendizes. O conjunto de técnicas, instrumentos, procedimentos e programas que, gradativamente, surgiram desse empreendimento constituem o campo de investigação e tecnologia educacional que veio a ser denominado “Educação a Distância” (EAD). Sem as limitações impostas pelo modelo presencial, a EAD tem permitido massiva disseminação de conhecimentos, favorecendo a popularização do ensino [Sherry, 1996; Jonassen, 2001; Vasileva, 2001; Phelan, 2002].

Desde a sua diferenciação no contexto da Educação, a EAD tem sido respaldada por experiências significativas realizadas em todo o mundo. Intuitivamente, pode ser afirmado que sempre que alguém lê um texto impresso recebido por correspondência, ouve rádio, assiste a um programa de televisão ou acessa a rede mundial de computadores (Internet), tal pessoa está, no mínimo, recebendo informação, por meio da qual, como consequência, poderá adquirir algum tipo de conhecimento e ter induzidas mudanças de atitudes e de comportamentos [Garrison, 1987; Perraton, 1988].

De modo mais específico, diferentes pesquisadores têm empregado intercambiavelmente as expressões “educação a distância” e “aprendizagem a distância” em relação a uma grande variedade de programas, provedores de instrução, audiências, metodologias e meios de comunicação. Existe algum consenso relativo que são as características definidoras da EAD: a) a separação do agente transmissor e do aprendiz no tempo e/ou no espaço [Perraton, 1988]; b) o controle voluntário do ritmo de aprendizagem pelo aprendiz ao invés de pelo agente transmissor a distância [Jonassen, 1992]; e c) a comunicação não-contígua entre o aprendiz e o agente transmissor, que é, então, mediada por sistemas multimídia, impressoras, ou alguma forma de tecnologia de transdução da

informação na sua forma eletrônica para uma forma processável pelos sentidos humanos [Garrison, 1987].

Por volta dos anos sessenta do século XX, os cientistas do EAD passaram a contar com a possibilidade da ampla utilização de computadores na Educação. Parcela considerável das aplicações educacionais que vieram a utilizar essa tecnologia foi classificada como “Instrução Assistida por Computador” (IAC; expressão traduzida do Inglês “Computer-Assisted Instruction” (CAI); [Park, 1987]). Todavia, os sistemas CAIs não consideram o perfil do estudante e por isso o que se tem veementemente almejado é a construção de aplicações inteligentes, tais como as propostas classificadas como “Instrução Inteligente Assistida por Computador” (expressão traduzida do Inglês “Intelligent Computed Assisted Instruction” (ICAI)). Os sistemas ICAIs possuem características adaptativas e utilizam técnicas de Inteligência Artificial (IA).

No final dos anos de 1990, a Internet abriu espaços na Educação, encurtando distâncias para cursos e programas em EAD [Vasileva, 2001]. Tal facilidade veio como consequência da associação dessa revolucionária tecnologia educacional à Informática e às telecomunicações, o que possibilitou agilidade e velocidade de comunicação interativa nunca antes alcançada pelo homem.

Sobre o fator social da EAD, Toschi [2004] afirma que o problema da distância física entre o professor e os estudantes pode ser um fator possibilitador de tratamento igualitário entre os participantes do curso e que embora sem eliminar as diferenças, a distância pode diminuir a discriminação. Por esse prisma verifica-se um perfil de proposta de democratização inclusiva na modalidade não presencial.

A grande expansão promovida pela EAD demandou o desenvolvimento de tecnologias promotoras de um ambiente amigável mais próximo do perfil do estudante de tal forma a não se tornar uma tecnologia de massa na qual toda a responsabilidade da construção do conhecimento é transferida unicamente para o estudante. A implementação de um ambiente educacional em EAD, de forma semelhante ao ambiente presencial, precisa de uma atenção ao estudante. Esta atenção pode ter início na identificação do estudante, estabelecendo alguma forma de personalização do ambiente de estudo.

## 2.3 – Padrões para a Personalização

Para estabelecer a importância de padrões para a personalização é necessário entender que existem diferenças entre os estudantes. Cabe entender que as diferenças existem e que é necessário entendimento da situação para conduzir a soluções ou hipóteses que permitam um melhor equilíbrio nas relações entre essas diferenças.

Quando um indivíduo está em uma situação de escolher algo entre várias opções disponíveis, a escolha mais provável é aquela que mais se aproxima de suas preferências individuais. Quanto mais próximo o objeto estiver da preferência individual, mais personalizado será o objeto. Quando alguém quer agradar outra pessoa, sabe que alcançará o objetivo se souber das preferências pessoais dessa pessoa.

Em processos de transmissão de conhecimento, a personalização é um fator importante no processo. Para transmitir algo, é importante saber quem é o estudante (identificar) para que se possa apresentar o conhecimento o mais próximo possível dos padrões desse estudante [Libâneo, 1992]. Conhecer o estudante (classificar) pode consistir de vários aspectos tais como o nível de conhecimento acumulado do estudante em relação ao conhecimento a ser apresentado, suas características e preferências, suas habilidades pessoais, etc. Quanto mais personalizada for a apresentação do conhecimento, é mais provável que ocorra melhor aproveitamento dos conteúdos a serem transmitidos.

A tarefa de identificar e classificar o comportamento das pessoas, inicialmente, pode parecer uma tarefa quase impossível. Cada pessoa ou indivíduo tem uma forma de reagir diante das diferentes situações. Entretanto, se forem estabelecidos determinados critérios, é possível verificar a possibilidade de generalização de características comuns. A generalização não pode ser tão ampla que agrupe todos os indivíduos em uma única classe e nem tão específica que descreva cada indivíduo.

A contextualização da dificuldade no processo de classificação de pessoas pode ser visualizada em um exemplo de compreensão mais fácil. A compreensão dos aspectos considerados na possibilidade de estabelecer padrões pessoais, pode ser iniciada pelo estudo da forma física das pessoas, por ser de natureza concreta e de visualização mais simples.

As características físicas são parte do conjunto da herança genética legada a cada indivíduo por seus ancestrais. Dessas características, algumas são básicas e não podem ser transformadas, como por exemplo, o tipo sanguíneo. Outras, entretanto, podem sofrer modificação ao longo do desenvolvimento, como a massa muscular, tamanho dos ossos e cabelos, etc. Apesar de todas essas diferenças, as pessoas podem ser classificadas em

determinados grupos, conforme o objeto de estudo. Assim, é possível classificar grupos por etnias, porte físico, estatura, tipo de cabelo, cor dos olhos ou qualquer outra característica ou grupo de características que interesse a algum estudo ou classificação.

De forma análoga à classificação física das pessoas, é possível estabelecer critérios para a classificação de padrões de comportamento. Ao ser considerado todos os aspectos de um indivíduo, é possível notar uma grande diversidade de comportamentos e uma alta complexidade na definição do perfil único de cada indivíduo. Entretanto, a limitação dos aspectos a serem considerados para um determinado objetivo, possibilita uma generalização e classificação de vários indivíduos em um determinado grupo. Por exemplo, se for considerado apenas o fato do indivíduo gostar ou não de uma cor, a diversidade de indivíduos pode, por exemplo, ser simplificada em duas classes apenas: a classe dos que gostam daquela cor e a classe dos que não gostam daquela cor.

Do mesmo modo da estrutura física, a forma do ser humano interagir com o mundo é, basicamente, semelhante para todos os seres humanos: percepção/ação ou estímulo/resposta. Entretanto, pessoas diferentes apresentam diferentes respostas para o mesmo estímulo. Essa diferença é um somatório das características herdadas, as experiências vividas e moldadas pelo meio.

Na área da Psicologia, o estudo das relações entre as características se caracteriza como um objeto de pesquisas, nos quais muitas abordagens são utilizadas na tentativa de explicar as diferenças entre as pessoas. A Psicologia, em uma perspectiva behaviorista, procura classificar padrões de comportamento em perfis psicológicos, no sentido de compreender as diferentes formas de ser e agir das pessoas. A partir desse estudo é possível generalizar a predição do comportamento ou as ações de cada tipo. Assim, conforme o perfil, é possível estabelecer as suas tendências e aptidões e quais as prováveis formas de ação/reação [Schultz, 2008].

Uma tarefa fundamental da teoria da personalidade consiste em descrever as estruturas do sistema com que está lidando. Faz-se necessária uma linguagem descritiva que permita a criação do tipo das pessoas em geral e de uma determinada pessoa em particular [Lazarus, 1984]. Assim, para definir perfis psicológicos ou personalidade, é necessário, antes, criar os parâmetros necessários pelo qual será afirmado sobre um grupo de pessoas ou uma pessoa ser isto ou aquilo.

Para criar os parâmetros, inicialmente, pode ser estabelecido que existe dois tipos de pessoas, em uma relação binária: pessoas que gostam de aves e pessoas que gostam de peixes, pessoas que moram na cidade e pessoas que moram no campo e assim por diante. Entretanto,



se for estabelecido que algumas pessoas que moram no campo também gostam de aves ou de peixes e a mesma coisa para as que moram na cidade, isto levará a um grupo de quatro tipos de pessoas. Desta forma, se continuar a combinar outros pares de características, será novamente duplicado os tipos e, conseqüentemente, é obtido um número maior de tipos. Entretanto, se continuar a realizar essas subdivisões binárias, pode-se chegar a um número tão grande de tipos que o estudo ou a classificação se tornará inviável ou, no mínimo, pouco prático. O problema foi abordado por Carl G. Jung no clássico “Psychological Types” o qual fez uma proposição de classificação de tipos [Jung, 1976].

A abordagem da descrição da personalidade, a partir do tipo, utiliza-se do esquema da classificação ou da ordenação, que é amplo e unificador. Nesse sentido, uma pessoa é classificada como pertencente a um tipo, a partir do padrão de traços exibidos. Se partilhar um padrão de traços com um grupo grande, pertencerá, juntamente com os membros desse grupo, a um determinado tipo, simplificando imensamente a descrição, já que cada traço comum não precisará ser arrolado para cada indivíduo [Lazarus, 1984].

Para Jung [1971], o tipo psicológico é uma explanação da personalidade humana. Ele observou que o comportamento humano não é algo aleatório, com as ações sendo resultado do acaso. Ao invés disso, o comportamento segue padrões desenvolvidos a partir da estrutura da mente humana. Desta forma, Jung desenvolveu uma teoria sobre os tipos psicológicos baseada em quatro funções (sentimento, pensamento, intuição e sensação) e duas atitudes (extroversão e introversão).

Na teoria de Jung, verifica-se que quando a mente humana está em atividade, ela está realizando uma das duas tarefas: obtendo informações (percebendo) ou organizando e priorizando informações para decidir (julgando). Jung identificou duas formas fundamentais pelas quais as pessoas percebem e julgam as coisas e os fatos. Elas percebem por meio dos sentidos físicos ou por meio da intuição. Para julgar, utilizam o pensamento/raciocínio ou o sentimento. As preferências inatas, na forma de perceber e julgar, influenciam essencialmente o tipo de atenção prestada e o processo pelo qual frequentemente utilizam para tomar decisões. Jung, também identificou duas atitudes opostas que os indivíduos assumem perante o mundo, são elas a extroversão e a introversão. Novamente, ele acreditou que as pessoas nascem com uma preferência para uma ou outra atitude e essa preferência molda a forma pela qual os indivíduos interagem com o mundo [Jung, 1971; Daniels, 1992; Jung, 2008]. O esquema representado na Figura 2.1 ilustra a teoria de Jung.

Os tipos psicológicos são desenvolvidos a medida que as pessoas direcionam sua energia para cada um dos pares opostos (sensação ou intuição, pensamento ou sentimento,

extroversão ou introversão). Devido ao fato de cada um dos elementos do par ser preferido e utilizado mais frequentemente, a teoria dos tipos psicológicos prediz que as preferências se tornarão cada vez mais seguras e melhor desenvolvidas. O uso habitual dessas preferências levam às diferenças entre as pessoas e à padrões previsíveis de comportamento [Schultz, 2008; Jung, 2008 ].

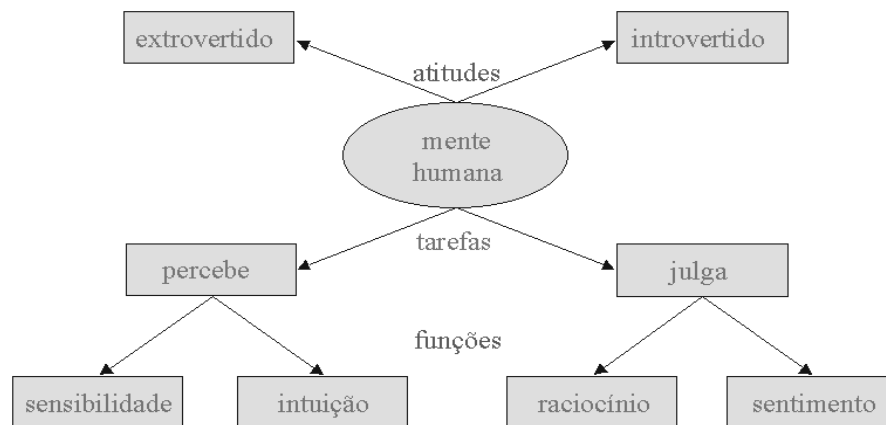


Figura 2.1: Padrões de comportamento da mente humana.

Os testes psicológicos fazem parte do campo de investigação da Psicologia que associam itens cotidianos do ser humano a padrões de dimensões que expressam uma característica comportamental. A região de abrangência de uma dimensão é definida por um conjunto de itens em um teste psicológico. Normalmente, as dimensões são representadas por dicotomias. Dicotomias são duas características de uma determinada dimensão posicionadas em extremidades ou pólos. O conjunto de resposta aos itens do teste psicológico identifica a tendência de cada característica na dimensão considerada [Keirsey, 1984; Myers, 1985; Keirsey 1998; Hogan, 2006; Gregory, 2007].

A Figura 2.2 apresenta um exemplo da dimensão “Julgamento”. No exemplo, a dicotomia é formada pelas características “sentimento” representada pelo valor 1 e “razão” representada pelo valor -1. Nessa figura pode ser observado que a dimensão “Julgamento” tende para o valor 1, ou seja, a característica “Sentimento”.




Figura 2.2: Exemplo de dicotomia.

A partir das definições de Carl Jung, as psicólogas Isabel Briggs Myers e Katharine Briggs acrescentaram algumas características e uma nova abordagem na forma de definir a classificação dos tipos psicológicos. Para tal, elas elaboraram uma classificação na qual são consideradas quatro preferências básicas das pessoas (I/E (introversão/extroversão), N/S (intuição/sensibilidade), T/F (raciocínio/sentimento) e P/J (perceber/julgar)). Para descobrir cada uma das preferências, é necessário considerar quatro questões. A partir dessas questões, pode-se definir certas características que farão a composição do tipo psicológico da pessoa. A resposta para cada uma das questões leva a definição do tipo dentro do escopo de cada dicotomia. A abordagem da classificação Myers-Briggs consiste em descobrir, conforme o modelo linear da Figura 2.3, para qual lado é a tendência ou a preferência da pessoa. A partir desse ponto, é obtida a definição de uma letra para cada dicotomia. O conjunto das letras de cada dicotomia resultam na classificação de tipos psicológicos do teste de Myers-Briggs [Myers & Briggs, 1985; Myers & Briggs, 1997].




Figura 2.3: Modelo linear Myers-Briggs.

A maioria dos testes de personalidade são realizados por meio de auto-relatórios cuja resposta dos itens variam conforme a maturidade, o vocabulário, a experiência de vida, a cultura e assim por diante. A utilidade do modelo é determinada pela precisão tanto do modelo como do instrumento. A utilização do instrumento consiste em um conjunto de fundamentos de testes psicológicos entre estes, o conhecimento do instrumento utilizado. Na pesquisa do tipo real individual, a instrumentação é apenas uma parte do conjunto de ferramentas. A condução do trabalho por um profissional capacitado na utilização dessa instrumentação é outra importante parte que garante o reconhecimento e a confiabilidade da descrição obtida. [Cronbach, 1999; Hogan, 2006; Gregory, 2007]

Conforme discutido nesta seção, a personalização está relacionada com o perfil de cada indivíduo. Este perfil pode ser definido por meio de testes psicológicos que estabelecem um padrão, normalmente relacionado com as preferências e as ações inerentes ao perfil. Assim, em processos de personalização, pode ser relevante considerar meios de definição do perfil e sua relação com os objetivos almejados.

Em processos de transmissão de conhecimento, a personalização pode ser um elemento muito favorável ao desenvolvimento do trabalho. Entretanto, com grandes quantidades de estudantes a personalização pode ser de difícil estabelecimento no que se refere a quais métodos de ensino-aprendizagem são mais adequados a cada perfil. Um caminho para estabelecer essa personalização pode ser obtido por uma personalização conhecida e considerada adequada ao perfil do estudante e utilizar em outros estudantes com perfil semelhante. Esse caminho é semelhante ao conceito de zona de desenvolvimento proximal, apresentado por [Vygotsky, 1988].

### *2.3.1 – Zona proximal de desenvolvimento*

Lev Semenovitch Vygotsky nasceu em 1896 em Orsha, pequena cidade perto de Minsk, a capital da Bielo-Rússia. Seus pais eram de uma família judaica culta e com boas condições econômicas, o que permitiu a Vygotsky uma formação sólida desde criança. Após sua formação em direito, destacou-se na área da Psicologia. Vygotsky faleceu em 1934, tendo produzido mais de 200 trabalhos científicos. Sua obra ainda está em pleno processo de descoberta e debate em vários pontos do mundo, incluindo o Brasil.

Vygotsky foi pioneiro na noção de que o desenvolvimento intelectual ocorre em função das interações sociais e condições de vida. Ele foi o primeiro psicólogo moderno a sugerir os mecanismos pelos quais a cultura torna-se parte da natureza de cada pessoa ao insistir que as funções psicológicas são um produto de atividade cerebral. Ele enfatizava o processo histórico-social e o papel da linguagem no desenvolvimento do indivíduo. Vygotsky acreditava que as características individuais e até mesmo suas atitudes individuais estão impregnadas de trocas com o coletivo. Suas maiores contribuições estão nas reflexões sobre o desenvolvimento infantil e sua relação com a aprendizagem em meio social, e também o desenvolvimento do pensamento e da linguagem. [Vygotsky, 1996; Vygotsky, 1998].

Vygotsky descreve dois níveis de desenvolvimento, denominados desenvolvimento real e desenvolvimento potencial. O desenvolvimento real é aquele que já foi consolidado pelo indivíduo, de forma a torná-lo capaz de resolver situações utilizando seu conhecimento de forma autônoma. O nível de desenvolvimento real é dinâmico, aumenta a cada novo aprendizado. O desenvolvimento potencial é determinado pelas habilidades que o indivíduo já construiu, porém ainda não está consolidado. Isto significa que o processo de aprendizagem que gerou o desenvolvimento real, gerou também habilidades que se encontram em um nível menos elaborado que o já consolidado. Desta forma, o desenvolvimento potencial é aquele que o sujeito ainda não desenvolveu plenamente mas poderá desenvolvê-lo [Vygotsky, 1988].

Em linhas gerais, o conceito Zona de Desenvolvimento Proximal (ZDP), define a distância entre o nível de desenvolvimento real, determinado pela capacidade de resolver um problema sem ajuda, e o nível de desenvolvimento potencial, determinado por meio de resolução de um problema sob a orientação de um adulto ou em colaboração com outro companheiro. Quer dizer, um conjunto de informações que a pessoa tem a potencialidade de aprender mas ainda não completou o processo de aprendizagem; são os conhecimentos fora de seu alcance atual, mas potencialmente atingíveis. De forma geral, verifica-se que o conhecimento não pode ser construído sem uma estrutura de aprendizagem prévia [Vygotsky, 1988]. A Figura 2.4 ilustra o conceito de zona proximal de desenvolvimento.




Figura 2.4: Zona proximal de desenvolvimento.

Para os processos de ensino com reflexo e aprendizagem, o conceito de ZPD é, na abordagem deste trabalho, importante em vários aspectos, tais como: a) para aprender um determinado conhecimento, o indivíduo precisa ter desenvolvido as habilidades e fundamentos para conectar e assimilar o novo conhecimento. O que indica que, além de

preparar o conteúdo a ser dialogado, é necessário desenvolver habilidades e estrutura para sedimentar o conhecimento. Além do que, é importante estabelecer a organização do conteúdo atual para que ele possa desenvolver as habilidades necessárias para possibilitar atingir outros níveis de conhecimento; b) a colaboração ou a mediação é importante na evolução do desenvolvimento real atual para um próximo nível de desenvolvimento potencial. O reaproveitamento de outras experiências de aprendizagem, de quem já passou pelo processo e outras ações correlatas, podem se mostrar como um elemento facilitador no desenvolvimento do estudante. A aplicabilidade da ZPD transcende a simples suposição de ajuda, ela possibilita uma gama de possibilidades, métodos, tecnologias e procedimentos que estão presentes na aprendizagem e que mediam a aprendizagem na ZPD [Vygotsky, 1988; Kozulin, 2003; Chaiklin, 2003; Obukhova, 2009].

## **2.4 – Componentes do Processo Ensino-aprendizagem**

O processo de ensino-aprendizagem pode ser definido como uma sequência de atividades entre professores e estudantes, tendo em vista a assimilação de conhecimentos. Nessa aproximação pode ser observada a existência de três elementos: o professor, o estudante e a matéria, como conteúdos [Libâneo, 1994].

O estudante é a parte interagente para qual é direcionado todo o esforço do processo, visando o desenvolvimento de suas habilidades. Assman [Assman, 2007] enfatiza que o aspecto fundamental da educação reside nas vivências personalizadas de aprendizagem. Assim, como elemento essencial do processo, o estudante precisa de atenção quanto a sua individualidade no desenvolvimento do processo de ensino e aprendizagem.

O professor é um importante agente desse processo, responsável pela direção e organização dos meios que proporcionem, ao estudante, assimilar os conhecimentos. O professor planeja, dirige e orienta o processo de ensino, tendo em vista estimular e suscitar a atividade própria dos estudantes para a aprendizagem. A função docente pode ser definida como sendo a atividade de realizar a tarefa de mediação na relação cognitiva entre o estudante e as matérias de estudo [Libâneo, 1994].

Sobre a organização das matérias de estudo, para o processo de mediação, deve ser considerada a importância da organização da linguagem com diferenciação de níveis. Devido as tendências opostas implícitas na natureza dos processos de percepção visual e da linguagem, o papel desta última na percepção é surpreendente. Os elementos independentes

em um campo visual são percebidos simultaneamente enquanto a linguagem requer um processamento sequencial. Na resolução de situações problemas, percepção e linguagem estão ligadas e esta última, tem um papel importante para o resultado [Vigostsky, 1998].

Conforme [Dewey, 1979], a sociedade subsiste, tanto quanto a vida biológica, por um processo de transmissão de conhecimento, ressaltando que essa transmissão ocorre por meio da comunicação, tradicionalmente, dos mais velhos para os mais novos. A simples transmissão, porém, não é suficiente para assegurar a subsistência, é, pois, necessário uma forma de comunicação que possibilite tal processo. Entretanto, a comunicação só será viável e efetiva se existir um transmissor que saiba conduzir o objetivo a ser alcançado no sentido e universo do receptor .

No processo de transmissão de conhecimentos, bons resultados são obtidos quando existem elementos que procuram gerar experiências de aprendizagem, criatividade para construir conhecimentos e habilidade para saber acessar fontes de informação [Assman, 2007].

A organização do processo de transmissão do conhecimento e as ações decorrentes, indicam a importância da atuação do professor no desenvolvimento do planejamento instrucional para a obtenção de bons resultados.

O planejamento instrucional é o processo para estabelecer uma sequência de ações que permita consistência, coerência e continuidade no processo ensino-aprendizagem, que ocorrem, basicamente, em dois níveis: o planejamento do conteúdo e o planejamento da apresentação. Em síntese, no planejamento do conteúdo é estabelecido "o que o estudante deve aprender". No planejamento da apresentação ocorre a definição de "como o estudante deve aprender" o conhecimento contido no conteúdo [Vassileva, 1995; Vasileva, 2001; Pinto, 2004].

#### *2.4.1 – Organização de conteúdos*

A sociedade subsiste, tanto quanto a vida biológica, por um processo de transmissão e esta transmissão ocorre por meio da comunicação, historicamente, dos mais velhos para os mais novos. Pode-se entender, como citado, que a simples transmissão não é suficiente para assegurar a subsistência. É necessário, pois, uma forma efetiva de comunicação. Entretanto, a comunicação só será viável e efetiva se existir um transmissor que saiba conduzir o objetivo a

ser alcançado no sentido e universo do receptor. Nessa comunicação, deve existir uma mentalidade similar como a necessidade de um modo comum de compreensão. Assim, pode ser estabelecido na comunicação um elemento importante para propiciar a educação e esta, dependendo das condições, pode ser efetivada a distância [Dewey, 1979]. Com a possibilidade de que essa comunicação possa ocorrer independente da distância, é possível propiciar meios para minimizar algumas diferenças, como a própria distância.

O sucesso de um processo de transmissão de conhecimento deve considerar a organização e a apresentação do conteúdo. O conteúdo é composto por um conjunto organizado de conceitos relacionados ao conhecimento a ser transmitido. Cada conceito expressa uma idéia fundamental para a formação do conhecimento proposto pelo conteúdo. A organização e distribuição do conteúdo consiste na estruturação de uma sequência dos conceitos. Esta sequência, por sua vez, é um conjunto de atividades pedagógicas ligadas entre si, planejadas para ensinar um conteúdo, etapa por etapa. A organização das atividades em sequência tem o objetivo de construir os elementos necessários para a compreensão do conhecimento a ser transmitido. Um conteúdo didático pode ser entendido como um elemento estruturado de tal forma que o conjunto constituído pela organização das idéias contidas em cada conceito formam o conhecimento a ser transmitido. [Dahlberg, 1978; Patten, 1986; Libâneo, 1994; Dolz, 2004].

#### *2.4.2 – Apresentação do conteúdo didático*

Após a definição do conteúdo, a próxima etapa é estabelecer os procedimentos para a apresentação e o desenvolvimento do conteúdo. Ou seja, estabelecer a forma como o estudante deverá aprender o conteúdo transmitido para formar o conhecimento. A apresentação do conteúdo pode ser realizada por meio de textos, filmes, livros, aulas presenciais ou por vídeoconferência, computadores, etc.

A organização da apresentação do conteúdo não deve ser entendida como sendo mecânica, apenas como a seleção e a organização lógica dos conteúdos para transmiti-los. Os próprios conteúdos devem incluir elementos da vivência prática dos estudantes para torná-los mais significativos. Face aos diferentes entendimentos dos estudantes, é importante criar estratégias diferentes para a apresentação dos conteúdos [Libâneo, 1994]. No caso de ambientes não presenciais, nos quais a pluralidade dos estudantes é desconhecida do



apresentador, é relevante a inserção de um instrumento que organize a apresentação para cada estudante.

Geralmente, para a elaboração, a escolha e a aplicação de programas e procedimentos de ensino para classes numerosas, os professores desenvolvem um conteúdo em formato único e geral para todos os estudantes. Neste formato é pressuposto um estudante com determinada capacidade e habilidade e o conteúdo é apresentado da mesma forma para todos os estudantes. O processo de ensino-aprendizagem acontece com a interação entre o professor, o estudante e o conteúdo. Após a exposição, o estudante apresenta uma determinada reação ao conteúdo que foi exposto, é a reatividade. Esta reatividade ao conteúdo indica algum grau de assimilação do que foi apresentado. A percepção da reação do estudante propicia, ao professor, interagir no processo, estabelecendo a ação necessária na sequência do estudo. Esta ação do professor interagindo com o estudante e o conteúdo, denominada de mediação, propicia a construção do conhecimento pelos estudantes [Libâneo, 1994; De Vaney, 2001; Jonassen, 2001].

Um estudo comparativo entre as percepções de estudantes no ensino presencial e não presencial indicou a maior eficiência e riqueza na apresentação do conteúdo na modalidade presencial. A menor eficiência e riqueza de apresentação foi apontada como sendo, vídeos e os conteúdos textuais [Zhang, 2003 ]. Os resultados apresentados pelo estudo confirmam as impressões do senso comum (modalidade presencial é melhor) sobre os meios educacionais.

Considerando um mesmo conteúdo desenvolvido nas duas modalidades, têm-se fatores decisivos que levam aos resultados apresentados. Na modalidade presencial, a apresentação é dinâmica, com o professor interagindo em todos os momentos, corrigindo e ajustando as possíveis dúvidas de forma a enriquecer a exposição. O professor é o mediador experiente para operar a zona de desenvolvimento proximal (ZPD) do estudante de forma dinâmica. A apresentação não presencial de um conteúdo, normalmente é estática. O estudante deve impor sua dinâmica individual. Esta dinâmica depende muito da experiência e da disciplina de organização do estudante, no sentido de saber selecionar e relacionar as habilidades e os conhecimentos necessários. No estudo individual, a operação da ZPD pode ser estruturada implicitamente de forma estática durante a organização do conteúdo. O estudante passa a ser o responsável pela dinamização que possibilitará a própria internalização do conhecimento.

Para a apresentação do conteúdo, os conceitos são organizados em uma sequência lógica para conduzir ao conhecimento [Patten, 1986; Libâneo, 1994]. A organização dessa sequência pode ser realizada de diferentes modos, desde a organização clássica até as organizações customizadas. A apresentação da sequência normalmente é precedida por uma

introdução seguida de um teste inicial e, ao final, apresenta-se um resumo sobre os conceitos abordados e realiza-se o teste final [Horton, 2000].

Conforme ilustrado na Figura 2.5, no tutorial clássico [Horton, 2000] o conteúdo é apresentado progressivamente em uma sequência dos níveis básico, intermediário e avançado.

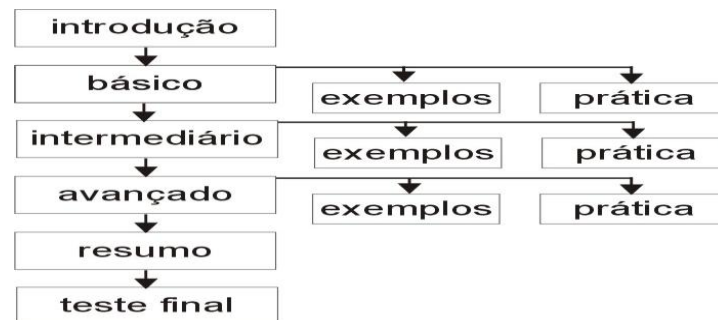


Figura 2.5: Tutorial clássico.

No tutorial orientado por atividades [Horton, 2000], ilustrado na Figura 2.6, uma preparação com conhecimentos ou motivações adicionais precede a realização da própria atividade.



Figura 2.6: Tutorial orientado por atividades.

No tutorial customizado pelo aprendiz [Horton, 2000], apresentado na Figura 2.7, entre a introdução e o resumo existem ciclos de páginas de opções (navegação) e páginas de conteúdo. A página de opções apresenta uma lista de caminhos para a escolha pelo aprendiz ou um teste no sentido de definir o próximo passo.




Figura 2.7: Tutorial customizado.

No tutorial de avanço por conhecimento [Horton, 2000], ilustrado na Figura 2.8, o estudante pode omitir conteúdos já dominados. Para definir o início do estudo na sequência do conteúdo, o estudante é submetido a testes com dificuldade progressiva. O resultado de cada teste define se o estudante deve seguir para o próximo teste ou iniciar o estudo no ponto definido pelo teste.




Figura 2.8: Tutorial de avanço por conhecimento.

No tutorial exploratório [Horton, 2000], ilustrado na Figura 2.9, existe uma página inicial de exploração com links de acesso a documentos, bancos de dados ou outras fontes de informação. Nesse modelo de tutorial, o estudante tem todo o conteúdo disponível e define o quê, quando e em que ordem estudar. O professor pode ocultar alguns elementos do conteúdo e manter o controle da disponibilização dos mesmos, estabelecendo uma ordem de acesso.

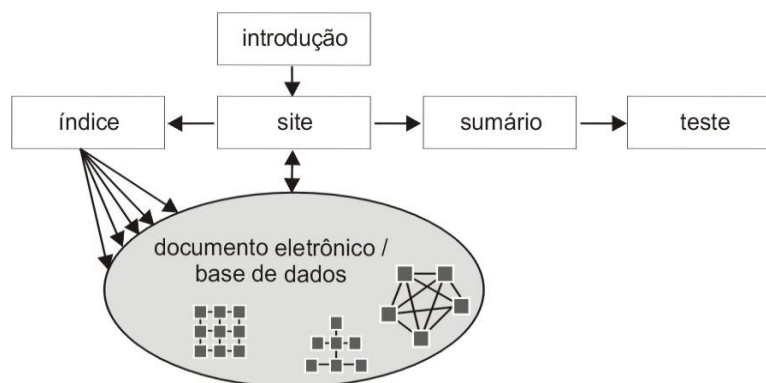


Figura 2.9: Tutorial exploratório.

No tutorial gerador de lições [Horton, 2000], apresentado na Figura 2.10, o resultado do teste inicial, realizado pelo estudante, é utilizado para definir tanto as partes do conteúdo que serão apresentadas como, também, definir a sequência de apresentação. Como pode ser observado, esse modelo de tutorial possibilita diferentes combinações dos tópicos para a apresentação do conteúdo. Cada estudante pode ter uma apresentação diferente do conteúdo, caracterizando uma apresentação personalizada.

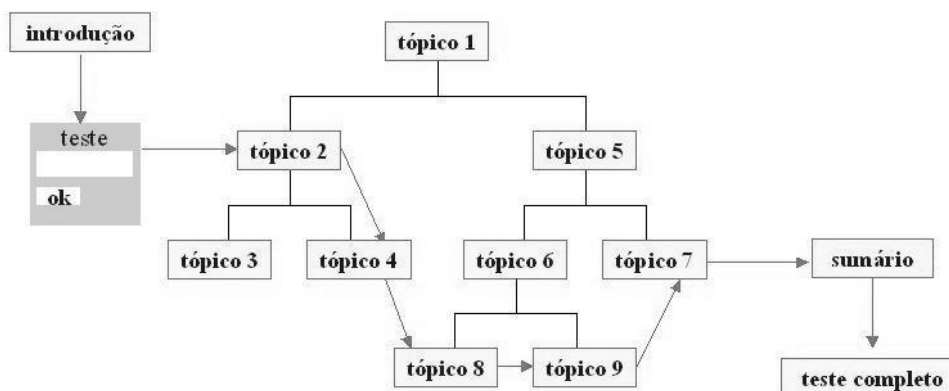


Figura 2.10: Tutorial gerador de lições.

A modalidade de ensino a distância, apesar de oferecer boas perspectivas tem suas peculiaridades que, não sendo observadas, podem se tornar fator de exclusão pela acentuação das diferenças. Tal situação pode ser observada em estruturas nas quais a intenção de propiciar um conhecimento fundamentada na simples transmissão de conhecimento por meio de mecanismos que não consideram as diferenças individuais. Como exemplo, pode ser observada a situação em que um conteúdo é apresentado e tratado da mesma forma para qualquer estudante, sem considerar sua individualidade ou meio de inserção.

Na modalidade de ensino presencial a apresentação pode ser diferenciada para cada estudante pela interação imediata de um mediador ou condutor do processo. Em modalidades de ensino não presencial, a diferença é realizada pelo próprio estudante, conforme sua forma de interpretação e condução do conteúdo. A separação entre o tempo e o espaço do professor pode consistir em um fator complicador. Na realidade, os meios de comunicação convencionais podem se mostrar pouco eficazes para tal. É necessário o emprego de uma tecnologia que possa ter uma espécie de inteligência, para auxiliar o estudante no processo, bem como para auxiliar o professor na tarefa de selecionar as ações necessárias diante das diversas situações, durante o estudo individual do estudante.

## 2.5 - Computadores na Educação

Existem várias possibilidades e formas de utilizar computadores para auxiliar o estudante em seu processo de aprendizagem. Esse auxílio pode ocorrer, por exemplo, a partir do uso de softwares educacionais. Tais softwares, em sua maioria, são programas desenvolvidos com o intuito de colaborar na tarefa de tutoria, embora quaisquer outros

softwares possam ser adotados para esse fim, desde que apresente uma metodologia adequada para tal [Giraffa, 1997; Giraffa, 1999].

Os softwares educacionais podem ser classificados de diversas formas. Taylor [1980] os divide em: tutor, tutelado e ferramenta. Lucena [1994] considera que devido à incorporação de novas tecnologias e ao avanço de recursos de hardware e de software, essa classificação pode ser ampliada para tutor; tutelado; ferramenta; exercício e prática; simulação e jogos educativos.

O tutor é um tipo de software em que o computador assume o papel de um “professor”. Desta forma, o software possui o poder de apresentar os conceitos ao estudante oferecendo níveis diferenciados, de acordo com as avaliações das respostas obtidas do educando. Segundo [Giraffa, 1995], nesta modalidade encontram-se alguns sistemas CAIs, nos quais o modelo de ensino-aprendizagem é baseado unicamente em instrução programada, com apoio na teoria comportamentalista de Skinner [Park, 1987].

A metodologia escolhida pode ser implementada em um dos dois modelos de sistemas educacionais computadorizados, o modelo “Instrução Assistida por Computador” (IAC) ou o modelo “Instrução Inteligente Assistida por Computador” (ICAI).

O modelo IAC surgiu baseado no paradigma da Instrução Programada (IP) [Skinner, 1968]. A IP é definida, dentre outros aspectos: a) pela partição criteriosa, em quadros e blocos, do conteúdo a ser ensinado, considerados os fatores tais como a natureza do conteúdo, o repertório de conhecimentos do aprendiz sobre os conteúdos mais ou menos relacionados ao que está programado para ser ensinado, o estágio de desenvolvimento linguístico do aprendiz, o nível de escolarização, etc.; b) o arranjo da apresentação dos quadros considerado o nível de dificuldade de cada um, de forma que a sequência de apresentações é organizada dos quadros mais fáceis para os mais difíceis; c) a possibilidade de progressão auto-controlada no sentido dos quadros iniciais para os finais de um bloco, ou seja, o aprendiz pode determinar o ritmo em que quer aprender, e d) o que ocorre como consequência da resposta do aprendiz e funciona como evento que indica a ele, à medida que caminha pelos quadros, a correção ou a incorreção das suas respostas (feedback) [Markle, 1969; Holland, 1961; Malpass, 1970; Rosenberg, 2001] são bons exemplos de aplicação prática do paradigma ao ensino do conteúdo da Psicologia Geral, da Análise do Comportamento e do Espanhol.

Alguns críticos da IP a interpretam erroneamente, como observa alguns autores que seguem essa linha, afirmando que ela é um método educacional “centrado no agente transmissor”, visto que: a) pré-determina o modo como o conteúdo será fracionado e apresentado, e, portanto, b) a compreensão do aprendiz terminará por ser a de quem

programou o ensino, não existindo possibilidade de compreensão criativa — aspecto esse entendido como decorrente de ser o paradigma uma extensão aplicada dos princípios do condicionamento operante [Catania, 1998; Pierce, 1999], esses entendidos como elementos básicos de uma “teoria comportamentalista skinneriana”, que, de fato, inexiste no sentido alegado por tais críticos [Skinner, 1950]. Tais suposições são equivocadas, conforme interpretação do grupo favorável ao trabalho de Skinner, pois não se aplicam ao paradigma da IP e nem ao pensamento skinneriano, mas, sim, ao uso inadequado da primeira e ao desconhecimento do segundo. Deve-se ter clareza que não existe paradigma de ensino que prescindia de algum tipo de partição do conteúdo e que não cause efeitos sobre o aprendiz. Esses são problemas inerentes à relação ensino-aprendizagem, cuja solução científica demanda investigação conceitual e empírica competentes, sob pena de ser criada uma situação na qual se afirma a existência positiva do aprender não tendo ocorrido o ensinar, quaisquer que sejam os critérios de avaliação adotados [Oakeshott, 1967].

Instrução Assistida por Computador ou Sistemas CAI (do inglês, Computer Aided Instruction) tiveram sua origem na área educacional, influenciada pela Teoria Comportamentalista de Skinner [Park, 1987], com a finalidade de auxiliar o professor no processo de ensino. Sua abordagem é centrada no professor, na qual o estudante deve inicialmente receber explicações expositivas para depois exercitá-las no computador.

No entendimento deste trabalho, um dos principais problemas dos sistemas CAI é que eles não levam em consideração as diferenças existentes entre os estudantes. A exposição do conteúdo é idêntica para todos os educandos, independente do estudante ter um desenvolvimento melhor ou inferior ao de outro. Nesses modelos, o conteúdo é previamente elaborado e consiste basicamente de um “virador de páginas”, ou seja, uma extensão dos antigos livros de papel, agora digitalizados.

A partir da década de setenta do século XX, passou-se a utilizar técnicas de Inteligência Artificial (IA) nos sistemas CAIs, na busca de criar programas com características adaptativas. Com a utilização de técnicas de IA, os sistemas CAIs passaram a ser denominados ICAIs (do inglês, Intelligent Computer Aided Instruction). Os sistemas ICAIs passaram a ser capazes de analisar os padrões de erro, o estilo e a capacidade de aprendizagem do estudante. Desta forma, possibilitaram oferecer instrução especial sobre o conceito em que o estudante está apresentando dificuldade [Saviani, 1991].

A classe de softwares ICAIs ou Sistemas Tutores Inteligentes (STIs) tiveram suas origens na área da Ciência da Computação e possuem sua base teórica na Psicologia Cognitivista. Sua estrutura básica é subdividida em módulos, cujas sequências dependem da

resposta do estudante. A estruturação do conhecimento é baseada na heurística e a modelagem do estudante tenta avaliar todas as respostas durante a interação com o sistema [Carvalho, 2002].

As diferenças fundamentais entre os ICAIs e os CAIs tradicionais estão na forma com que o seus projetos são concebidos [Giraffa, 1995; Giraffa, 1999]. Em sistemas CAI os estudantes são induzidos a uma resposta correta, baseada em estímulos previamente planejados. Os ICAIs buscam extrair capacidades cognitivas do estudante e utilizar esses resultados para a tomada de decisão.

Os sistemas CAIs são considerados restritos devido à sua incapacidade de manter um diálogo aberto com o estudante. Diferentemente, nos sistemas ICAIs são aplicadas técnicas de IA de forma a proporcionar instruções adaptadas, sejam elas no sentido ou forma do contexto.

Uma das dificuldades encontradas para a criação de softwares educacionais, sejam eles CAI ou ICAIs, está na capacidade de reunir uma equipe inter e multidisciplinar que possibilite um bom resultado técnico e pedagógico. Na criação de tais softwares é importante a presença de especialistas da área de computação e engenharia de software, bem como pedagogos, psicólogos, designers gráficos, dentre outros [Carvalho, 2002].

### *2.5.1 – Sistemas tutores inteligentes*

Um sistema tutor para ser considerado inteligente deve ser flexível. Isto significa que ele deve ter a capacidade para aprender com o meio de inserção e atualizar o seu conhecimento [Viccari, 1990; Giraffa, 1999]. Nesse tipo de software o estudante aprende fazendo e, igualmente, o sistema se adapta ao desenvolvimento do estudante. Desta forma, os Sistemas Tutores Inteligentes (STIs) deveriam assumir um papel próximo ao do “professor humano”. Mas devido às inúmeras limitações, tanto em nível de software quanto de hardware, isto está longe de acontecer. Os seres humanos têm a possibilidade de trabalhar com diversos aspectos referentes a sentidos como olfato, tato, visão, etc., e analisar as respostas dos estímulos. Isto ainda é inviável do ponto de vista tecnológico. Para Jonassen [Jonassen, 1993], um STI deve passar em três testes antes de ser considerado “inteligente”:

- O conteúdo do tema ou especialidade deve ser codificado de modo que o sistema possa acessar as informações, fazer inferências ou resolver problemas;

- O sistema deve ser capaz de avaliar a aquisição desse conhecimento pelo estudante; e
- As estratégias do tutor devem ser projetadas para reduzir a discrepância entre o conhecimento do especialista e o conhecimento do estudante.

Viccari [Viccari, 1996] menciona que as arquiteturas de sistemas tutores inteligentes variam de uma implementação para outra. Em geral, os STIs tradicionais possuem uma organização básica, como pode ser visualizado na Figura 2.11.

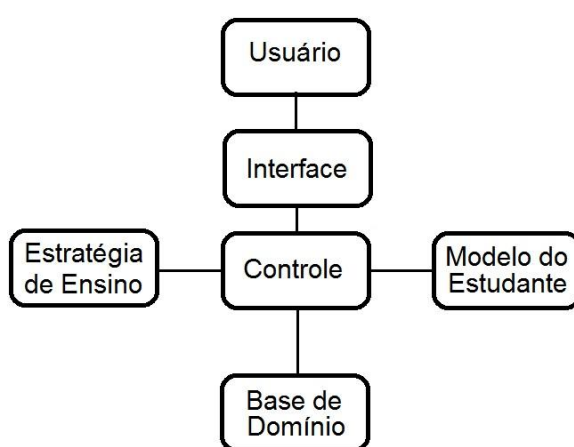


Figura 2.11: Arquitetura tradicional de um STI.

A base de domínio é o componente que age como o especialista e desempenha a função de fonte de conhecimento a ser apresentada. Ela é considerada como um padrão para as avaliações de desempenho do estudante. Essa base é constituída pelo material instrucional, por um sistema de geração de exemplos, por processos de simulação e pela possibilidade de formulação de diagnósticos [Giraffa, 1997; Giraffa, 1999]. Em essência, esse modelo incorpora a maior parte da “inteligência” do sistema na forma do conhecimento necessário para solucionar os problemas do domínio [Park, 1988]. O grande desafio é fornecer uma rica representação desse domínio, de forma que possibilite flexibilidade no ensino.

O conhecimento que o sistema deve ter do seu próprio usuário proporcionará um ensino personalizado e inteligente. O modelo do estudante representa o conhecimento e as habilidades cognitivas do usuário em um determinado momento. A característica principal desse modelo é a de tentar contemplar todos os aspectos do conhecimento e do



comportamento do estudante, que tragam consequências para o seu desempenho e aprendizagem [Viccari, 1996; Giraffa, 1997; Giraffa, 1999; Alencar, 2000].

As estratégias de ensino constituem o modelo pedagógico em si e podem ser vistas como planos de apresentação do material instrucional. Esse modelo deve conter o conhecimento necessário para a tomada de decisões sobre quais táticas de ensino empregar. A construção de tais estratégias é bastante complexa e exige muita versatilidade, pois as decisões devem ser tomadas dinamicamente, tendo como base as atitudes e as necessidades do estudante [Viccari, 1996; Giraffa, 1997; Giraffa, 1999].

De modo geral, é possível afirmar que o usuário tem a concepção de que a interface é o próprio sistema. Logo, fica evidente que uma atenção especial deve ser dispensada nesse sentido. A interface será a responsável pela apresentação do material instrucional e pela manipulação do progresso do estudante, por meio da recepção de sua resposta [Viccari, 1996; Giraffa, 1997; Giraffa, 1999].

O módulo de controle é o responsável pela coordenação geral do tutor. Geralmente são as funções programadas para trocas de informações, apresentação de interfaces, etc. Esse módulo consiste de funções tais como acesso a banco de dados, manutenção do histórico da sessão do usuário e comunicação com outros programas utilitários que façam parte do STI [Viccari, 1996; Giraffa, 1997; Giraffa, 1999; Alencar, 2000].

Nas diferentes técnicas empregadas, observa-se um esforço no sentido de desenvolver disponibilidades de estratégias diferenciadas e um mecanismo que possibilite a adaptação necessária ao estudante. Um grande esforço no desenvolvimento de um STI é a busca de um mecanismo que possa compensar a falta do professor na condução didática do conteúdo apresentado. Existe um grande esforço no desenvolvimento de técnicas para personalizar reativamente o conteúdo apresentado [Viccari, 1996; Cocco, 2004; Rissoli, 2007, González, 2009; Fontenla, 2010].

Outro modo de formular um STI é considerar uma abordagem de sistema cooperativo multiagente. Embora não exista uma definição precisa para agente, na Inteligência Artificial eles são frequentemente considerados como uma entidade capaz de exibir alguns aspectos da inteligência humana. Em geral, os agentes funcionam contínua e autonomamente em um ambiente no qual existem outros processos e agentes. Podem existir diversos agentes no sistema, cada um com sua função. Eles podem agir, por exemplo, modelando o perfil do estudante, o sistema tutor e/ou a base de conhecimento. A interação de tais agentes determina o comportamento “inteligente” do sistema tutor [Correa, 1994; Alencar, 2000; Vicari, 2005].

Trabalhos recentes têm apresentado soluções promissoras destacando a utilização de agentes inteligentes. Em 2004 foi apresentado um modelo multiagente com três agentes (tutor, perfil e comunicação) empregando estilos de aprendizagem para estabelecer estratégias [Cocco, 2004]. Em 2006 foram apresentados parâmetros para o desenvolvimento de sistemas com agentes [Dastbaz, 2006]. Outra proposta inseriu o conceito de mapas conceituais para criar um assistente inteligente baseado em regras oriundas da lógica Fuzzy para modelar o desenvolvimento do estudante, obtendo bons resultados no apoio ao curso de programação [Rissoli, 2007]. Uma proposta baseada em características psicológicas foi utilizada para modelar um sistema multiagente para proporcionar um conteúdo personalizado ao estudante [Méndez, 2008]. O emprego de objetos de aprendizagem ofereceu a incorporação de ferramentas de colaboração para o ambiente de aprendizagem [González, 2009]. A apresentação de um sistema baseado no paradigma de arquitetura orientada a serviços ofereceu ferramentas que possibilitaram o gerenciamento da integração de diversos componentes em um ambiente educacional [Fontenla, 2010]. De maneira geral, pode ser observado que as ferramentas desenvolvidas procuram proporcionar um suporte educacional conforme o conhecimento sobre o problema apresentado. Esse conhecimento procura aperfeiçoar técnicas e conhecimentos anteriormente estabelecidos e demanda um grande esforço na sua aquisição, representação e implementação.

Uma linha de pesquisa de STIs emprega técnicas de inteligência artificial conexionista, com predomínio de utilização de redes neurais artificiais [Alencar, 2000]. Nessa linha o processo de aquisição de conhecimento é simplificado por técnicas automatizadas que extraem o conhecimento por meio de exemplos. Para o desenvolvimento do STI são definidas as características relevantes e empregado um algoritmo de aprendizado para estabelecer a relação entre as características e o conhecimento necessário do domínio do sistema. A primeira geração desses sistemas foi desenvolvida com diversas RNAs e procurava modelar o estudante conforme suas respostas no sistema [Carvalho, 2002]. O sistema empregava muitas RNAs e demandava um grande esforço na sua configuração. A próxima geração procurou reduzir a quantidade de redes com a implantação de um sistema híbrido, passando a empregar apenas uma RNA e uma forma de identificar o perfil do estudante [Melo, 2003], foi realizada a inserção dos estilos de aprendizagem [Meirelles, 2003] e um estudo definiu a modelagem como generalização de espaços de aprendizagem [Melo, 2006]. Um estudo realizou um experimento comprovando que o sistema híbrido poderia ser aplicado a outros conteúdos novos sem a necessidade de novos treinamentos [Quinderé, 2008;]. O trabalho mais recente procurou inserir uma abordagem empregando o paradigma de aprendizagem por reforço para

ajuste da RNA, apresentando bons resultados sem apresentar diferenças significativas em relação ao sistema híbrido. A grande contribuição foi o fato de reduzir a quantidade de testes iniciais para a identificação do estudante [Fonseca, 2007].

O desenvolvimento de um STI consiste no estabelecimento de algum tipo de estratégia para monitorar as ações do estudante e estabelecer as ações de apresentação do conteúdo. Essas estratégias procuram implementar o conhecimento de especialistas na solução de situações educacionais. As técnicas de IA empregadas no desenvolvimento de STIs proporcionam uma forma de tentar reproduzir em computadores as técnicas desenvolvidas no ensino tradicional, proporcionando uma forma dinâmica de interação com o estudante.

No desenvolvimento de STIs, as técnicas de IA clássica estão mais consolidadas, porém o mesmo é dificultado pelas características do processo de aquisição do conhecimento. No entanto, os sistemas conexionistas vislumbram um avanço mais rápido devido as técnicas de aquisição do conhecimento serem automatizadas com exemplos. Entretanto, ainda não há uma consolidação formal do modelo que possa servir de referência no desenvolvimento e aperfeiçoamento do mesmo

## **2.6 – Considerações Finais Deste Capítulo**

Neste capítulo foi realizada uma revisão sobre os conceitos contidos em processos de ensino-aprendizagem, organização e apresentação de conteúdos, soluções computacionais para a tutoria e formas de estabelecer a personalização de estudantes.

Os conceitos de personalização do estudante são fundamentados com a finalidade de estabelecer os métodos para identificar os "padrões da mente humana".

Os conceitos de transmissão e sistematização de conhecimento contextualizam a organização do conhecimento a ser aprendido pelo estudante.

A apresentação das soluções computacionais para a organização e a transmissão de conhecimento mostra as possibilidades de proporcionar ferramentas auxiliares no processo de apresentação dos conteúdos.

O próximo capítulo apresenta uma breve revisão sobre os padrões e as redes neurais artificiais, o modelo de rede neural Perceptron de Múltiplas Camadas utilizado no sistema proposto neste trabalho.

# CAPÍTULO 3

## PADRÕES E REDES NEURAIS

### 3.1 - Introdução

Reconhecer padrões é uma tarefa normal e relativamente simples para o cérebro humano. A todo instante as pessoas se encontram reconhecendo padrões de forma consciente ou inconsciente. Ao observar um determinado objeto previamente conhecido, o cérebro humano consegue identificá-lo e classificá-lo. Porém, quando um objeto novo é apresentado, o cérebro busca classificá-lo, estabelecendo relações com os objetos previamente conhecidos.

Desenvolver tal processo de reconhecimento de padrões em máquinas não é uma tarefa simples. A automatização do reconhecimento de padrões, entre outras coisas, consiste da abstração de processos, identificação das características relevantes, manipulação e estabelecimento da relação entre as características.

A automatização de sistemas utilizando computadores tem sido empregada nas mais diversas áreas de atuação, proporcionando maior velocidade e precisão na execução de tarefas e no processamento de dados.

Em um sistema de computação convencional, a solução do problema é desenvolvida de acordo com a experiência, o conhecimento e a criatividade do programador diante da situação apresentada. As soluções são criadas para tratar a situação conforme as possibilidades visualizadas. Diante de uma situação nova o sistema desenvolvido poderá falhar porque a situação não foi prevista por quem desenvolveu a solução. Assim, pode ser verificado que a qualidade das soluções está diretamente ligada ao conhecimento do problema apresentado e ao adequado desenvolvimento de uma solução computacional (algoritmo). Diante disso, é possível afirmar que nos sistemas convencionais pode não existir resposta para entradas de dados não previstas, mesmo pertencendo à classe intermediária das implementadas, e esta situação pode ocasionar falhas em momentos críticos [Melo, 2007].

O paradigma dos sistemas inteligentes introduziu uma importante mudança nas aplicações computacionais. Nos sistemas de computação inteligente, diferente da computação convencional, são criados mecanismos que permitem apresentar respostas para as situações novas ou não previstas pelo programador. O desenvolvimento de sistemas inteligentes pode ser realizado por meio de técnicas simbólicas ou conexionistas.

As técnicas simbólicas constituem uma abstração explícita do conhecimento. Isto significa que o desenvolvedor precisa entender quais são os fatos e as relações que compõem o processo do conhecimento. Este entendimento em grande parte demanda algum tipo de comunicação com especialistas na área de conhecimento. A qualidade da comunicação influencia a qualidade do sistema a ser desenvolvido.

Nas técnicas conexionistas o conhecimento pode ser desenvolvido a partir da definição de características relevantes ao conhecimento. Após a definição das características o sistema pode ser desenvolvido fundamentado em um processo de aprendizagem de máquina. A aprendizagem estabelece a relação entre as características e o objeto.

As redes neurais artificiais (RNA) fazem parte do conjunto de técnicas do conexionismo que permitem o desenvolvimento de soluções para sistemas inteligentes. A aplicação de RNA torna-se especialmente útil em problemas com considerável nível de dificuldade para estabelecer a relação entre as características e a classificação do objeto.

Este capítulo apresenta uma breve revisão sobre os padrões e as redes neurais artificiais, o modelo de rede neural Perceptron de Múltiplas Camadas utilizado no sistema proposto neste trabalho.

### **3.2 – Reconhecimento de Padrões (RP)**

As técnicas de classificação de padrões são utilizadas para descrever e organizar padrões por meio de um conjunto de características consideradas nos objetos [Fu, 1980].

Um padrão pode ser definido como algo que apresenta uma regularidade conforme certas características, uma entidade à qual se pode atribuir um nome [Fu, 1980; Devijver, 1982; Duda 2001]. Por exemplo, um quadrado é um padrão de figura geométrica.

Em linhas gerais, o objetivo do estudo de padrões é estabelecer métodos para a definição e a análise de características dos objetos que possibilitem identificar regularidades.

### 3.2.1 – Sistema de reconhecimento de padrões

Para o ser humano, identificar a forma e os elementos de um quadrado pode ser algo simples e intuitivo. Por meio de um elemento sensor como a visão, por exemplo, o cérebro recebe os estímulos de uma forma geométrica. Os estímulos passam por um sistema de ligações entre os neurônios que estabelece a identificação da figura como sendo um quadrado. O cérebro realiza a identificação com um sistema de aprendizado que de alguma forma estabelece e ajusta o sistema de ligações entre os neurônios para identificar o objeto visualizado. O resultado das ligações é uma representação interna do cérebro, que pode não corresponder à mesma representação em outro cérebro.

Possibilitar a representação externa não é tão simples. É necessário uma sistematização do processo para que este possa ser compreendido por outros ou reproduzido em uma máquina. Para sistematizar o processo de reconhecimento é necessário compreender como proceder, quais características devem ser consideradas e como relacionar estas características [Fu, 1980; Devijver, 1982; Duda 2001].

Qualquer que seja a sua forma, os dados contém informações sobre os processos que o geraram. Essa informação pode ser obtida pela análise da estrutura da informação. A estrutura estabelece como a informação pode ser organizada de modo que as relações entre as variáveis do processo possam ser identificadas [Fu, 1980]. A definição dessas variáveis e atributos é um elemento fundamental para o estudo de reconhecimento de padrões.

Como exemplo inicial, é delineado a sistematização do reconhecimento do padrão da figura geométrica quadrado. Para simplificar, inicialmente, é considerada a classificação no universo de figuras geométricas que compreendem o retângulo e o quadrado. Como as duas figuras têm características semelhantes, pode ser definida uma descrição que estabeleça o que é o padrão quadrado. Isto pode ser estabelecido de várias formas. Uma forma consiste em obter o valor de um lado e depois verificar se existe algum lado com valor diferente. Outra forma é obter o valor dos quatro lados, efetuar a soma desses lados, multiplicar um dos lados por quatro e comparar os dois resultados. Se os resultados forem idênticos é possível afirmar que a figura é um quadrado.

Em um próximo nível de dificuldade, podem existir figuras de quatro lados com tamanhos distintos. O problema agora já não consiste apenas em reconhecer entre os retângulos e os quadrados. Nesse caso, considerar apenas o tamanho dos lados já não é suficiente para identificar a figura, é preciso considerar mais características. Por exemplo, pode ser considerada a característica do ângulo entre os lados. Se os quatro ângulos forem de

90° então o processo pode continuar para as verificações do primeiro caso, a diferença entre o retângulo e o quadrado.

Ampliando o universo do problema, pode ser necessário fazer o reconhecimento do quadrado quando é apresentada qualquer figura geométrica. Novamente, os passos anteriores não são suficientes. Nesse nível de dificuldade pode ser acrescentada a informação de quantos lados tem a figura apresentada. Caso a figura tenha quatro lados o problema pode continuar para as outras etapas já descritas.

Diante dos três exemplos de identificação do padrão quadrado, é possível observar que a medida que aumenta o universo do problema, devem ser consideradas mais características e a inserção de novos procedimentos. Nos exemplos apresentados é possível observar um gradiente de soluções em que a solução do universo mais simples, pode fazer parte do universo mais complexo.

Descrever como estabelecer um padrão é uma parte do problema de reconhecimento de padrões. Pode-se dizer que essa é a parte do processamento do padrão. Para completar a técnica de reconhecimento de padrões é necessário definir uma entrada e uma saída para que o sistema possa interagir com o meio. A entrada é um elemento sensor que percebe as características do objeto apresentado. A saída é a classificação do padrão. A Figura 3.1 apresenta o esquema de um sistema para a classificação de padrões.




Figura 3.1: Sistema para reconhecimento de padrões.

O objeto a ser classificado é apresentado ao sensor que o converte em sinais para o sistema de reconhecimento que efetua o reconhecimento e a classificação. O sensor é a parte responsável pela aquisição dos dados. Ao receber o sinal do sensor o sistema realiza um pré-processamento para simplificar as etapas seguintes e reduzir ruídos que possam interferir na classificação. A próxima etapa é a extração das características cujo propósito é reduzir os dados com a avaliação dos valores das propriedades consideradas no processo. Os valores são avaliados por um classificador que avalia e define a classe do objeto apresentado. Desta forma, é possível estabelecer um modelo geral para a classificação de padrões, conforme

representado na Figura 3.2, como sendo constituído de um pré-processamento, da extração de características e da classificação [Fu, 1980; Devijver, 1982; Duda 2001].




Figura 3.2: Modelo geral do sistema de reconhecimento.

Frequentemente o objeto de interesse não é uma descrição detalhada de todas as variáveis, mas sim a consideração de alguns de seus grupos que exibem propriedades específicas. Os padrões gerados de acordo com esse grupo de variáveis constituem uma classe, cuja definição varia de acordo com o problema. Por esta razão, um sistema de reconhecimento de padrão é usualmente entendido como um processo de atribuição de padrão a uma classe dentre um conjunto de classes definidas por critérios previamente definidos [Fu, 1980; Devijver, 1982; Duda 2001].

Em geral, os padrões podem ser representados em um espaço multidimensional. A representação inicial do padrão geralmente tem uma dimensionalidade alta, é o espaço de medidas. Considerando que algumas características podem ser relevadas na classificação do padrão, é possível simplificar o espaço para uma representação de dimensionalidade reduzida, que é o espaço das características. Essa transformação resulta em perda de informação, porém pode simplificar o processo de classificação.

O processo de classificação é realizado pelo classificador. O classificador, representado na Figura 3.3, implementa uma função de decisão que mapeia os pontos do espaço de características no conjunto de classes pré-definidas. Para possibilitar a relação entre o objeto e sua classe é necessário estabelecer um meio pelo qual diferentes regras de decisão possam ser avaliadas ou comparadas. A função de decisão é implementada por um algoritmo de reconhecimento que é uma sequência de operações lógicas e computacionais sobre o padrão.

O algoritmo de reconhecimento em conjunto com um grupo de técnicas para definir a forma de estabelecer e reconhecer o padrão é denominado de método de reconhecimento [Fu, 1980; Devijver, 1982].






Figura 3.3: Representação do classificador.

### 3.2.2 – Projeto de sistemas de reconhecimento de padrões

O projeto de um sistema de reconhecimento de padrões é constituído de uma análise dos padrões para estabelecer o processo de medidas, a extração das características e a organização das relações das características para possibilitar a classificação. Conforme pode ser observado na Figura 3.4, as etapas do projeto são iterativas e geralmente constam de atividades tais como coleta de dados, escolha das características, definição do modelo, treinamento e avaliação do sistema [DUDA, 2001].




Figura 3.4: Etapas do projeto de um sistema de reconhecimento de padrões.

A coleta de dados pode demandar uma grande parte no desenvolvimento e no custo do projeto. É possível realizar uma coleta inicial de tamanho reduzido para avaliar um estudo preliminar da viabilidade do projeto e das características do sistema. Usualmente uma quantidade maior de dados coletados é necessária para assegurar uma boa qualidade no campo de atuação do sistema.

A escolha das características é uma parte crítica do projeto e depende do universo de domínio do problema. O acesso a exemplares de dados contribui para a escolha de um conjunto de características relevantes ao problema. Um conhecimento prévio dos diferentes exemplares do problema pode facilitar na escolha das características promissoras para a

classificação. A seleção de características deve considerar alguns pontos tais como facilidade de extração, invariabilidade perante as transformações irrelevantes, não sensível a ruídos e relevante para diferenciar padrões em diferentes categorias

A escolha do modelo do classificador deve atender a requisitos que satisfaçam as necessidades do universo do problema a ser solucionado com a classificação. A escolha está ligada a complexidade do problema e as expectativas de desempenho para o projeto.

O treinamento do sistema refere-se ao uso de dados na definição do classificador. Ainda não existe um método universal para solucionar os problemas de projetos de sistemas de reconhecimento de padrões. Entretanto, os métodos mais efetivos no desenvolvimento de classificadores empregam a aprendizagem com exemplos de padrões.

A avaliação do classificador é importante tanto para medir o desempenho do sistema como para avaliar a necessidade de melhorias no sistema. É importante avaliar se o desempenho do sistema continua satisfatório diante de novos dados, diferentes dos utilizados no treinamento. O resultado dessa avaliação serve como referência para o ajuste nas etapas anteriores visando a solução do problema.

Uma das mais importantes áreas de pesquisa em reconhecimento estatístico de padrões é determinar a complexidade no ajuste do modelo. Não deve ser tão simples a ponto de que não consiga determinar a diferença entre as classes. Também não deve ser tão complexa a ponto de oferecer uma classificação pobre diante de novos padrões [Duda, 2001].

Alguns problemas de reconhecimento de padrões para sua solução requerem algoritmos computacionalmente impraticáveis. Apesar de oferecerem uma solução teórica, os tempos de armazenamento, recuperação e manuseio podem não serem viáveis devido a grande quantidade de dados a serem processados. Desta forma, os recursos computacionais necessários e a complexidade computacional de diferentes algoritmos devem ser considerados sob o aspecto da possibilidade de implementação [Duda, 2001].

O estudo de reconhecimento de padrões tem um grande número de subproblemas com diferentes níveis de complexidade e magnitude. Conforme a complexidade do problema, existe uma diversidade de técnicas e metodologias que podem ser utilizadas.

Conforme [Duda, 2001] as técnicas mais eficientes são as que utilizam algum método de aprendizado por exemplos na estruturação do classificador.

As redes neurais artificiais (RNA) tem como característica a grande capacidade de aprender com exemplos. Devido a essa capacidade de aprendizado as RNAs são consideradas classificadores universais e são utilizadas com grande eficiência na solução de problemas de alta complexidade [Fausett, 1994; Haykin, 2000; Duda, 2001; Braga, 2007].

### 3.3 - Redes Neurais Artificiais

#### 3.3.1 – Inteligência artificial

De forma mais generalizada, os sistemas inteligentes buscam imitar a forma do ser humano pensar. São estruturados de tal forma que, após o período de “aprendizagem”, são capazes de generalizar os padrões de entrada do problema e emitir uma resposta, mesmo para situações não conhecidas anteriormente.

De forma geral um sistema inteligente é composto de três elementos básicos: sensores, atuadores e o sistema, conforme ilustrado na Figura 3.5. O sensor é o elemento de entrada, pelo qual o sistema “percebe” o mundo. Esta percepção é processada pelo sistema que busca uma solução na sua organização interna. O resultado da solução é enviado para a saída na qual os elementos atuadores desenvolvem alguma ação no universo problema do sistema inteligente [Russel, 2004].




Figura 3.5: Representação de um sistema inteligente.

Em 1956 no Dartmouth College, John McCarthy reuniu pesquisadores interessados em áreas afins no estudo da inteligência e da computação científica. O seminário de Dartmouth foi o marco que definiu o novo campo de estudo denominado Inteligência Artificial [Russel, 2004]

As técnicas para implementar a Inteligência Artificial (IA) são classificadas em dois paradigmas: IA simbólica e IA conexionista. A IA simbólica procura simular o comportamento inteligente do ser humano sem considerar os mecanismos responsáveis por esse comportamento. A IA conexionista acredita que se construindo um sistema que simule a estrutura do cérebro, esse sistema apresentará comportamento inteligente, ou seja, será capaz de aprender, assimilar, errar e aprender com seus erros [Russel, 2004].

A IA simbólica, também denominada de IA clássica, procura organizar os processos de produção de conhecimento em regras e outras formas correlatas que possam ser automaticamente organizadas e apresentadas pelo sistema diante das situações. O conhecimento é abstraído, organizado e representado a partir do conhecimento de especialistas [Russel, 2004; Lugger, 2004].

A IA conexionista emprega técnicas computacionais que propõem uma forma particular de processamento da informação baseadas na organização e no funcionamento do cérebro humano. As técnicas de conexionismo procuram organizar o conhecimento em células e suas combinações [Fu, 1994; Fausett, 1994; Haykin, 2000; Braga, 2007].

A decisão por um dos paradigmas depende de vários fatores. Um dos fatores a ser considerado é o processo de aquisição e representação do conhecimento [Russel, 2004; Lugger, 2004; Rezende, 2005].

Na IA clássica o processo de aquisição do conhecimento, geralmente, é realizado por técnicas manuais tais como entrevistas, observação, etc. O problema nessas técnicas está na qualidade da comunicação entre o engenheiro do conhecimento e o especialista. A experiência desse engenheiro é outro fator importante no processo de aquisição e representação do conhecimento. A experiência do engenheiro do conhecimento e a comunicação entre ele e o especialista influenciam diretamente a qualidade da modelagem do conhecimento [Rezende, 2005].

Na IA conexionista, a aquisição e a representação do conhecimento por técnicas semi-automáticas ou automáticas simplifica a modelagem. O especialista estabelece as características a serem consideradas nas classes do conhecimento. A organização e a representação do conhecimento pode ser realizada de maneira automática empregando alguma técnica de aprendizagem de máquina [Rezende, 2005].

Para a implementação da IA conexionista existem várias técnicas. A técnica mais tradicional e empregada é conhecida como Redes Neurais Artificiais (RNAs).

Por ser uma parte da estrutura utilizada neste trabalho o funcionamento geral da RNA será apresentado nos próximos subitens.

### *3.3.2 – Histórico das Redes Neurais*

As primeiras informações mencionadas sobre a neurocomputação datam de 1943, quando [McCulloch & Pitts, 1943] apresentaram em artigos o primeiro neurônio artificial

baseado no neurônio humano. O trabalho de McCulloch e Pitts concentrou-se, principalmente, na descrição do modelo do neurônio artificial e suas capacidades computacionais.

Alguns anos depois, [Hebb, 1949] demonstrou como a variação dos pesos de entrada dos nodos (neurônios) possibilita a aprendizagem das redes neurais. Hebb foi o primeiro a propor uma lei de aprendizagem específica para as sinapses dos neurônios.

Em 1958, Rosenblatt [1958] apresentou o modelo de RNA denominado perceptron com capacidade de classificar padrões.

Minsky e Papert [1969] demonstraram que o perceptron possui capacidade limitada de classificação para problemas. A solução pode ser alcançada para problemas nos quais é possível dividir o espaço de entrada em duas regiões por meio de uma reta (classes linearmente separáveis). Esse fato causou um esquecimento e uma consequente descrença em sistemas baseados em redes neurais.

Por um longo período, as pesquisas na área de RNA foram realizadas informalmente e não apresentavam resultados relevantes [Russel, 2004]. Apenas nos meados da década de 1980 [Rumelhart, 1986] apresentou o algoritmo back-propagation, que permite o treinamento de redes multicamadas, expandindo a capacidade das redes neurais para a resolução de problemas com níveis de maior complexidade, além dos problemas linearmente separáveis. A partir de então ocorreu um aumento no interesse por essas redes. Além disso, o fato da escola simbolista (inteligência artificial simbólica) não ter conseguido grandes avanços na solução de determinados tipos de problemas, também contribuiu para o ressurgimento das redes neurais artificiais.

### *3.3.3 – Visão geral de redes neurais*

As RNAs são estruturas de processamento distribuído e paralelo viabilizadas, principalmente, por meio de software ou hardware de computador.

As RNAs imitam a maneira do cérebro humano processar informações. O cérebro humano, uma rede neural, é composto de neurônios. Conforme pode ser visualizado na Figura 3.6, o neurônio biológico é dividido em três seções inter-relacionadas: o corpo da célula, os dendritos e o axônio. Os dendritos recebem os impulsos nervosos (informações) de outros neurônios, transmitindo-os até o corpo da célula. Em seguida, a informação é transformada

em novos impulsos, os quais são transmitidos a outros neurônios por meio do axônio. [Fu, 1994; Fausett, 1994; Haykin, 2000, Braga, 2007].




Figura 3.6: Estrutura do neurônio humano.

A conexão feita entre o axônio de um neurônio e o dendrito de outro neurônio é denominada sinapse. As sinapses formam as ligações entre os neurônios, compondo assim as redes neurais. As sinapses funcionam como válvulas, sendo capazes de controlar a transmissão de impulsos (fluxo de informação) entre os neurônios na rede neural. O efeito das sinapses é variável e esta variação implementa a capacidade de adaptação ao neurônio [Fu, 1994; Fausett, 1994; Haykin, 2000, Braga, 2007].

Para a implementação das RNAs [MacCulloch & Pitts, 1943] propuseram um modelo de neurônio artificial (nodo) similar em estrutura e funcionamento ao neurônio biológico. A Figura 3.7 ilustra o modelo proposto de neurônio artificial.




Figura 3.7: Estrutura do neurônio artificial (MacCulloch e Pitts).

O nodo possui um ou mais sinais de entrada ( $E_0, E_1, E_2, \dots, E_n$ ) e um sinal de saída ( $S$ ). Os pesos ( $w_0, w_1, w_2, \dots, w_n$ ) são valores que indicam o grau de importância que determinada entrada possui em relação ao respectivo neurônio. O sinal de excitação no neurônio é

resultante da somatória do produto de cada entrada por seu respectivo peso (função soma  $\Sigma$ ). O sinal de excitação resulta em uma saída conforme a função de ativação (ou função de transferência T) interna do neurônio. A função de ativação possui um limiar ( $\Theta$ ) que resulta em uma saída quando a informação recebida pela função ultrapassa o valor estabelecido [Braga, 2007]. Uma forma de ilustrar a função de ativação (T) é por meio da comparação com um recipiente com um furo ( $\Theta$ ) em uma determinada altura. A saída do líquido ocorre quando a quantidade colocada no vasilhame é igual ou superior a altura do furo.

De forma análoga ao cérebro, os neurônios artificiais são interconectados, formando a rede neural artificial, conforme ilustrado na Figura 3.8. Assim, é possível criar as estruturas para a generalização de padrões por meio de variadas entradas, resultando em uma ou mais saídas que podem representar uma ação ou um objeto do mundo real (padrão) como resposta aos dados apresentados na entrada [Fu, 1994; Fausett, 1994; Haykin, 2000, Braga, 2007].

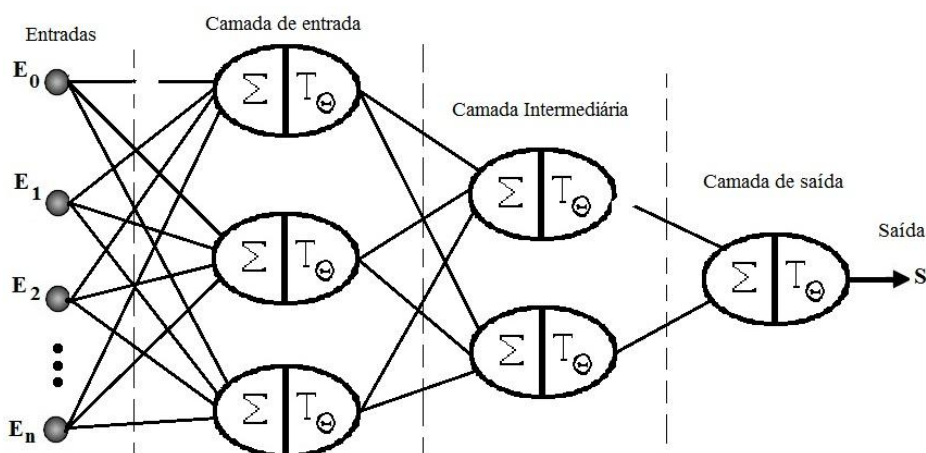


Figura 3.8: Rede neural artificial (RNA).

A fase de aprendizado (normalmente descrita como “treinamento da rede”) trata do ajuste adequado dos pesos, possibilitando a retenção das características dos padrões conhecidos e o emprego da rede na generalização/classificação de novos padrões [Fu, 1994; Fausett, 1994; Haykin, 2000, Braga, 2007].

Em termos gerais, uma RNA possui o seguinte funcionamento: após ser especificada a estrutura (como os neurônios serão interconectados), uma série de exemplos (conjunto de treinamento) são apresentados para treinar a RNA no reconhecimento dos padrões. Nessa fase, são ajustados os pesos das entradas de cada neurônio, conforme os exemplos apresentados, permitindo a adaptação da rede às situações apresentadas. Ao final dessa fase, a

rede estará “treinada”, capacitada a reconhecer os padrões que lhe forem apresentados. A rede será capaz de fornecer uma resposta coerente para os padrões que não tenham feito parte do conjunto de treinamento, classificando-os dentro de um dos padrões previamente “aprendidos”. Assim, a rede não informa que o novo padrão não existe, mas, sim, conforme suas características adquiridas, que o padrão se assemelha a algum dos padrões que ela conhece [Fausett, 1994; Haykin, 2000, Braga, 2007].

Em uma aplicação específica, para o treinamento da RNA, é utilizada para a “aprendizagem” uma amostra representativa da população que se deseja fazer a classificação. As características fornecidas (estímulos) são os parâmetros necessários para o ajuste do comportamento interno da RNA. Quanto mais representativa é a amostra, melhor é a capacidade de resposta da rede na identificação de novos padrões. O treinamento ou o “aprendizado” da RNA pode ser realizado de duas formas: aprendizado supervisionado ou aprendizado não-supervisionado [Fausett, 1994; Russel, 2004; Braga, 2007].

No modo denominado “aprendizado supervisionado”, para cada exemplo apresentado na entrada da RNA resulta em uma saída. Esta saída é comparada com uma saída conhecida esperada correspondente ao exemplo apresentado. Caso sejam diferentes, os pesos da rede são reajustados. Esse processo é repetido continuamente para cada exemplo, utilizando-se a mesma amostra repetidas vezes. O treinamento é finalizado quando as respostas estiverem concordantes com suas respectivas expectativas [Fausett, 1994; Haykin, 2000, Braga, 2007].

Existe alguma semelhança entre o processo que caracteriza o aprendizado supervisionado e o que é denominado “aprendizagem por tentativa e erro” no campo das teorias psicológicas da aprendizagem [Catania, 1998].

No modo denominado “aprendizado não-supervisionado”, os exemplos da amostragem são apresentados à rede no sentido de forçar a auto-organização das informações em sua estrutura. Os neurônios são elementos classificadores (especializados em conjuntos específicos de padrões não definidos explicitamente no treinamento) e os dados de entrada são os elementos para a classificação [Fausett, 1994; Haykin, 2000, Braga, 2007].

Um exemplo de aprendizagem não supervisionada é o desenvolvimento do discernimento de cores pela visão humana. Inicialmente, a visão não está completamente desenvolvida. Pela estimulação natural do ambiente é formada no cérebro uma estrutura que ordena as cores de tal modo que as cores semelhantes são detectadas por neurônios espacialmente próximos. Ao ser apresentada uma entrada, os neurônios competem para estabelecer qual será o identificador do novo padrão. Após a definição do identificador, os outros neurônios “sabem” qual é o responsável pela identificação do padrão. Desta forma,



quando os padrões semelhantes são apresentados, todos “procuram encaminhar” o padrão para o neurônio identificador definido [Golberg, 1999].

Após o treinamento da RNA, ela é avaliada com outra amostra denominada “conjunto de teste”. A partir dessa amostra, verifica-se o índice de resposta da rede aos padrões apresentados. Se o índice estiver dentro dos limites esperados (pré-estabelecidos), a rede estará pronta para a utilização [Fausett, 1994; Haykin, 2000, Braga, 2007].

Depois de treinadas e testadas, as redes neurais são utilizadas para tarefas de classificação, otimização ou auto-organização, dependendo da natureza do problema a ser tratado [Rosemberg, 1958; Rumelhart 1986; Fu, 1994].

### 3.3.4 – O neurônio artificial

O modelo do neurônio artificial de [McCulloch & Pitts, 1943], apresentado na Figura 3.9, tenta simular as realidades biológicas que ocorrem dentro de uma célula do sistema nervoso. A informação proveniente de outros neurônios entram em  $n$  entradas  $x_i$  (sinapses) formando o vetor  $x$  (entradas). Cada entrada está associada a um peso  $w_i$  que reflete a importância da mesma para o problema. Quanto menor é o peso maior é a importância da entrada.




Figura 3.9: Neurônio Artificial.

O processamento do neurônio começa com a ponderação e a soma dos sinais de entrada pela função soma. A ponderação é obtida pela multiplicação de cada entrada  $x_i$  pelo peso  $w_i$  ( $x_i * w_i$ ) correspondente a conexão na qual o sinal passa. A soma dos sinais

ponderados ( $x_1w_1 + x_2w_2 + x_3w_3 + \dots + x_nw_n$ ) pela função soma resulta na saída  $Y_j$ , conforme representado na Equação (3.1).

$$Y_j = \sum_{i=0}^n x_i w_i \quad (3.1)$$

onde:

- j - índice do neurônio;
- n - quantidade de entradas;
- $x_i$  - i-ésima entrada; e
- $w_i$  - i-ésimo peso.

A próxima etapa do processamento é a de comparar a saída  $Y_j$  com um limiar ( $\theta$ ). Essa etapa é realizada pela função de transferência (T) resultando na saída  $S_j$  do perceptron. O valor de  $S_j$  é resultante de uma função degrau onde  $S_j(x) = 0$  se  $Y_j \leq 0$  caso contrário  $S_j(x) = 1$  se  $Y_j > 0$ . A saída  $S_j$  é uma função como representado na Equação (3.2).

$$S_j = T\left(\sum_{i=0}^n x_i w_i - \Theta\right) \quad (3.2)$$

onde:

- j - índice do neurônio;
- T - função degrau;
- n - quantidade de entradas;
- $x_i$  - i-ésima entrada; e
- $w_i$  - i-ésimo peso.

A função de ativação do modelo de [McCulloch & Pitts, 1943] não é a única maneira de obter o valor de saída do neurônio. A Figura 3.10 mostra diferentes tipos de funções de ativação. A função linear resulta em uma saída linear contínua, a função degrau resulta em uma saída binária (não-linear discreta) e a função sigmoideal resulta em uma saída não-linear contínua.




Figura 3.10: Funções de ativação.

A função sigmoidal tem um conjunto de propriedades que se mostram muito úteis nos cálculos relacionados à aprendizagem dos pesos e ao mapeamento contínuo e não linear realizado pela rede [Fausett, 1994; Haykin, 2000, Braga, 2007].

### 3.3.5 – Topologias de redes com neurônios artificiais

O potencial e a flexibilidade do cálculo baseado em redes neurais vêm da criação de conjuntos de neurônios interligados entre si. O processamento local de cada neurônio (nodo) em ação combinada com outros nodos estabelece a inteligência global da rede. Um nodo da rede recebe um estímulo na sua entrada, processa esse sinal e emite um novo sinal de saída que por sua vez é recebido por outros nodos. A topologia da RNA diz respeito a estruturação dos nodos [Fausett, 1994; Haykin, 2000, Braga, 2007].

Normalmente, a rede é organizada em camadas, nas quais são agrupados neurônios que recebem a informação simultaneamente. A primeira camada está ligada diretamente a entrada, na qual são inseridos os dados (características) na rede. A última camada está ligada com a saída, o resultado do processamento da rede. Algumas topologias apresentam uma camada intermediária, também denominada camada oculta ou escondida. As camadas intermediárias não são ligadas diretamente às entradas e nem às saídas.

Uma categorização básica da topologia dos neurônios pode ser realizada em relação ao método de propagação da informação recebida. Pode-se distinguir entre as redes realimentadas e as redes de propagação para frente (*feedforward*). As redes realimentadas não têm restrições nas ligações entre os neurônios. O fluxo da informação pode ser bidirecional. Saídas de uma camada podem ser conectadas as entradas de nodos de camadas anteriores. No caso das redes de propagação para frente o fluxo de informação é unidirecional. As saídas de

uma camada só podem ser conectadas nas entradas das camadas posteriores. Esse último modelo é o que está sendo utilizado neste trabalho

Quanto à forma de conexão de um neurônio com outro, as redes podem ser totalmente ou parcialmente conectadas. Nas redes totalmente conectadas, cada saída da camada anterior encontra-se conectada a entrada de cada nodo da camada posterior. Nas redes parcialmente conectadas cada saída pode estar conectada apenas a algumas entradas da camada posterior. As redes totalmente conectadas são as mais comuns.

### *3.3.6 – Aprendizado computacional*

Uma importante característica das RNAs é a capacidade de aprender por exemplos. Na abordagem conexionista o conhecimento é adquirido por meio do ajuste da intensidade das ligações entre os elementos da rede.

Após a definição da rede neural ela precisa ser treinada para atuar na solução do universo de estudo em consideração. O treinamento da rede significa efetuar um ajuste nos pesos dos neurônios seguindo algum algoritmo de aprendizagem. Esse treinamento também costuma ser denominado de “aprendizado da rede” ou “aprendizado computacional”. Para o treinamento é utilizado uma amostragem do universo problema considerado. A amostra deve ser rica na representatividade das classes a serem consideradas na solução.

Uma distinção principal em relação ao paradigma de aprendizagem que é válido para todo tipo de sistema com capacidade de adaptação é a aprendizagem supervisionada e a aprendizagem não-supervisionada [Fausett, 1994; Haykin, 2000, Braga, 2007].

No modo denominado “aprendizado não-supervisionado”, os exemplos da amostragem são apresentados à rede no sentido de forçar a auto-organização das informações em sua estrutura. Nesse modo não existe uma definição inicial dos elementos em categorias, e não existe conhecimento prévio sobre quais classes pertencem os elementos da amostra. Isso significa que a rede tem que achar atributos estatísticos relevantes, desenvolvendo uma representação própria dos estímulos que entram na rede. Para esse tipo de treinamento após a definição da quantidade de categorias para a representação do problema, o algoritmo estabelece a relação dos atributos que conduzam ao reconhecimento das classes. Dentre as metodologias de aprendizagem não supervisionada destacam-se os mapas auto-organizáveis de Kohonen [Kohonen, 1981].

Após o treinamento não supervisionado, o sistema estabelece uma organização para reconhecer o universo de estudo na quantidade de classes estabelecidas. Desta forma, qualquer problema é classificado exatamente em uma dessas classes, não existindo classificações intermediárias.

No modo denominado “aprendizado supervisionado” o ajuste da rede é conduzido por um processo de supervisão que compara a resposta da rede com um parâmetro conhecido para a situação apresentada. Nesse paradigma o conjunto de treinamento é composto de dois elementos: dados das entradas (características do objeto) e a correspondente saída conhecida (padrão). O treinamento consiste em apresentar as características na entrada da rede que emite uma saída. A partir desse ponto começa a atuação da supervisão do treinamento. A saída emitida pela rede é comparada com a saída conhecida. Caso sejam diferentes, os pesos da rede são reajustados, caso contrário nenhuma alteração é realizada. Esse processo é repetido do primeiro até o último exemplar, formando um ciclo de treinamento. O ciclo é repetido enquanto o nível de erro está acima de uma expectativa ou uma quantidade de ciclos não é excedida.

Após o treinamento supervisionado, a organização do sistema permite o reconhecimento das classes apresentadas no treinamento e a interpolação de classes novas, não presentes no conjunto de treinamento. Essa particularidade é interessante para universos contínuos e, principalmente, quando não é difícil precisar se a amostragem tem boa representatividade do problema. Na fase de utilização da rede treinada, diante das novas classes, a capacidade de interpolação possibilita as classificações intermediárias entre as classes aprendidas no treinamento supervisionado.

### *3.3.7 – Regras para o ajuste de pesos*

A etapa de treinamento de uma RNA é um processo iterativo no qual os pesos das conexões são reajustados para que, no final do processo, a rede possa refletir o conhecimento adquirido do ambiente externo apresentado pelos exemplos.

Uma forma típica de aprendizado supervisionado é o aprendizado por correção de erros [Fausett, 1994; Haykin, 2000, Braga, 2007]. Neste método procura-se minimizar o erro da resposta atual da rede em relação a saída desejada. Considerando o instante atual  $t$ , a

resposta calculada pela rede  $y(t)$  e a resposta desejada  $y_d(t)$ , o erro  $e(t)$  é calculado pela Equação (3.3).

$$e(t) = y_d(t) - y(t) \quad (3.3)$$

onde:

$e$  - erro;  
 $t$  - instante atual;  
 $y$  - saída calculada pela rede; e  
 $y_d$  - saída desejada (esperada).

Durante o processo de aprendizagem os pesos são reajustados de forma iterativa. Em cada iteração  $t$  o peso  $w(t)$  influencia a função calculada pela rede. O algoritmo de aprendizagem é estabelecido por uma regra que julga a qualidade do peso e determina se o peso deve ter seu valor ajustado com uma diferença  $\Delta w(t)$  na iteração  $t + 1$ . Assim, a regra básica de adaptação dos pesos pode ser definida pela Equação (3.4).

$$w_i(t+1) = w_i(t) + \Delta w_i(t) \quad (3.4)$$

onde:

$t$  - instante atual; e  
 $w_i$  -  $i$ -ésimo peso da rede.

A partir da Equação (3.4), foram desenvolvidas várias regras de aprendizagem, nas quais são considerados a taxa de erro, a velocidade de aprendizado, a minimização do custo e outras variáveis. A regra delta de aprendizagem, representada pela Equação (3.5) considera o erro  $e(t)$ , o sinal de entrada  $x(t)$  e uma taxa de aprendizado  $\eta$ . Esta taxa é uma constante positiva que determina o avanço em cada passo no processo iterativo de aprendizagem. [WIDROW, 1960; FAUSETT, 1994; HAYKIN, 2000, BRAGA, 2007].

$$w_i(t+1) = w_i(t) + \eta e(t) x_i(t) \quad (3.5)$$

onde:

$t$  - instante atual;  
 $w_i$  -  $i$ -ésimo peso da entrada;  
 $e$  - erro;

$x_i$  – i-ésima entrada do neurônio; e  
 $\eta$  - taxa de aprendizado.

Conforme a regra delta, o ajuste dos pesos deve ser proporcional ao produto do erro pelo valor da entrada no instante de tempo considerado. Essa regra é utilizada no treinamento das redes perceptron e das redes MLP que serão expostos a seguir. Nesses modelos a regra de ajuste consiste na minimização da soma dos erros quadráticos da saída, conforme apresentado na Equação (3.6).

$$\varepsilon^2 = \frac{1}{2} \sum_{i=1}^n (y_{di} - y)^2 \quad (3.6)$$

onde:

$n$  - número de exemplos de treinamento;  
 $y_{di}$  - saída desejada para o vetor de entrada  $x_i$ ; e  
 $y$  - saída corrente para vetor de  $x_i$ .

O conjunto de dados formado pelos pares de entrada e saída ( $x_i$ ,  $y_{di}$ ) define o cálculo de um erro quadrático  $\varepsilon^2$  para o ajuste de cada peso da rede.

### 3.3.8 – O perceptron

O perceptron é a forma mais simples de uma rede neural utilizada para a classificação de dados linearmente separáveis. Basicamente, ele é constituído de um único neurônio com pesos sinápticos ajustáveis. O algoritmo de ajuste dos pesos (aprendizagem) do perceptron foi introduzido por [Rosenblatt, 1958]. Apesar da representação de Rosenblatt considerar a rede com três níveis, a topologia do perceptron é de apenas uma camada [Fausett, 1994; Haykin, 2000, Braga, 2007].

Uma rede perceptron é formada pelo conjunto de entradas, a camada de neurônios e a(s) saída(s). O neurônio realiza o processamento das entradas pela combinação da função soma com a função de transferência. Esta função compara o resultado desse processamento com um limiar ( $\theta$ ) para resultar em uma saída.

Para que o perceptron possa ser utilizado na classificação de padrões é necessário um treinamento para ajustá-lo a classe problema apresentada. O treinamento da rede perceptron é do tipo supervisionado. A Figura 3.11 apresenta o algoritmo de treinamento do perceptron.

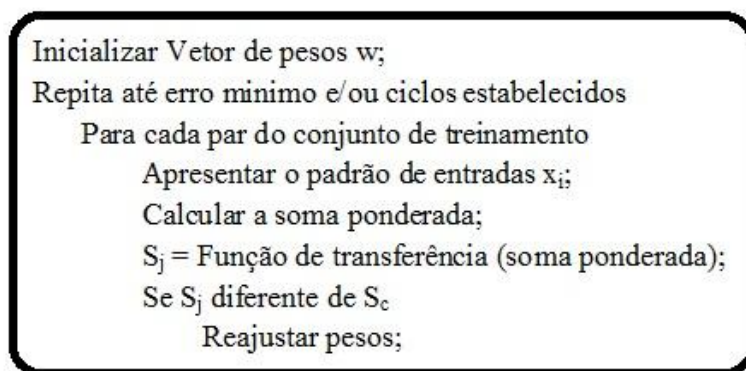


Figura 3.11: Algoritmo de treinamento do perceptron.

Para o treinamento é selecionada uma amostra. Cada elemento da amostra é composto por um grupo de características (entradas) associadas a uma saída esperada. Cada grupo de características de um elemento é apresentado na entrada do perceptron. As entradas são processadas pelo perceptron que emite uma saída calculada pela rede. Esta saída é comparada com a saída esperada caso sejam diferentes a regra de aprendizado é acionada para reajustar os pesos. Um ciclo de treinamento ocorre quando todos os elementos da amostra são apresentados. Ao final de cada ciclo é verificado o erro acumulado no ciclo. O treinamento pode ser encerrado em duas condições: uma taxa de erro a nível zero ou mínimo (estabelecido previamente) ou uma quantidade de ciclos tenha sido excedida. Na primeira situação a rede é considerada treinada. Na segunda é necessário um novo treinamento com novos parâmetros de inicialização [Fausett, 1994; Haykin, 2000, Braga, 2007].

Quando são utilizadas Redes Neurais Artificiais de uma só camada, os padrões de treinamento apresentados à entrada são mapeados diretamente em um conjunto de padrões de saída da rede, ou seja, não é possível a formação de uma representação interna. Nesse caso, a codificação proveniente do mundo exterior deve ser suficiente para implementar esse mapeamento. Tal restrição implica que os padrões de entrada similares resultem nos padrões de saída similares, o que leva o sistema à incapacidade de aprender os mapeamentos complexos. Como resultado, os padrões de entrada com estruturas similares, fornecidos pelo



mundo externo, que levem a saídas diferentes, não são possíveis de serem mapeados por redes sem representações internas, isto é, sem camadas intermediárias.

Minsky e Papert [1969] analisaram matematicamente o perceptron e demonstraram que as redes de uma camada são incapazes de solucionar problemas não linearmente separáveis. Como eles não acreditavam na possibilidade de se construir um método de treinamento para redes com mais de uma camada, eles concluíram que as redes neurais seriam sempre suscetíveis a essa limitação.

### 3.3.9 – Perceptron de múltiplas camadas (MLP)

Diante da limitação das redes perceptron na solução de problemas mais complexos, foi verificada a necessidade de uma estrutura com maior capacidade de representação. Precedido por propostas semelhantes, Rumelhart, Hinton e Williams, em 1986, demonstraram que é possível treinar eficientemente redes com camadas intermediárias, resultando no modelo de Redes Neurais Artificiais mais utilizado atualmente, a rede Perceptron Multi-Camadas – MLP (do inglês, Multi Layer Perceptron) [Fausett, 1994; Haykin, 2000, Braga, 2007].

Na rede MLP, ilustrada na Figura 3.12, cada camada tem uma função específica. A camada de saída recebe os estímulos da camada intermediária e constrói o padrão que será a resposta. As camadas intermediárias funcionam como extratoras de características, seus pesos são uma codificação das características apresentadas nos padrões de entrada e permitem que a rede crie sua própria representação, mais rica e complexa, do problema.




Figura 3.12: Rede neural perceptron de múltiplas camadas (MLP).

Juntamente com a habilidade de aprender por meio de treinamento, o poder computacional da rede MLP é derivado da combinação de três características:

- a) Modelo de cada neurônio da rede inclui uma função de ativação não linear (a mais comum é a função logística sigmóide);
- b) A rede possui uma ou mais camadas de neurônios ocultos, que não fazem parte nem da entrada e nem da saída. Esses neurônios capacitam a rede a aprender as tarefas mais complexas, extraindo as características mais significativas dos padrões de entrada; e
- c) A rede exibe um alto grau de conectividade, determinado pelas sinapses da rede. Uma modificação na conectividade requer uma mudança nas conexões ou em seus pesos.

Conforme a complexidade do problema, a representação para resultar no mapeamento correto da entrada para a saída pode ser obtida estabelecendo conexões certas entre as unidades de entrada e um conjunto de unidades intermediárias.

As conexões certas podem ser estabelecidas pelo treinamento com um conjunto de treinamento representativo do universo de estudo. A dificuldade é estabelecer a quantidade de camadas intermediárias. [Cybenko, 1988] provou que são necessárias no máximo duas camadas intermediárias (com um número suficiente de unidades por camada) para resultar em quaisquer mapeamentos. Nesse estudo, também foi provado que apenas uma camada intermediária é suficiente para aproximar qualquer função contínua.

### *3.3.10 – Treinamento de redes perceptron de múltiplas camadas*

De forma mais simples, as redes MLP podem ser visualizadas como um conjunto de redes perceptron interligadas. Assim como o perceptron, o treinamento da rede MLP é do tipo supervisionado.

No caso de redes de camada única a regra de aprendizagem pode ser aplicada diretamente ao conjunto de pesos das conexões da camada de entrada. Isto ocorre devido a saída calculada da rede estar relacionada diretamente com a saída desejada.

Em uma rede MLP os neurônios da camada de entrada resulta em uma saída para a primeira camada intermediária. O neurônio da camada de saída resulta na saída a partir de valores provenientes da última camada intermediária. No caminho da entrada até a saída

existem outras camadas com entradas cujos valores são provenientes da camada anterior e produzem saídas para a camada posterior. Os valores de entrada e saída intermediários são desconhecidos e não estão relacionados no par  $(x_i, y_{di})$  do conjunto de treinamento. Assim, a regra de correção de erros pode ser aplicada somente na camada de saída pois as outras camadas não tem saída desejada definida.

A solução para o problema de treinamento surgiu com a descrição de um algoritmo para a retropropagação do erro (*backpropagation*). O princípio do algoritmo backpropagation é a estimação do erro das saídas das camadas anteriores a partir do erro da camada de saída. O erro da saída é calculado e este é retroalimentado, utilizando o gradiente descendente para estimar o erro nas camadas anteriores. Nesse método existe uma diferenciação na forma de calcular o erro na regra delta. Quando o neurônio é da camada de saída não existe alteração na regra. Se o neurônio pertence a outra camada, o erro é calculado por estimativa considerando a somatória do erro dos neurônios [Carvalho, 1998; Haykyn, 2001; Braga, 2007]. A aprendizagem consiste de um passo para frente (propagação ou forward) e um passo para trás (retropropagação ou backward) pelas diferentes camadas da rede, conforme ilustrado na Figura 3.13.

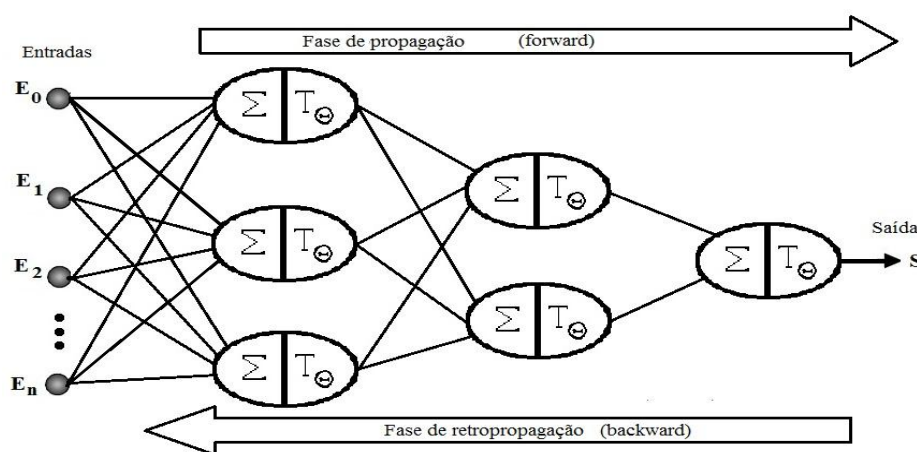


Figura 3.13: Fases do treinamento da rede MLP.

Durante a propagação, as variáveis do conjunto de entrada são apresentadas na camada de entrada da rede (sensores). Cada entrada é ponderada pelo seu respectivo peso e aplicada ao neurônio ou neurônios da camada subsequente, resultando em um determinado efeito. Essa situação é repetida nas camadas subsequentes até a camada de saída na qual resulta em uma representação da rede (resposta da rede) para os padrões que foram aplicados na camada de

entrada. Essa ação ocorre tanto na fase de utilização da rede (treinada) como na fase de treinamento da rede.

Durante a fase de treinamento da rede, a resposta da rede é comparada com um valor esperado. Caso os valores sejam diferentes, o algoritmo de treinamento back-propagation inicia a retropropagação do erro. Na retropropagação, cada peso sináptico é reajustado para fazer com que a resposta da rede se aproxime do valor desejado (convergência). O algoritmo back-propagation, representado na Figura 3.14, é um algoritmo supervisionado que utiliza pares de entrada e saída para ajustar os pesos da rede por meio da correção dos erros.

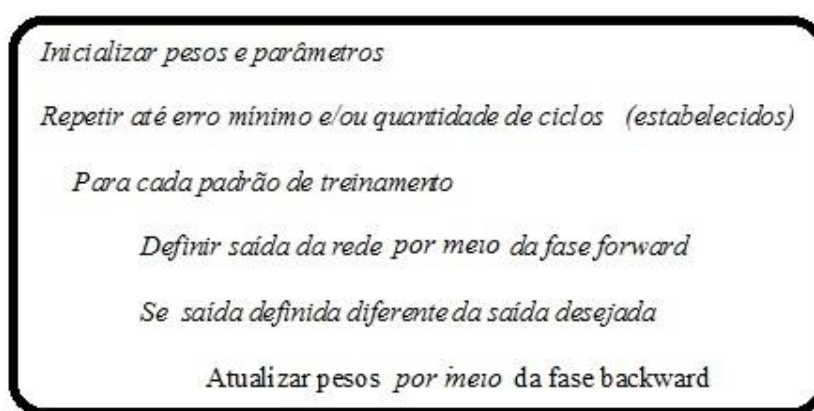


Figura 3.14: Algoritmo backpropagation.

Para o treinamento da rede é importante a definição de alguns parâmetros da estratégia do treinamento. Desta forma, é necessário estabelecer o objetivo do treinamento, a forma de utilização e a apresentação do conjunto de dados.

A definição do objetivo estabelece até quando o treinamento será realizado, ou seja, o ponto de parada do algoritmo de treinamento. O final do treinamento pode ocorrer estabelecendo um valor do desempenho a ser atingido, quantidade de ciclos de treinamento ou, ainda, a combinação dos dois fatores. O valor do desempenho depende da expectativa de utilização da rede.

A forma de utilização do conjunto de dados estabelece como a amostra é dividida para compor os conjuntos de treinamento e de teste da rede. O conjunto de treinamento é utilizado para o treinamento da rede. O conjunto de validação é uma subdivisão do conjunto de treinamento e é utilizado para verificar a eficiência da rede quanto a sua capacidade de generalização durante o treinamento, podendo ser empregado como critério de parada do treinamento. O conjunto de teste é utilizado após o encerramento do treinamento para

verificar o desempenho da rede sob as condições reais de utilização. Nas situações em que a representatividade da amostra é pequena, alguns pesquisadores utilizam toda a amostra obtida como conjunto de treinamento apenas. Nessas situações, o teste da rede é observado durante a utilização da mesma.

A forma como os dados são apresentados no treinamento pode ser individual ou em lote. Quando a apresentação é realizada em lote, todo o conjunto de exemplos do treinamento é apresentado antes de iniciar a fase de retropropagação para o ajuste dos pesos. Quando os exemplos são apresentados individualmente, a retropropagação é realizada após a apresentação de cada um.

### *3.3.11 – Desenvolvimento de sistemas conexionistas*

O processo de desenvolvimento com RNAs inicia com a análise cuidadosa sobre o problema para minimizar as ambiguidades e os erros nos dados. A seguir, deve-se realizar a coleta de dados relativos ao problema [Rezende, 2005]. Os dados coletados devem ser significativos e cobrir amplamente o domínio do problema; não devem cobrir apenas as operações normais ou rotineiras, mas também as exceções e as condições nos limites desse domínio [Carvalho, 1998].

Após a coleta, os dados devem ser separados em conjuntos de treinamento e de testes. Depois de determinados esses conjuntos, eles são geralmente colocados em ordem aleatória para a prevenção de tendências associadas à ordem de apresentação dos dados. Além disso, pode ser necessário pré-processar esses dados por meio de normalizações, escalonamentos e conversões de formato para torná-los mais apropriados à utilização na rede.

A próxima etapa é a definição da configuração da rede [Haykyn, 2001; Braga, 2007], que pode ser dividida em três etapas:

- a) Seleção do paradigma neural apropriado à aplicação;
  - b) Determinação da topologia da rede a ser utilizada - número de camadas, número de unidades em cada camada, etc.; e
  - c) Determinação dos parâmetros do algoritmo de treinamento e das funções de ativação.
- Este passo tem um grande impacto no desempenho do sistema resultante.

Existem metodologias na condução dessas tarefas. Normalmente essas escolhas são realizadas de forma empírica e requerem experiência dos projetistas.

O próximo passo é o treinamento da rede. Nesta fase, seguindo o algoritmo de treinamento escolhido, são ajustados os pesos das conexões. É importante considerar, nessa fase, alguns aspectos tais como a inicialização da rede, o modo de treinamento e o tempo de treinamento.

Uma boa escolha dos valores iniciais dos pesos da rede pode diminuir o tempo necessário para o treinamento. Normalmente, os valores iniciais dos pesos da rede são números aleatórios.

Quanto ao modo de treinamento, o ciclo pode ser completado a cada dado do conjunto (individual) ou após a apresentação de todos os dados do conjunto (batch). O modo individual aloca menor espaço no armazenamento de dados, além de ser menos suscetível ao problema de mínimos locais. Por outro lado, no modo batch tem-se uma melhor estimativa do vetor gradiente, o que torna o treinamento mais estável. A eficiência relativa dos dois modos de treinamento depende do problema que está sendo tratado.

Quanto ao tempo de treinamento, vários fatores podem influenciar a sua duração, porém sempre é necessário estabelecer algum critério de parada. O critério de parada do algoritmo backpropagation não é bem definido, podendo ser considerado um número máximo de ciclos, taxa de erro médio, capacidade de generalização da rede ou a combinação desses critérios. Em determinado instante do treinamento, a aprendizagem começa a degenerar e a rede se especializa no conjunto de dados do treinamento, perdendo a capacidade de generalização. Esse ponto pode ser outro critério de parada do treinamento.

O treinamento deve ser interrompido quando a rede apresentar uma boa capacidade de generalização e quando a taxa de erro for suficientemente pequena, ou seja menor que um erro admissível. Assim, deve ser encontrado um ponto ótimo de parada com erro mínimo e capacidade de generalização máxima. Esse ponto mínimo pode ser obtido a partir das curvas de erro dos conjuntos de treinamento e de validação. A curva do conjunto de treinamento é decrescente tendendo a zero. A curva do conjunto de validação é decrescente até um número de ciclos. Depois a curva de validação começa a crescer. Esse ponto é denominado mínimo global e é o ponto no qual a rede apresenta a melhor capacidade de generalização.

Com a conclusão do treinamento, pode-se realizar o teste da rede. Durante essa fase o conjunto de teste é utilizado para determinar o desempenho da rede com dados que não foram previamente utilizados. Em alguns casos, o teste é realizado durante as primeiras utilizações

da rede. O desempenho medido na fase de teste costuma ser um indicador do desempenho real no emprego da rede.

### **3.4 – Considerações Finais Deste Capítulo**

Neste capítulo foi realizada uma revisão sobre os conceitos gerais de reconhecimento de padrões e dos fundamentos das redes neurais artificiais.

A área de reconhecimento de padrões apresenta os fundamentos e as metodologias para o desenvolvimento de projetos de sistemas para a solução de problemas de classificação de padrões.

A capacidade de aprender por meio de exemplos e de generalizar a informação aprendida são os atrativos principais da solução de problemas utilizando RNAs. Outras características importantes são a capacidade de auto-organização e de processamento temporal que, aliadas àquelas citadas anteriormente, fazem das RNAs uma ferramenta computacional extremamente poderosa e atrativa para a solução de problemas complexos.

Diante do exposto neste capítulo, verifica-se que a abordagem empregando RNAs possibilita um mecanismo eficiente para a automatização da organização do conhecimento. O processo de aquisição do conhecimento pode ser realizado com a definição e o treinamento de uma RNA tendo por base características relevantes do universo de estudo. Após o treinamento, a RNA está capacitada para a tarefa de classificar os padrões no universo problema de estudo.

Devido a capacidade de classificação das RNAs, verifica-se a relevância do emprego desse artefato computacional para a tarefa de identificação e associação dos padrões a serem empregados neste trabalho.

O próximo capítulo apresenta uma breve revisão bibliográfica sobre a representação matemática de modelos e os métodos numéricos. São apresentados os conceitos necessários da representação matemática para a formalização de um modelo. O método das diferenças finitas é descrito por proporcionar a fundamentação necessária na representação da organização da apresentação do conteúdo. Nesse capítulo são mostrados os elementos necessários para a fundamentação da modelagem matemática do modelo proposto neste trabalho. Finalmente, são realizadas as considerações finais desse capítulo.

# CAPÍTULO 4

## REPRESENTAÇÃO MATEMÁTICA DE MODELOS E MÉTODOS NUMÉRICOS

### 4.1 - Introdução

O universo e seus componentes podem ser descritos de várias formas e linguagens. A forma dessa descrição em uma determinada linguagem pode ser entendida por todos que conhecem a linguagem. A precisão do entendimento da descrição apresentada dependerá do rigor da linguagem.

Linguagens com menor formalismo são úteis na comunicação entre os seres humanos. Entretanto a mensagem a ser transmitida pode ter ambiguidade na interpretação. A frase “Este senhor é um velho conhecido” exemplifica a ambiguidade de interpretação. Pode ser interpretada tanto como um senhor de idade conhecido, como sendo um senhor conhecido há muito tempo ou anteriormente.

Linguagens com maior formalismo não são de uso cotidiano entre as pessoas. Essas linguagens apresentam um universo restrito de palavras e uma organização rigorosa. Esse rigor possibilita uma univocidade na interpretação da mensagem ou do conceito apresentado.

O formalismo matemático é um exemplo de linguagem formal. A matemática possui símbolos e uma semântica que possibilita uma interpretação exata do que se deseja transmitir. Desta forma, quando se apresenta a sentença “ $2 + 3$ ”, ela será interpretada como uma soma entre dois números. O rigor no formalismo matemático tem se mostrado como uma ferramenta de linguagem universal e extremamente útil para a descrição de fenômenos e de objetos.

A definição de componentes em um plano possibilita ao leitor entender a distribuição dos componentes em relação ao problema apresentado. A relação entre os componentes de um plano pode ser descrita por funções. As funções tem especial utilidade na definição do comportamento da distribuição dos componentes. A função é uma espécie de linguagem que



descreve como estabelecer a posição de qualquer componente (ponto) em relação às variáveis consideradas no problema. Desta forma é possível representar graficamente um problema empregando uma função que estabelece a posição de cada componente ou ponto nessa representação.

Alguns problemas, com comportamento mais estável, são possíveis de representação com uma função única. Cada ponto do problema pode ser definido exatamente pela mesma função, independente dos outros pontos. Esse é o caso de retas, círculos, parábolas, curvas com variação uniforme, etc.

Entretanto, existem casos em que não existe uma relação única em todos os pontos. A sequência dos pontos do problema não apresentam uma ordem e as retas e as curvas do problema apresentam uma aparente desordem. Nesses casos, é necessário considerar os pontos vizinhos para definir ou estimar um determinado ponto. Nessas situações é possível estabelecer a linha de sequência dos pontos ou a superfície de estudo com o emprego de métodos numéricos iterativos. O método das diferenças finitas é um exemplo de método que possibilita descrever linhas e superfícies de um problema qualquer, que por sua complexidade de variação não é possível de descrição em uma única função.

A modelagem matemática, por sua univocidade é importante para o estabelecimento de um modelo para facilitar o seu entendimento.

Este capítulo apresenta uma breve revisão bibliográfica sobre a representação matemática de modelos e os métodos numéricos. São apresentados os conceitos necessários da representação matemática para a formalização de um modelo. O método das diferenças finitas é descrito por proporcionar a fundamentação necessária na representação da organização da apresentação do conteúdo. Nesse capítulo são mostrados os elementos necessários para a fundamentação da modelagem matemática do modelo proposto neste trabalho.

## **4.2 – Matemática e Representação de Modelos**

A Matemática estuda quantidades, medidas, espaços, estruturas e variações. Um trabalho matemático consiste em procurar por padrões, formular conjecturas e, por meio de deduções rigorosas a partir de axiomas e definições, estabelecer novos resultados [Silva, 2008].

A modelagem matemática é a área do conhecimento que estuda a simulação de sistemas reais com a finalidade de prever o comportamento dos mesmos, sendo empregada em diversos campos de estudo. Um modelo matemático é uma representação ou uma interpretação simplificada da realidade. O modelo pode ser uma interpretação de um fragmento de um sistema, segundo uma estrutura de conceitos mentais ou experimentais. Em teoria de modelos um modelo é uma estrutura composta por um conjunto universo e por constantes, relações e funções definidas no conjunto universo [Hodges, 1997].

De forma simples, a definição de um modelo inicia com a definição das variáveis necessárias para obter um determinado resultado (objetivo do modelo). O desenvolvimento do modelo consiste na estruturação das relações e das transformações das variáveis iniciais de tal forma a se obter o resultado esperado para o modelo. Matematicamente, o modelo pode ser expresso por uma fórmula ou uma função [Himonas, 2005; Silva, 2008; Dante, 2008]. Por exemplo, supondo um problema em que é desejado apresentar como resultado o dobro de um número. A variável de entrada é um número que pode ser identificada com a variável “ $x$ ”. A variável de saída é o dobro do número e pode ser identificada com a variável “ $y$ ”. A estruturação do modelo consiste em transformar a variável  $x$  em  $y$ , que é o dobro de  $x$ . O dobro de um número pode ser obtido somando o número a ele mesmo (com mesmo sinal e valor) ou multiplicando o número pelo número dois. A escolha de qualquer uma das funções permite estabelecer a estrutura para transformar a variável  $x$  na variável  $y$ . Após a definição das variáveis e da estrutura, é estabelecido o modelo para fornecer o dobro de um número. O modelo estabelecido no exemplo pode ser definido conforme a função representada na Equação (4.1) ou na Equação (4.2). A linguagem matemática fornecida pelos modelos, representados por essas equações, consolida e apresenta de forma unívoca o conceito do dobro de um número.

$$y = x + x \quad (4.1)$$

$$y = 2x \quad (4.2)$$

De maneira geral, a equação que descreve o modelo tem dois lados. O lado esquerdo representa a saída do modelo. O lado direito contém as variáveis de entrada para o modelo estruturadas para possibilitar a obtenção da saída definida pelo modelo [Himonas, 2005; Silva, 2008; Dante, 2008].

Assim como na linguagem natural, uma representação gráfica permite sintetizar o comportamento de uma função, além de possibilitar uma visualização do modelo. A representação gráfica é realizada em um plano no qual cada variável com seu domínio é representada por um eixo. A relação entre as variáveis é descrita pela função que define a posição de cada ponto ou elemento no plano. Este plano pode ter duas ou mais dimensões, dependentes da quantidade de variáveis consideradas no problema [Himonas, 2005; Silva, 2008; Dante, 2008]. A Figura 4.1 ilustra o gráfico da função “dobro”, definida pelas Equações (4.1) e (4.2).




Figura 4.1: Representação gráfica da função “dobro”.

Pode ser observado na Figura 4.1 que é possível verificar detalhes que poderiam demorar um pouco mais para serem constatados ou, ainda, nem serem tão facilmente constatado pela análise da fórmula. O gráfico mostra que a função dobro é uma reta, com uma determinada inclinação com afastamento crescente em relação ao eixo horizontal. Essa visualização é interessante tanto para matemáticos como para leigos. O gráfico é a forma intuitiva que qualquer pessoa pode visualizar um objeto ou fenômeno. A equação ou função é a forma exata de interpretar e representar essa visualização.

A construção do plano consiste em distribuir os eixos conforme a quantidade de variáveis consideradas no problema (uma para cada variável de entrada e uma para a variável de saída). Cada ponto é definido pela aplicação da função às variáveis de entrada, estabelecendo uma relação de coordenadas (ligação) entre as variáveis. A interligação dos pontos estabelece o aspecto visual do modelo a ser representado. A quantidade de variáveis do modelo define o gráfico como bidimensional, tridimensional ou multidimensional [Himonas, 2005; Silva, 2008; Dante, 2008].

Um modelo apresenta apenas uma visão ou uma parte do todo. Normalmente, para estudar um determinado fenômeno complexo, são criados vários modelos. Frequentemente, os modelos atingem grau de sofisticação suficiente para justificar as ferramentas computacionais

A formalização matemática consolida o modelo, facilita seu entendimento e possibilita a concepção e o desenvolvimento de novos trabalhos. Trabalhos apresentados em diferentes áreas do conhecimento mostram a capacidade de descrição da formalização matemática [Cruz, 2005; Barros, 2005; Teixeira, 2007; Vargas, 2008; Cereda, 2008; Barajas, 2010].

### **4.3 - Métodos Numéricos**

Na maioria das aplicações da ciência e da tecnologia existe algum tipo de emprego da matemática. Ao longo do desenvolvimento da humanidade, sempre existiu uma relação muito próxima entre a matemática de um lado e a ciência e a tecnologia do outro. Algumas de suas áreas surgiram e foram desenvolvidas na tentativa de solucionar problemas reais. Muitas vezes, alguns problemas reais não podem ser convenientemente solucionados por meio de fórmulas exatas. Entretanto, se for aceitável uma solução aproximada para esses problemas, os métodos numéricos são as ferramentas adequadas para a sua solução [Buffoni, 2002].

Os métodos numéricos correspondem a um conjunto de ferramentas ou métodos utilizados para se obter a solução de problemas matemáticos de forma aproximada. Esses métodos se aplicam a problemas que não apresentam uma solução exata, portanto precisam ser resolvidos numericamente [Buffoni, 2002]. Para resolver numericamente um problema matemático é preciso ter conhecimento de métodos numéricos. Esse conhecimento é importante para decidir se o problema requer a utilização ou não de um método numérico para a sua solução. Se a solução depender do emprego de métodos numéricos, deve ser verificado se existem métodos numéricos para se resolver o problema e qual o mais adequado para o problema.

#### *4.3.1 – Métodos de interpolação e aproximação de curvas*

Em experimentos, é normal o pesquisador precisar de aproximar funções matemáticas para os dados. Tais dados são originados dos testes e dos resultados obtidos da análise do problema e que, obviamente, não contém todos os dados possíveis. Com isto a curva do problema é esboçada a partir dos dados disponíveis (amostras). Entretanto, com base nos pontos disponíveis, o pesquisador precisa estimar qual é a situação provável dos outros

pontos, para acomodar o problema em uma determinada curva solução. Assim, existe a necessidade de estimar os pontos intermediários da curva por alguma técnica. Para estimar esses pontos, o pesquisador tem a sua disposição um conjunto de técnicas denominadas de métodos de interpolação e aproximação de curvas. Algumas abordagens possuem funções que passam exatamente pelo ponto, outras apresentam uma boa aproximação sem necessariamente passar pelos mesmos [Griffiths, 2006].

Muitos métodos como interpolação polinomial ou método das diferenças tem um maior ou menor ajuste dos pontos, dependendo da complexidade e da quantidade de pontos conhecidos. Entretanto, nesses métodos o que se observa é uma definição que depende dos pontos existentes. A inserção de um novo ponto que venha a modificar a curva resulta em refazer o método para definir novos valores gerais.

#### *4.3.1.1 – Interpolação*

Em matemática, denomina-se interpolação o método que permite construir um novo conjunto de dados a partir de um conjunto discreto de dados previamente conhecidos, obtidos a partir de uma amostragem ou de um experimento. Como, normalmente, esse conjunto de dados não possui continuidade, pode tornar irreal a representação teórica de um fenômeno real empiricamente observado. Pela interpolação, pode-se construir uma função que aproxime esses dados, conferindo-lhes, então, a continuidade desejada [Griffiths, 2006; Chapra, 2009].

Uma outra aplicação da interpolação é a aproximação de funções complexas por meio de funções mais simples. Supondo que exista uma função, mas que seja complicada demais para que seja possível ela ser avaliada de forma eficiente. Pode-se selecionar alguns dados da função complicada e tentar interpolá-los com uma função mais simples. Obviamente, quando for utilizada a função mais simples para calcular os novos dados, normalmente pode não ser obtido o mesmo resultado da função original, mas dependendo do domínio do problema e do método de interpolação utilizado, o ganho de simplicidade pode compensar o erro [Griffiths, 2006; Chapra, 2009].

A interpolação permite fazer a reconstituição (aproximada) de uma função, bastando para tanto conhecer apenas alguns pontos do problema. A função resultante da reconstituição com certeza passa pelos pontos fornecidos, e, em relação aos outros pontos, pode ser considerada um mero ajuste [Griffiths, 2006; Chapra, 2009]. Essa característica é muito

interessante na predição do comportamento de problemas reais, nos quais não é possível a disponibilidade de todos os dados. Essa situação é comum na maioria dos experimentos nos quais os dados são obtidos por amostragem.

Um exemplo do conceito de interpolação pode ser visualizado na Figura 4.2, em que os dados do experimento são representados no gráfico da Figura 4.2(a). Uma primeira forma de interpolação pode ser realizada admitindo-se que os valores de cada ponto serão constantes até o ponto seguinte. Nesse caso, os pontos serão interpolados como apresentado no gráfico da Figura 4.2(b). Uma outra forma de interpolar os dados é estabelecendo uma reta entre cada um dos pontos, como apresentado no gráfico da Figura 4.2 (c). As interpolações apresentadas nas Figuras 4.2(b) e 4.2(c) são do tipo linear ou polinômio de primeiro grau. O principal problema é que se os pontos forem poucos ou muito afastados entre si, a representação gráfica para uma determinada função não será muito bem representada por tal método. Nesse caso, costuma-se utilizar polinômios de graus mais elevados ou aplicar outros métodos.




Figura 4.2: Exemplos de interpolação simples.

Os métodos de interpolação polinomial consistem em obter um polinômio de interpolação  $Q_n(x)$  que passe por todos os  $n$  pontos do conjunto. Os métodos procuram estabelecer um polinômio de grau  $n$  ou menor que passe por todos os pontos conhecidos. A função estabelecida pelo polinômio assegura que qualquer função passará exatamente pelos pontos conhecidos e os pontos desconhecidos, serão estabelecidos por aproximação.

O método polinomial de Lagrange [Griffiths, 2006] para um conjunto de  $n + 1$  pontos de dados  $(x_i, y_i)$  em que  $i = 0, 1, 2, \dots, n$  conduzem a uma interpolação polinomial obtida pelo polinômio  $Q_n(x)$  da Equação (4.3).

$$Q_n(x) = L_0(x)y_0 + L_1(x)y_1 + \dots + L_n(x)y_n \quad (4.3)$$

Na Equação (4.3) cada  $L_i(x)$ , onde  $i = 0, 1, 2, \dots, n$  são os polinômios de lagrange de grau  $n$  definidos pela Equação (4.4).

$$L_i(x) = \frac{(x-x_0)(x-x_1)\dots(x-x_{i-1})(x-x_{i+1})\dots(x-x_{n-1})(x-x_n)}{(x_i-x_0)(x_i-x_1)\dots(x_i-x_{i-1})(x_i-x_{i+1})\dots(x_i-x_{n-1})(x_i-x_n)} \quad (4.4)$$

Uma desvantagem no método de Lagrange está no elevado número de operações necessárias para calcular uma interpolação. Cada polinômio é por si só de ordem  $n$ , e deve ser avaliado no respectivo grau  $n$ . Além disso, se for necessário calcular um novo ponto, os cálculos das interpolações anteriores não podem ser reaproveitados. Isto é, todos os cálculos para o novo ponto têm que serem refeitos integralmente desde o início.

#### 4.3.1.2 – Método das diferenças

Uma abordagem para estabelecer o polinômio de interpolação  $Q_n(x)$  que passará por  $n + 1$  pontos dados como  $(x_i, y_i)$ , onde  $i = 0, 1, 2, \dots, n$ , é a representação polinomial conforme a Equação (4.5).

$$Q_n(x) = C_0 + C_1(x-x_0) + C_2(x-x_0)(x-x_1) + \dots + C_n(x-x_0)(x-x_1)\dots(x-x_{n-1}) \quad (4.5)$$

As constantes  $C_0, C_1, C_2, \dots, C_n$  são definidas a partir de  $Q_n(x_i) = y_i$ , onde  $i = 0, 1, \dots, n$ , resultando nas Equações (4.6).

$$C_0 = y_0$$

$$C_1 = \frac{y_1 - C_0}{(x_1 - x_0)}$$

$$C_2 = \frac{y_2 - C_0 - C_1(x_2 - x_0)}{(x_2 - x_0)(x_2 - x_1)} \quad (4.6)$$

$$C_3 = \frac{y_3 - C_0 - C_1(x_3 - x_0) - C_2(x_3 - x_0)(x_3 - x_1)}{(x_3 - x_0)(x_3 - x_1)(x_3 - x_2)}$$

etc.

As constantes  $C_i$ s da Equação (4.6) podem ser facilmente resolvidas e substituídas na Equação (4.5). Se forem adicionados novos dados, o polinômio de interpolação de ordem mais elevada resultante, é derivado adicionando-se termos no polinômio de ordem mais baixa já encontrados. Esse método, diferente do método de Lagrange, tem um menor número de operações devido ao reaproveitamento dos cálculos anteriores para cada nova inserção de pontos. Assim, é possível construir toda uma função de forma dinâmica.

#### 4.3.1.3 – Funções spline

Os métodos de interpolação anteriormente descritos neste capítulo conduzem a polinômios de alta ordem. Em geral os polinômios são da ordem da quantidade total de pontos menos um. Isto pode levar a rotinas de maior complexidade. Se a continuidade das derivações mais altas das interpolações não for essencial, podem se utilizados métodos alternativos empregando polinômios de baixa ordem.

Os métodos “spline” são interessantes por apresentarem uma solução para ajuste da curva quando um novo ponto é inserido. A interpolação entre os pontos dados ocorre geralmente com polinômios de baixa ordem. Com isto consegue-se uma redução da complexidade matemática e um aumento da flexibilidade [Griffiths, 2006; Chapra, 2009].

O mais conhecido dos métodos “spline” consiste de funções spline cúbicas que são capazes de preservar a continuidade acima da segunda derivada [Griffiths, 2006; Chapra, 2009; Boyce, 2010]. Fisicamente, uma spline pode ser comparada a uma régua metálica flexível, inicialmente uma reta com apenas dois pontos e, a medida que são inseridos novos pontos, ela vai se ajustando aos mesmos e o processo se repete a medida que outro ponto é inserido entre dois pontos internos e assim por diante.

As equações diferenciais expressam a relação entre as variáveis em termos de suas derivadas. A necessidade de solucionar equações algébricas aparece em muitos problemas na modelagem matemática devido às leis físicas em engenharia e nas ciências. Frequentemente essas equações são expressas em termos das derivadas das variáveis ao invés das próprias variáveis. As equações diferenciais podem ser apresentadas em diferentes formas, entretanto, frequentemente elas consistem de funções de  $x$  e  $y$  [Griffiths, 2006; Chapra, 2009; Boyce, 2010].



A Figura 4.3 apresenta um exemplo para obter a interpolação utilizando três funções cúbicas  $f_1(x)$ ,  $f_2(x)$  e  $f_3(x)$ .




Figura 4.3: Interpolação utilizando funções spline cúbicas.

Como pode ser observado na Figura 4.3, existem 4 pontos e 3 funções cúbicas. Em geral quando tem-se  $n + 1$  pontos, são necessárias  $n$  funções que podem ser escritas conforme apresentado na Equação (4.7)

$$f_i(x) = A_{1i} + A_{2i}x + A_{3i}x^2 + A_{4i}x^3, \quad i = 1, 2, \dots, n \quad (4.7)$$

Os quatro coeficientes  $A_{ji}$  da Equação (4.7) são determinados conforme algumas condições necessárias na definição da solução. O resultado das derivadas levam ao estabelecimento do ponto a ser interpolado entre os dois pontos considerados no cálculo.

O método de interpolação utilizando spline é particularmente interessante na interpolação e no ajuste de curvas. Sua flexibilidade possibilita uma aproximação considerando as funções definidas entre os pontos. Essas características asseguram simplicidade e alta capacidade ao método.

#### 4.3.2 – Equações diferenciais

O objetivo da modelagem de problemas é encontrar um conjunto de equações matemáticas que descreva adequadamente um fenômeno e possibilite encontrar uma solução exata ou uma solução aproximada. A solução exata usualmente é devido a um método de solução analítica encontrado empregando-se os métodos algébricos e diferenciais; enquanto a

solução aproximada é resultante da aproximação da solução analítica empregando-se os métodos numéricos, que usualmente baseiam-se em operações aritméticas elementares.

Em matemática, uma equação diferencial é uma equação cuja incógnita é uma função que aparece na equação sob a forma das respectivas derivadas. As equações diferenciais são extremamente importantes para as ciências, pois informam como a variação de uma grandeza afeta outras grandezas relacionadas [Boyce, 2010].

As equações diferenciais dividem-se em dois tipos: equação diferencial ordinária (EDO) e equação diferencial parcial (EDP). A EDO contém apenas funções de uma variável e derivadas daquela mesma variável. A EDP contém funções com mais do que uma variável e suas derivadas parciais.

Uma equação diferencial parcial ou equação de derivadas parciais (EDP) é uma equação que consiste de várias funções incógnitas de várias variáveis independentes e essas funções são dependentes de suas derivadas.

Existem vários métodos para a solução de equações diferenciais. O método de Euler para equações diferenciais, faz parte dos métodos de passo único e é um dos métodos mais simples entre os métodos para a solução de equações diferenciais. Apesar da sua simplicidade, ele tem elementos suficientes para demonstrar a metodologia para a solução de tais problemas. Por outro lado, a precisão do método de Euler é bem menor do que outros métodos [Griffiths, 2006; Chapra, 2009; Boyce, 2010].

#### *4.3.2.1 – Método das diferenças finitas*

O método das diferenças finitas é um método de resolução de equações diferenciais que se baseia na aproximação de derivadas por diferenças finitas.

No método das diferenças finitas, as derivadas que ocorrem no domínio das equações diferenciais parciais são substituídas por sua diferença finita equivalente. Essas derivadas são aproximadas por várias combinações da variável desconhecida no grid de pontos em torno do local no qual a derivação ocorre [Griffiths, 2006; Boyce, 2010].

Para exemplificar o método de diferenças finitas, inicialmente deve ser considerado um plano de domínio da solução em um plano cartesiano bidimensional como apresentado na Figura 4.4.




Figura 4.4: Diferenças finitas no plano bidimensional.

Na Figura 4.4, o plano pode ser dividido em quadros regulares de tamanho  $k$  e  $h$ . A variável dependente  $U$  é uma função das duas variáveis independentes  $x$  e  $y$ . O ponto de definição da derivada é obtido pelos índices  $(i, j)$ , nos quais  $i$  é incrementado na direção  $x$  e  $j$  é incrementado na direção  $y$ .

Considerando  $h$  como o intervalo de variação no eixo  $x$ , a Equação (4.8) apresenta a diferença no centro do plano  $x$  da primeira derivada do ponto  $U_{i,j}$ . A primeira derivada pode ser melhor visualizada como molécula laplaciana, representada pela Figura 4.5 [Griffits, 2005].

$$\left( \frac{\partial U}{\partial x} \right)_{i,j} \cong \frac{1}{2h} [U_{i+1,j} - U_{i-1,j}] \quad (4.8)$$

$$\left( \frac{\partial U}{\partial x} \right)_{i,j} \cong \frac{1}{2h} \left[ \textcircled{-1} - \textcircled{0}_{i,j} - \textcircled{1} \right]$$

Figura 4.5: Molécula da diferença no centro do plano  $x$ .

Considerando  $k$  como o intervalo de variação no eixo  $y$ , a Equação (4.9) apresenta a diferença no centro do plano  $y$  da primeira derivada do ponto  $U_{i,j}$ . A primeira derivada pode ser melhor visualizada como molécula laplaciana, representada pela Figura 4.6 [Griffits, 2005].

$$\left(\frac{\partial U}{\partial y}\right)_{ij} \cong \frac{1}{2k} (U_{i,j+1} - U_{i,j-1}) \quad (4.9)$$

$$\left(\frac{\partial U}{\partial y}\right)_{ij} \cong \frac{1}{2k} \begin{pmatrix} 1 \\ 0 \\ -1 \end{pmatrix}_{ij}$$

Figura 4.6: Molécula da diferença no centro do plano y.

A derivação no centro do plano de domínio da solução é a combinação da derivada do plano horizontal  $h$  (Equação (4.8)) com a derivada do plano vertical  $y$  (Equação (4.9)) resultando na Equação (4.10).

$$\left(\frac{\partial U}{\partial x}\right)_{ij} + \left(\frac{\partial U}{\partial y}\right)_{ij} \cong \frac{1}{2h} (U_{i,j+1} - U_{i,j-1}) + \frac{1}{2k} (U_{i,j+1} - U_{i,j-1}) \quad (4.10)$$

Se não for indicado de outra forma, pode-se assumir que o intervalo de variação  $h$  no plano  $x$  é o mesmo valor do intervalo de variação  $k$  no plano  $y$ . Desta forma,  $h = k$  e a Equação (4.10) pode ser simplificada pela Equação (4.11) [Griffits, 2005].

$$\left(\frac{\partial U}{\partial x}\right)_{ij} + \left(\frac{\partial U}{\partial y}\right)_{ij} \cong \frac{1}{2h} [(U_{i,j+1} - U_{i,j-1}) + (U_{i,j+1} - U_{i,j-1})] \quad (4.11)$$

A derivada do plano bidimensional pode ser melhor visualizada como molécula laplaciana, representada pela Figura 4.7.

A organização da molécula, como apresentada na Figura 4.7, é utilizada em muitas aplicações para ajuste de curvas e interpolação de pontos. Na área de processamento digital de imagens [Pedrini, 2008; Gonzales, 2010] o conceito é utilizado em diversas técnicas como segmentação de imagens e filtros, por exemplo.

O exemplo apresentado na Figura 4.7 utiliza diferença no centro do plano bidimensional em derivadas de baixa ordem. O mesmo princípio pode ser aplicado em

versões de alta ordem, incluindo, se necessário, as diferenças backward e forward [Griffiths, 2006; Boyce, 2010].

$$\left( \frac{\partial U}{\partial X} + \frac{\partial U}{\partial Y} \right)_{ij} \approx \frac{1}{2h} \left[ \begin{array}{c} \textcircled{1} \\ \textcircled{-1} - \textcircled{0} - \textcircled{1} \\ \textcircled{-1} \end{array} \right]_{ij}$$

Figura 4.7: Molécula da diferença no centro do plano bidimensional.

Como as fórmulas de diferença no centro fornecem maior precisão em termos de inclusão e definição de pontos, é recomendada sua utilização sempre que possível. Com a utilização dessas formulas o  $ij$ -ésimo ponto do grid sempre está no centro da molécula. Esse é o ponto no qual a derivada deve ser aproximada e a molécula pode ser visualizada como uma sobreposição do grid sobre o domínio bidimensional da solução [Griffiths, 2006; Chapra, 2009].

#### 4.4 – Considerações Finais Deste Capítulo

Este capítulo apresentou os conceitos utilizados na representação matemática de modelos e os métodos numéricos, fundamentais para o desenvolvimento deste trabalho.

Foi discutida a importância do modelo matemático como ferramenta, compreensão, solução de problemas e consolidação da solução apresentada.

A análise numérica computacional é uma área da matemática na qual se encontram vários e diversificados métodos que constituem ferramentas para se determinar, exata ou aproximadamente, as soluções numéricas para os problemas modelados matematicamente. A busca de soluções aproximadas tem sido muito importante na resolução de problemas quando não existe possibilidade de resolução por técnicas exatas. A formalização matemática consolida o modelo, facilita o seu entendimento e possibilita a concepção e o desenvolvimento de novos trabalhos

O próximo capítulo apresenta o modelo proposto, descrito formalmente em sua estrutura e organização. Nesse capítulo são mostrados os elementos essenciais na definição do conteúdo multinível, a identificação do estudante, a associação do padrão proximal de aprendizagem e a organização da apresentação do conteúdo.

## **PARTE II**

---

### **Trabalho Proposto**

# CAPÍTULO 5

## MODELO PROPOSTO

### 5.1 - Introdução

O modelo proposto neste trabalho procura estabelecer a organização dos componentes a serem considerados no desenvolvimento de sistemas tutores inteligentes conexionistas.

A organização de um modelo para a transmissão de conhecimentos deve considerar três elementos básicos e suas relações: o professor como o agente mediador do conhecimento, o estudante como o agente interessado no conhecimento e o conteúdo que contém os conceitos, valores e significados a serem aprendidos.

A personalização do sistema procura reproduzir as diferentes ações de um professor para conduzir o ensino presencial. Especificamente, o trabalho pretende conduzir a forma diferenciada do professor apresentar o mesmo conceito diante das dificuldades do estudante durante a exposição do conceito.

Este trabalho propõe a organização de um conteúdo com diferentes maneiras de apresentar a organização e distribuição conceitual em contraposição aos conteúdos gerais que apresentam um formato único de apresentação.

Neste trabalho é proposta uma forma de identificar o perfil do estudante (considerando o tipo psicológico) e selecionar um padrão de apresentação mais adequado a ele. A inserção de reatividade proporciona ao sistema mecanismos para reajustar a trajetória didática de forma dinâmica, interagindo com o estudante.

Este capítulo apresenta o modelo proposto, descrito formalmente em sua estrutura e organização. Neste capítulo são mostrados os elementos essenciais na definição do conteúdo multinível, a identificação do estudante, a associação do padrão proximal de aprendizagem e a organização da apresentação do conteúdo.

## 5.2 – Composição do Modelo

Um aspecto interessante no desenvolvimento de um STI é a busca de aproximação do conteúdo ao perfil do estudante. Quanto mais o conteúdo estiver ajustado ao perfil do estudante, melhor é a empatia dele com o conteúdo apresentado. Para proporcionar essa aproximação do conteúdo é necessário estabelecer um modelo que defina as ações do processo.

O modelo apresentado neste trabalho propõe uma estruturação do conteúdo em vários níveis, uma identificação do perfil do estudante e a associação do perfil a um padrão que possibilite a personalização do conteúdo. O sistema identifica o perfil do estudante e seleciona um padrão que mais se assemelha com o perfil, estabelecendo uma zona proximal de desenvolvimento [Vygotsky, 1988]. Este padrão passa a ser utilizado como elemento base para as ações de personalização reativa na organização do conteúdo. A Figura 5.1 ilustra o sistema proposto.




Figura 5.1: Ilustração do sistema proposto.

Para operacionalizar o modelo do sistema proposto neste trabalho, é necessário definir a estruturação do conteúdo, o padrão proximal de aprendizagem e a forma de estabelecer a trajetória didática de apresentação do conteúdo.

### 5.2.1 - Conteúdo didático multinível

Um conteúdo personalizado pode ser considerado uma sequência diferenciada de conceitos. Essa diferença está no fato da sequência ser organizada de tal forma que se ajuste o



mais próximo possível ao perfil do estudante. A personalização do conteúdo pode oferecer, entre outras coisas, o melhor aproveitamento do assunto apresentado.

Como a concepção do conteúdo convencional é direcionada a um determinado perfil de estudante, normalmente ele é apresentado da mesma forma para qualquer estudante, sem considerar as eventuais diferenças. Desta forma, a possibilidade de ajuste do conteúdo para outros perfis de estudantes é quase nula. Assim, é necessário criar uma maneira que possibilite tratar o mesmo conteúdo de formas diferentes.

Um conteúdo ( $C$ ) convencional qualquer pode ser definido matematicamente pelo conjunto composto de uma sequência de conceitos ( $c_x$ ), como mostrado na Equação (5.1).

$$C = \sum_{x=1}^n c_x \quad (5.1)$$

onde:

$C$ : conteúdo;

$c_x$ : conceito do conteúdo ( $C$ ); e

$n$  : quantidade de conceitos.

Os conceitos são organizados em uma sequência lógica para conduzir ao conhecimento [Patten, 1986; Libâneo, 1994, Melo 2011; Melo, 2012]. A organização dessa sequência pode ser realizada de diferentes modos, desde a organização clássica até as organizações customizadas. A apresentação dessa sequência normalmente é precedida por uma introdução seguida de um teste inicial e, ao final, apresenta-se um resumo sobre os conceitos abordados e realiza-se o teste final [Horton, 2000].

A organização mais comum é a clássica, na qual a sequência do conteúdo desenvolvida é apresentada da mesma forma para qualquer estudante. De acordo com a Equação (5.1), o tutorial clássico apresentado na Figura 5.2 pode ser representado pela Equação (5.2).




Figura 5.2: Organização do tutorial clássico.

$$C = c_1 + c_2 + c_3 + \dots + c_n \quad (5.2)$$

onde:

$C$ : conteúdo;

$c_i$ : conceito do conteúdo (onde  $i = 1$  a  $n$ ); e

$n$  :  $i$ -ésimo conceito.

A organização customizada é uma forma de personalização do conteúdo porque possibilita a apresentação de partes do conteúdo conforme a necessidade do estudante. De acordo com a Equação (5.1), a trajetória do tutorial customizado apresentado na Figura 5.3 pode ser representada pela Equação (5.3).

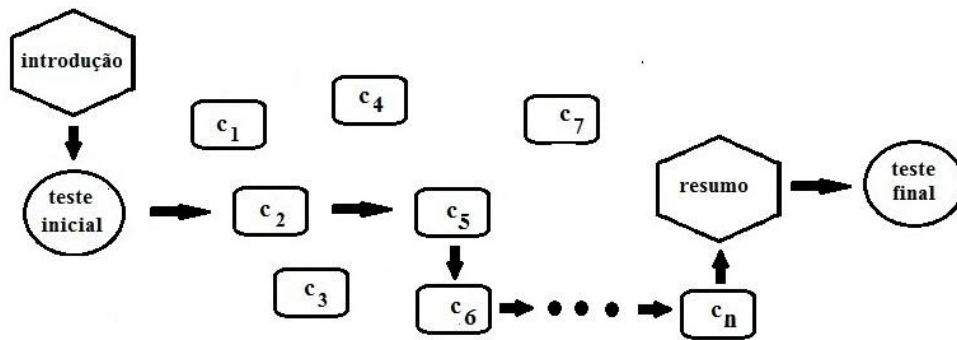


Figura 5.3. Exemplo de organização do tutorial customizado.

$$C = c_2 + c_5 + c_7 + \dots + c_n \quad (5.3)$$

onde:

$C$ : conteúdo;

$c_i$ : conceito do conteúdo (onde  $i = 1$  a  $n$ ); e

$n$  :  $i$ -ésimo conceito.

A sequência do conteúdo didático convencional é inadequada para o processo de personalização. Entretanto, se cada conceito for reescrito com diferentes níveis de apresentação, é possível compor o mesmo conteúdo utilizando diferentes combinações desses níveis [Melo 2011; Melo, 2012].

A reestruturação do conceito em diferentes formas de apresentação é denominada neste trabalho de conceito multinível. A estrutura desse conceito é semelhante à mediação docente, ou seja, após a apresentação do conceito, o professor procura uma maneira de estabelecer a condução do conhecimento conforme a reação do estudante [Melo 2011; Melo, 2012].

A diferença dos conceitos convencional e multinível é que este último é mais complexo e requer um esforço adicional para o seu desenvolvimento. No conceito multinível, inicialmente deve ser definida a quantidade de níveis de apresentação do conceito, e é estabelecido um nível para iniciar a apresentação. A referência para desenvolver os outros níveis é o nível inicial. Em todos os conceitos, os níveis idênticos devem ter o mesmo padrão de apresentação [Melo 2011; Melo, 2012].

O conceito multinível (cM) pode ser definido pela somatória dos vários níveis ( $N_y$ ), conforme mostrado na Equação (5.4).

$$cM = \sum_{y=1}^m N_y \quad (5.4)$$

onde:

$cM$  - conceito multinível;

$N_y$  – um nível do conceito multinível;

$y$  – índice do nível; e

$m$  - quantidade de níveis.

Considerando a definição de conteúdo conforme a Equação (5.1), o conteúdo multinível (CM) pode ser definido como sendo a somatória de vários conceitos multiníveis ( $cM_x$ ), como mostrado na Equação (5.5).

$$CM = \sum_{x=1}^n \left( \sum_{y=1}^m N_y \right)_x \quad (5.5)$$

onde:

$CM$  - conteúdo multinível;

$N_y$  – um nível do conceito multinível;

$y$  – índice do nível;

$m$  - quantidade de níveis;

$x$  – índice do conceito; e

$n$  - quantidade de conceitos;

Substituindo-se a expressão da definição de conceito multinível (cM) da Equação (5.4), a definição do conteúdo multinível da Equação (5.5) pode ser simplificada pela Equação (5.6).

$$CM = \sum_{x=1}^n cM_x \quad (5.6)$$

onde:

*CM* - conteúdo multinível;

*cM* - conceito multinível;

*x* – índice do conceito; e

*n* - quantidade de conceitos;

As diferentes combinações dos níveis de conceitos do conteúdo multinível possibilitam a apresentação personalizada do conteúdo para cada perfil de estudante. Além disso, possibilita as intervenções mediativas para os diferentes momentos do estudo. Desta forma, é possível que, no mesmo conteúdo, cada conceito multinível seja apresentado de forma distinta. A apresentação desse conceito pode ser realizada utilizando-se um ou mais níveis, conforme a necessidade de estabelecer a condução do conhecimento.

### 5.2.2 - Padrão proximal de aprendizagem

O objetivo da personalização é proporcionar ao estudante o melhor aproveitamento do assunto apresentado. Após a definição do conteúdo multinível, para prosseguir no processo de personalização, é necessário definir como identificar o perfil do estudante e como organizar o conteúdo de forma mais adequada para esse perfil.

Para identificar o perfil do estudante, o método proposto neste trabalho estabelece três padrões de classificação. Estes padrões são: pessoal, habilidades e pré-conhecimento do conteúdo.

O padrão pessoal são características obtidas a partir de um teste psicológico. Um teste inicial contendo questões sobre o conteúdo a ser estudado define o padrão de pré-conhecimento do conteúdo a ser apresentado. O padrão de habilidades é definido a partir de um questionário sobre a situação sociocultural e a familiarização com as tecnologias.

A região de abrangência de uma dimensão é definida por um conjunto de itens em um teste psicológico. Desta forma, uma dimensão ( $\Psi_d$ ) qualquer pode ser representada pela soma dos valores das respostas ( $rd_i$ ) de cada item para a dimensão considerada. A representação da dimensão psicológica é mostrada na Equação (5.7).

$$\Psi_d = \sum_{i=1}^n rd_i \quad (5.7)$$

onde:

$\Psi$  – padrão pessoal;  
 $d$  - uma dimensão do teste psicológico;  
 $i$  - item do teste psicológico;  
 $rd$  - valor da alternativa do item  $i$ ; e  
 $n$  - quantidade de itens do teste.

O conjunto das dimensões ( $\Psi_d$ ) consideradas no teste psicológico forma o padrão pessoal ( $\Psi$ ) como mostrado na Equação (5.8).

$$\Psi = \sum_{d=1}^n \Psi_d \quad (5.8)$$

onde:

$\Psi$  – padrão pessoal;  
 $d$  - uma dimensão do teste psicológico; e  
 $n$  - quantidade de itens do teste.

Os conhecimentos procedimentais formam o padrão de habilidades ( $A$ ) que é uma avaliação do contexto sociocultural do estudante. Essa avaliação pode conter itens como idade, sexo, manuseio de tecnologias, etc. Esse padrão complementa o padrão pessoal ( $\Psi$ ) com o objetivo de estabelecer elementos mais próximos da realidade do estudante e sua interação com o conteúdo. O padrão de habilidades ( $A$ ) é uma região definida pela soma de cada item do teste de habilidades ( $a_i$ ) ponderado pelo respectivo peso ( $w_i$ ) atribuído a cada resposta, conforme mostrado na Equação (5.9).

$$A = \sum_{i=1}^n a_i w_i \quad (5.9)$$

onde:

$A$  – padrão de habilidades;  
 $a$  - item do teste de habilidades;  
 $w$  - valor da resposta do item;

$i$  – índice do item; e  
 $n$  - quantidade de itens do teste.

O padrão do pré-conhecimento (K) do conteúdo é um pré-teste aplicado antes de apresentar o conteúdo. O objetivo desse pré-teste é verificar o grau de conhecimento do estudante sobre o conteúdo a ser apresentado. Para cada conceito do conteúdo é formulada uma questão no pré-teste. O padrão (K) é uma nota obtida pela soma das respostas de cada questão ( $Q_i$ ) do pré-teste ponderado pelo respectivo peso ( $w_i$ ), como mostrado na Equação (5.10).

$$K = \sum_{i=1}^n Q_i w_i \quad (5.10)$$

onde:

$K$  – padrão de pré-conhecimento do conteúdo;  
 $Q$  - questão do pré-teste;  
 $w$  - valor da resposta da questão;  
 $i$  – índice da questão; e  
 $n$  - quantidade de questões do teste.

O perfil do estudante ( $\Omega$ ) é uma região multidimensional resultante da intersecção das regiões dos padrões psicológico ( $\Psi$ ), habilidade (A) e do padrão do pré-conhecimento do conteúdo (K), como apresentado na Equação (5.11).

$$\Omega = \Psi \cap A \cap K \quad (5.11)$$

onde:

$\Omega$  – perfil do estudante;  
 $\Psi$  – padrão pessoal;  
 $A$  – padrão de habilidades; e  
 $K$  – padrão de pré-conhecimento do conteúdo.

Considerando o padrão psicológico ( $\Psi$ ), cada estudante tem um perfil próprio,  $uw$  pode ser único. Porém, se for considerado apenas esse parâmetro, a grande variedade de padrões psicológicos ( $\Psi$ ) resulta em uma grande quantidade de perfis de estudantes.

Entretanto, conforme a finalidade de utilização, um padrão psicológico ( $\Psi$ ) pode ser aproximado a outro padrão ( $\Psi$ ) semelhante. Utilizar outros padrões como complemento do padrão psicológico ( $\Psi$ ) pode melhorar a abrangência da região do perfil do estudante. Com o crescimento dessa região, aumenta a probabilidade de regiões comuns. Neste sentido, os padrões de habilidades (A) e de pré-conhecimento do conteúdo (K) possibilitam maior abrangência da região de classificação do perfil do estudante. Aumentando a abrangência da região de classificação é possível classificar por aproximação um maior número de perfis de estudante na mesma região.

No conteúdo multinível (CM), um caminho para a personalização é a definição do quanto o estudante prefere cada um dos níveis do conceito desse conteúdo. Para cada um desses níveis do CM, a preferência pelo nível ( $PL_i$ ) é uma função densidade de probabilidade [Walpole, 2007; Agresti, 2009] como mostrado na Equação (5.12).

$$PL_i = 1 - \sum_{j=1}^{n-1} PL_j \quad (5.12)$$

onde:

$PL_i$  - probabilidade de preferência para o nível  $i$  do conceito multinível;

$PL_j$  - probabilidade dos outros níveis do conceito multinível; e

$n$  - quantidade de níveis do conceito multinível.

A Equação (5.13) define o padrão de aprendizagem (L) como um vetor com as probabilidades de preferência para cada nível ( $PL_i$ ).

$$L = [PL_1, PL_2, PL_3, \dots, PL_n] \quad (5.13)$$

onde:

$L$  - padrão de aprendizagem;

$PL_i$  - probabilidade de preferência pelo nível  $i$  do conceito multinível; e

$n$  - quantidade de níveis do conceito multinível.

Com o perfil do estudante ( $\Omega$ ) e o padrão de aprendizagem (L) definidos, é necessário estabelecer uma associação entre eles. Neste trabalho, a proposta de organização

personalizada do conteúdo didático consiste em classificar o perfil do estudante ( $\Omega$ ) da Equação (5.11) e associá-lo com o padrão de aprendizagem (L) da Equação (5.13).

A partir do perfil do estudante ( $\Omega$ ) obtido pela Equação (5.11) é possível encontrar por aproximação um padrão de aprendizagem (L) que passa a ser o padrão proximal de aprendizagem ( $L_\Omega$ ).

O padrão de aprendizagem (L) é estabelecido diretamente a partir da observação de um estudante, como mostrado na Equação (5.13). O padrão proximal de aprendizagem ( $L_\Omega$ ) é obtido da mesma forma que o L, porém  $L_\Omega$  é estimado por aproximação considerando o perfil do estudante ( $\Omega$ ).

O padrão proximal de aprendizagem  $L_\Omega$  procura implementar o conceito da zona proximal de desenvolvimento [Vygotsky, 1988]. Esse padrão é a base para o sistema adequar a apresentação do conteúdo para que o estudante tenha um melhor aproveitamento na aprendizagem.

Se o padrão de aprendizagem (L) conduziu a um melhor aproveitamento para o estudante com perfil  $\Omega$ , conseqüentemente o padrão proximal de aprendizagem  $L_\Omega$  poderá resultar em um melhor aproveitamento do conteúdo para outro estudante com perfil  $\Omega$  semelhante.

A Figura 5.4 mostra alguns exemplos de padrões proximais de aprendizagem  $L_\Omega$  de diferentes estudantes. Esta figura exemplifica os padrões  $L_\Omega$  para um conteúdo multinível (CM) com 5 níveis. As probabilidades  $P(a)$ ,  $P(b)$ ,  $P(c)$ ,  $P(d)$  e  $P(e)$  para cada nível formam o vetor do padrão  $L_\Omega$ .




Figura 5.4: Exemplos de padrões proximais de aprendizagem  $L_\Omega$ .

### 5.2.3 - Ajuste reativo da trajetória didática

O padrão proximal de aprendizagem ( $L_\Omega$ ) não é suficiente para definir toda a sequência dos níveis para uma apresentação personalizada do conteúdo. Esse padrão é geral e



não possibilita a reatividade à apresentação do conteúdo. Além disso, não é possível representar com uma única função toda a sequência do conteúdo personalizado devido à reatividade do estudante nos diferentes momentos de apresentação de cada nível da sequência.

Um dos motivos pelos quais o padrão proximal de aprendizagem ( $L_{\Omega}$ ) não possibilita a personalização ocorre pela forma como esse padrão pode ser tratado. Por exemplo, quando na organização da apresentação for decidido mostrar apenas o nível com maior probabilidade de preferência do estudante, o conteúdo é o mesmo para todos os estudantes com  $L_{\Omega}$  maximizado nesse nível. Isso ocorre para o estudante independente do percentual probabilístico do nível maximizado. Essa situação é semelhante à apresentação do conteúdo clássico mostrado na Equação (5.1), porém no nível maximizado. Esse formato não pode ser considerado uma personalização na apresentação dos conteúdos.

Uma alternativa para tornar o conteúdo multinível (CM) personalizado pode ser o sorteio entre as probabilidades de cada nível. Esta ação pode resultar em um conteúdo diferente para cada estudante, mas pode apresentar incoerências na apresentação. Um exemplo de incoerência é quando o sistema indica o estudo do conceito no nível de maior dificuldade quando o estudante errou o teste no nível de menor dificuldade.

A apresentação personalizada do conteúdo deve ser reativa, além de estar relacionada a um padrão proximal de aprendizagem ( $L_{\Omega}$ ). A reatividade deve acontecer nos diferentes momentos da apresentação com o objetivo de corrigir possíveis problemas.

A reatividade não permite representar a sequência da apresentação personalizada em uma única função, como ocorre com a apresentação do conteúdo clássico mostrado na Equação (5.1). Desta forma, a função que representa a organização do conteúdo considerando a reatividade pode ser obtida utilizando-se derivadas parciais pelo método das diferenças finitas. Com este método, a correção da trajetória didática pode ser obtida pela derivada do padrão proximal de aprendizagem ( $L_{\Omega}$ ) em relação a um padrão que possa ajustar a trajetória didática da apresentação. O resultado dessa derivada possibilita a apresentação de um conteúdo coerente e reativo com o perfil do estudante ( $\Omega$ ) em cada ponto da apresentação. Esse tipo de apresentação do conteúdo pode ser caracterizado como personalizado tanto nos planos global como local.

A reação diante da apresentação de um conteúdo varia conforme o perfil individual de cada estudante. Diante dessa reação, o professor pode modificar a forma de apresentar o assunto.

Alguns pontos devem ser estabelecidos para representar o processo de decisão para a correção da trajetória didática na apresentação personalizada utilizando o conteúdo multinível (CM).

Na navegação em um conteúdo convencional (C), a tendência é que o estudante siga a trajetória didática definida pela sequência estabelecida pelo professor. Essa sequência apresenta apenas um nível de cada conceito. Isto ocorre porque esse conceito é o único nível disponível. A sequência no conteúdo convencional é ilustrada na Figura 5.5, na qual é possível observar que em todos os conceitos a trajetória passa por um único ponto que é o nível  $N_0$ .




Figura 5.5: Sequência da trajetória didática do conteúdo convencional.

No conteúdo multinível (CM), a trajetória didática tende a ser semelhante à trajetória do conteúdo convencional. Porém, conforme a reação do estudante após a apresentação de um nível qualquer, o professor pode efetuar uma variação nessa trajetória. Essa variação considera o padrão proximal de aprendizagem ( $L_\Omega$ ) e pode conduzir o estudante a outro nível do conceito, conforme pode ser observado na Figura 5.6.




Figura 5.6: Sequência da trajetória didática no conteúdo multinível.

No sistema proposto neste trabalho, o conceito multinível foi estruturado em cinco níveis: três níveis principais e dois auxiliares. Os níveis principais são médio, facilitado e avançado. Os níveis auxiliares são Exemplos e Perguntas e Respostas Frequentes (FAQs). O

nível médio é o nível de referência para os outros níveis e em cada conceito é o primeiro nível a ser apresentado ao estudante. O sistema proposto considera que os níveis principais e auxiliares estão posicionados no plano xy como mostrado na Figura 5.7.




Figura 5.7: Distribuição do conceito multinível.

Considerando como referência o nível  $LP_{i,j}$  na distribuição do conceito multinível (cM), a formalização matemática para a correção da trajetória didática pode ser estabelecida como mostrado na Figura 5.8.

A trajetória didática do estudante tende a seguir a posição  $LP_{i,j}$ . Entretanto, conforme a reação do estudante após a apresentação de um determinado nível, o professor pode variar a trajetória na direção de outro nível. O próximo nível a ser apresentado ao estudante é uma região localizada entre o padrão ( $L_{\Omega}$ ) desse estudante e a região definida pelo professor para a situação.




Figura 5.8: Formalização do conceito multinível

Para ilustrar a ação de correção da trajetória no plano de distribuição do conceito multinível (cM), pode ser considerada a variação no eixo dos níveis principais diante da reação do estudante após a apresentação do nível na posição  $LP_{i,j}$ . Se o estudante tem

difficuldade de entendimento, o professor pode apresentar níveis mais fáceis na direção de  $LP_{i-1,j}$ . Caso contrário, o professor pode apresentar níveis mais avançados na direção de  $LP_{i+1,j}$ . As variações também podem ocorrer no eixo dos níveis auxiliares.

Caso seja necessário inserir um novo nível no plano de distribuição do conceito multinível (cM), ele será posicionado entre os níveis existentes. O formalismo proposto neste trabalho possibilita corrigir a trajetória didática considerando a nova posição.

Pelo método das diferenças finitas, a correção da variação da trajetória didática pode ser definida como sendo uma variação entre o nível de referência e o nível que o estudante pode ser conduzido conforme sua reatividade.

A correção no eixo dos níveis principais, ilustrada na Figura 5.9, é formalizada matematicamente pela Equação (5.14).

$$\left( \frac{\partial U}{\partial X} \right)_{ij} \approx \frac{1}{2m} \left[ \begin{array}{c} \textcircled{-1} \\ \textcircled{0} \\ \textcircled{1} \end{array} \right]_{ij}$$

Figura 5.9: Correção no eixo dos níveis principais.

$$\left( \frac{\partial LP}{\partial x} \right)_{ij} \cong \frac{1}{2m} (LP_{i+1,j} - LP_{i-1,j}) \quad (5.14)$$

onde:

$LP$  - posição do nível;

$i,j$  - abscissa e ordenada do nível  $LP$  respectivamente; e

$m$  - intervalo de variação dos níveis principais.

A correção no eixo dos níveis auxiliares, ilustrada na Figura 5.10 é formalizada matematicamente pela Equação (5.15).

$$\left( \frac{\partial U}{\partial Y} \right)_{ij} \approx \frac{1}{2a} \left[ \begin{array}{c} \textcircled{1} \\ \textcircled{0} \\ \textcircled{-1} \end{array} \right]_{ij}$$

Figura 5.10: Correção no eixo dos níveis auxiliares.

$$\left(\frac{\partial LP}{\partial y}\right)_{ij} \cong \frac{1}{2a} [LP_{i,j+1} - LP_{i,j-1}] \quad (5.15)$$

onde:

$LP$  - posição do nível;

$i, j$  - abscissa e ordenada do nível  $LP$ , respectivamente; e

$a$  - intervalo de variação dos níveis auxiliares.

Combinando as Equações (5.14) e (5.15), o próximo nível do conceito a ser apresentado ao estudante é formalizado matematicamente pela Equação (5.16).

$$\left(\frac{\partial LP}{\partial x}\right)_{ij} + \left(\frac{\partial LP}{\partial y}\right)_{ij} \cong \frac{1}{2m} (LP_{i,j+1} - LP_{i,j-1}) + \frac{1}{2a} (LP_{i,j+1} - LP_{i,j-1}) \quad (5.16)$$

onde:

$LP$  - posição do nível;

$i, j$  - abscissa e ordenada do nível  $LP$ , respectivamente;

$m$  - intervalo de variação dos níveis principais; e

$a$  - intervalo de variação dos níveis auxiliares.

Considerando na Equação (5.16)  $a = m$ , a correção da trajetória didática como ilustrado na Figura 5.11 é formalizada matematicamente pela Equação (5.17).

$$\left(\frac{\partial U}{\partial X} + \frac{\partial U}{\partial Y}\right)_{ij} \cong \frac{1}{2m} \begin{bmatrix} & 1 & \\ -1 & 0 & 1 \\ & -1 & \end{bmatrix}_{ij}$$

Figura 5.11: Correção da trajetória didática.

$$\left(\frac{\partial LP}{\partial x}\right)_{ij} + \left(\frac{\partial LP}{\partial y}\right)_{ij} \cong \frac{1}{2m} [LP_{i,j+1} - LP_{i,j-1}] + [LP_{i,j+1} - LP_{i,j-1}] \quad (5.17)$$

onde:

*LP* - posição do nível;

*i,j* - abscissa e ordenada do nível *LP* respectivamente; *e*

*m* - intervalo de variação dos níveis principais e auxiliares.

### 5.3 - Estrutura do Sistema para a Personalização Reativa

A estrutura do modelo do sistema proposto é composta pelo conteúdo, pelo mecanismo de identificação do estudante e pelo mecanismo de navegação. O conteúdo contém o conhecimento a ser transmitido. O mecanismo de identificação do estudante fornece os dados para a personalização do conteúdo. E o mecanismo de navegação estabelece uma forma de organizar os conceitos para a apresentação do conteúdo.

Neste trabalho, o conteúdo proposto no sistema é um conteúdo multinível. Este conteúdo pode ser estabelecido em quantos níveis de conceitos forem necessários para proporcionar os recursos de apoio ao processo de mediação didática. A apresentação de cada conceito sempre deve iniciar em um determinado nível, que é o nível base do conteúdo multinível. Após a apresentação do nível base, podem ser apresentados outros níveis do conceito ou ser apresentado o nível base do próximo conceito.

O processo de apresentação do conteúdo é realizado por um mecanismo de navegação, ou navegador. O navegador possibilita estabelecer a trajetória de apresentação didática no conteúdo multinível. Para estabelecer a trajetória didática, o navegador propicia meios para assegurar a sequência dos conceitos e a seleção de quais níveis de cada conceito serão apresentados. A Figura 5.12 ilustra a estrutura do navegador com um conteúdo multinível de 5 níveis. Os pontos de teste após cada nível são utilizados como um dos elementos de decisão do mecanismo de navegação.




Figura 5.12: Estrutura do conteúdo multinível do sistema proposto neste trabalho.

Conforme pode ser observado na Figura 5.12, após a apresentação de cada nível é apresentado um teste objetivo. Para proporcionar opções de ação, o teste apresenta alternativas com diferentes graus de acerto. Desta forma, mesmo quando a aprendizagem não ocorrer de forma total, existe a opção de resposta com nível intermediário de acerto (“meio certa”) na lista de alternativas. Esta idéia expande as opções totalmente certa, totalmente errada e de desconhecimento total (“não sei”), possibilitando um controle mais refinado do resultado. A Figura 5.13 apresenta um exemplo de teste com diferentes graus de acerto. No exemplo a opção "a" é meio certa, a opção "b" é correta e a opção "c" é errada.

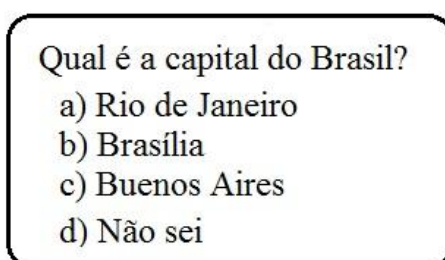


Figura 5.13: Exemplo de questão com diferentes graus de acerto

O método proposto neste trabalho utiliza uma rede neural Perceptron de multiplas camadas (MLP, do ingles *Mult Layer Perceptron*) para definir o perfil do estudante ( $\Omega$ ) da Equação (5.11) e estimar o padrão proximal de aprendizagem ( $L_\Omega$ ) da Equação (5.13), como ilustrado na Figura 5.14. A RNA é treinada com dados selecionados da observação de estudantes que apresentaram resultados positivos na capacidade de organizar o estudo individual. Ao final do treinamento, a RNA estará capacitada a exercer a função de classificar o estudante em um padrão  $\Omega$  e indicar o padrão proximal de aprendizagem  $L_\Omega$ .




Figura 5.14: Estrutura para definir o padrão proximal de aprendizagem  $L_\Omega$

Após a apresentação de um nível do conceito, o estudante apresenta uma determinada reação. Esta reação é uma situação local, específica daquele momento da apresentação. A reação do estudante pode ser o entendimento total ou parcial do que foi apresentado, interesse

de saber algo mais, ver algum exemplo, etc. A reatividade é a ação do professor ou de um sistema para atender o estudante em cada situação local. A reatividade propicia alternativas de alterações na trajetória didática.

Para desenvolver o mecanismo de reatividade no sistema, foi realizado um estudo com especialistas em docência (professores) sobre a atuação deles diante de cada situação possível ao final da apresentação de cada nível no conteúdo multinível. Desse estudo foram elaboradas as regras de ação local, denominadas regras de especialistas [Russel, 2004]. As regras tratam as situações existentes de acordo com a estrutura do conteúdo multinível, orientando as chances de escolha de níveis diante do desempenho do estudante após a apresentação de um determinado nível. A Tabela 5.1 apresenta o conjunto de regras de indicações locais.

Tabela 5.1: Regras de indicações locais.

Nível de origem	Resposta do teste	Próximo nível (percentual de indicação)				
		Facilitado	Avançado	FAQs	Exemplos	Próximo
<b>Facilitado</b>	<i>Errada</i>	0	5,74	35,74	51,85	6,67
	<i>Não sabe</i>	0	5	33,76	54,26	6,98
	<i>Meio certa</i>	0	11,31	27,44	37,25	24
	<i>Certa</i>	0	27,24	15,3	17,15	40,31
<b>Médio</b>	<i>Errada</i>	50,48	5,37	18,42	22,65	3,08
	<i>Não sabe</i>	52,59	3,89	19,56	20,38	3,58
	<i>Meio certa</i>	26,48	12,45	19,38	36,77	4,92
	<i>Certa</i>	3,33	45,38	16,15	17,49	17,65
<b>Avançado</b>	<i>Errada</i>	27,59	0	26,48	36,5	9,43
	<i>Não sabe</i>	35,19	0	23,7	33,15	7,96
	<i>Meio certa</i>	14,81	0	28,89	34,45	21,85
	<i>Certa</i>	4,39	0	14,67	17,98	62,96
<b>Faqs</b>	<i>Errada</i>	46,11	7,59	0	37,78	8,52
	<i>Não sabe</i>	45,74	7,38	0	39,29	7,59
	<i>Meio certa</i>	27,78	12,07	0	42,37	17,78
	<i>Certa</i>	6,27	28,56	0	20,15	45,02
<b>Exemplos</b>	<i>Errada</i>	49,87	7,59	31,98	0	10,56
	<i>Não sabe</i>	50,11	6,67	33,78	0	9,44
	<i>Meio certa</i>	28,16	13,83	38,94	0	19,07
	<i>Certa</i>	4,68	25,74	20,93	0	48,65



Na Tabela 5.1, cada regra indica o percentual de indicação do professor diante de uma situação local no conteúdo multinível. A definição das regras pelo professor foi realizada conforme a experiência de sala de aula, na qual os professores utilizam estratégias de ensino baseadas nos recursos disponíveis e no desempenho da turma. Por exemplo, é frequente o professor facilitar a explicação, ou citar um exemplo, de um tema quando os estudantes não o entendem na primeira explicação.

No sistema proposto neste trabalho, a Equação (5.16) é implementada combinando o padrão proximal de aprendizagem ( $L_{\Omega}$ ) com as regras dos especialistas. A seleção da regra apropriada à reatividade do estudante é realizada apresentando um exercício de múltipla escolha ao final da apresentação de cada nível. Esse exercício é o teste de retenção do nível e é o sensor do sistema para identificar a reação do estudante.

A inserção das regras de especialistas em conjunto com a RNA caracteriza um sistema híbrido. Essas regras no sistema proposto têm a mesma estrutura do padrão proximal (probabilidades para cada nível). Porém, cada regra é específica para cada situação no teste de retenção realizado após a apresentação do conteúdo. A Figura 5.15 mostra o exemplo de um conjunto de regras de especialistas para um nível qualquer. Nessa figura, cada coluna representa o conjunto de probabilidades de apresentação dos níveis dependendo da avaliação do teste de retenção.




Figura 5.15: Exemplo de regras de especialistas.

Para personalizar o conteúdo, são necessários os padrões global e local. O padrão global ( $L_{\Omega}$ ) é estabelecido uma única vez antes do início da apresentação. O padrão local (regras dos especialistas) é redefinido ao final da apresentação de cada nível conceitual. A próxima etapa na organização do conteúdo é definir o próximo nível do conceito a ser apresentado.

O ajuste da organização da sequência do conteúdo mostrado na Equação (5.13), pode ser realizado combinando o padrão global (estudante) com o padrão local (professor). Para

definir o próximo passo no tutor, o sistema inteligente dispõe do perfil do estudante (indicações globais), das regras simbólicas (indicações locais), do nível visitado e da resposta do exercício após a visitação do nível. O tutor inteligente, na perspectiva da ZPD, funciona como mediador no processo de desenvolvimento da aprendizagem.

De acordo com o nível e a resposta do exercício, o sistema recupera, do conjunto de regras simbólicas, a regra de indicações probabilísticas para a situação local específica. Cada probabilidade da regra é multiplicada pela probabilidade correspondente do perfil do estudante, gerando uma probabilidade resultante. Com a aplicação das regras simbólicas, a probabilidade resultante fica isenta de incoerências e as indicações para cada ponto são reforçadas ou atenuadas.

De posse da distribuição de probabilidade resultante, o sistema escolhe aleatoriamente (baseado em tal distribuição) no sentido de indicar o próximo nível a ser visitado ou a passagem para o próximo conceito. O próximo nível do conteúdo a ser apresentado pode ser obtido utilizando-se a técnica de Monte Carlo [Russel, 2004]. Nesta técnica é realizado um sorteio probabilístico para a escolha de um nível. As maiores probabilidades têm maior chance de serem escolhidas, porém as probabilidades menores também podem ser selecionadas.

A Figura 5.16 ilustra o processo de decisão da navegação inteligente. A coluna da esquerda é o perfil do estudante e a da direita a regra para uma situação local. Para decidir o próximo nível a ser apresentado, o sistema, calcula o produto das duas colunas e define uma distribuição probabilística resultante. Nessa distribuição (graficamente representada por uma roleta) é sorteado um ponto na região que será o próximo nível da apresentação.




Figura 5.16: Mecanismo do padrão de decisão probabilística.

Pode ser observado na Figura 5.16 que o nível avançado foi suprimido pela regra local e reforçado (maior chance) o nível médio/próximo. Ainda pode ser observado, nessa figura,

que o nível com menor chance é o FAQs. Para complementar a probabilidade resultante, um controle de níveis visitados transforma em zero a probabilidade de visita do nível que já tenha sido visitado no contexto. Com isto, caso o nível exemplos já tenha sido visitado, apenas os níveis facilitado, FAQs e médio/próximo farão parte da seleção genética da técnica de Monte Carlo.

Para personalizar os conteúdos didáticos é possível estruturar um sistema considerando o conteúdo multinível (CM), o perfil do estudante ( $\Omega$ ), o padrão proximal de aprendizagem ( $L_\Omega$ ) e a personalização do conteúdo multinível.

O sistema proposto neste trabalho é composto de introdução, testes iniciais, sequência de apresentação do assunto e teste final. A Figura 5.17 ilustra a estrutura do sistema.

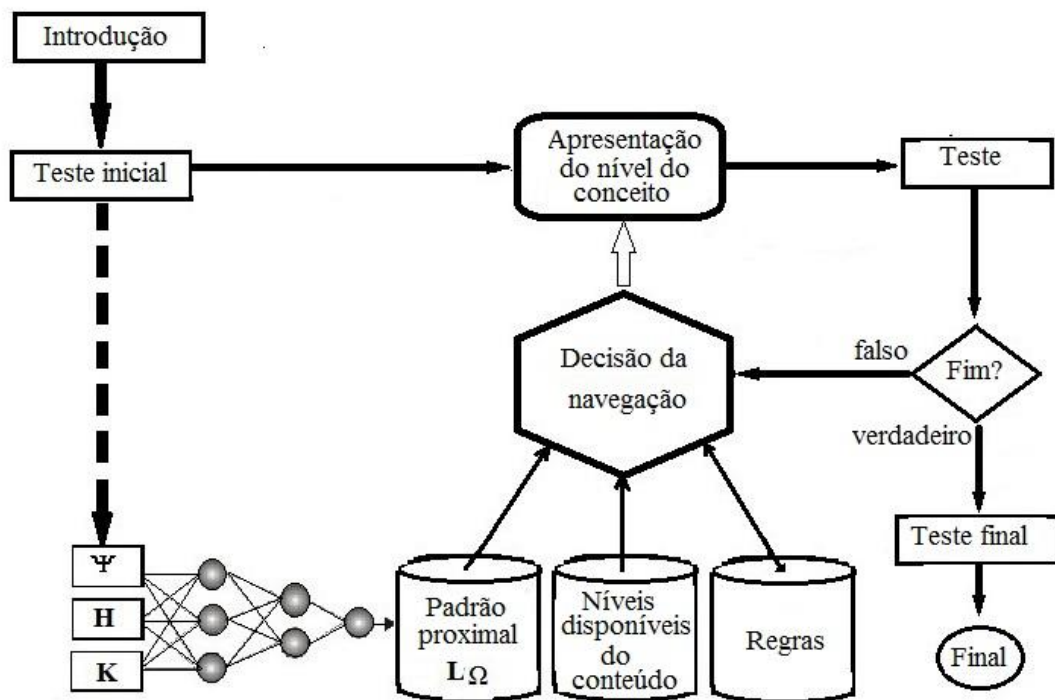


Figura 5.17: Estrutura do sistema para a personalização de conteúdos didáticos.

Na introdução do sistema proposto são apresentadas as informações gerais sobre o sistema e o assunto a ser apresentado. Após a introdução são realizados os testes de características, habilidades e pré-conhecimento. O resultado dos testes é inserido na entrada da RNA que classifica o perfil do estudante e apresenta, na saída, o padrão proximal de aprendizagem ( $L_\Omega$ ). Este padrão fica armazenado na memória do sistema como padrão de referência global para a apresentação do conteúdo.

Conforme definido pelo professor, o sistema inicia a sequência de apresentação do conteúdo a partir do primeiro conceito até o último conceito. A apresentação de cada conceito sempre inicia no nível médio. Após a apresentação de todo o conteúdo, é realizado um teste final.

A decisão da navegação no STI proposto neste trabalho é baseada no padrão de navegação gerado pela RNA e no desempenho local do aprendiz (nível corrente e resultado da correção do teste).

A apresentação do conteúdo é organizada em uma combinação de duas sequências: geral e localizada.

A sequência geral é organizada pelo professor que define a ordem de apresentação dos conceitos. Essa sequência apresenta os conceitos em uma ordem lógica, estruturando o conteúdo desde o primeiro ao último conceito. A sequência geral tem uma estrutura semelhante à organização do tutorial clássico apresentado na Equação (5.2).

A sequência localizada é organizada pelo sistema proposto que define quais os níveis serão apresentados e a ordem de apresentação deles de acordo com a sequência geral. Após a apresentação do conceito em um nível qualquer, o estudante pode reagir de diferentes maneiras. Conforme a reatividade, é selecionado um nível para ser apresentado. A sequência localizada corresponde às ações didáticas do professor diante da reatividade do estudante.

No sistema proposto, a organização da sequência localizada inicia sempre no nível médio. Ao final da apresentação de cada nível do conceito, o estudante é submetido a um teste de retenção desse nível. Após avaliar a resposta do estudante, o sistema seleciona no conjunto de regras dos especialistas, a regra local adequada para a situação. Combinando a regra local e o padrão global ( $L_{\Omega}$ ), o sistema define o próximo passo na apresentação do conteúdo efetuando um sorteio probabilístico. Este sorteio utiliza a técnica de Monte Carlo [Russel, 2004] mencionada anteriormente neste capítulo. O processo de definição do próximo passo é repetido até a conclusão do conteúdo. Dessa maneira, o sistema organiza um conteúdo personalizado e reativo ao estudante.

#### **5.4 – Considerações Finais Deste Capítulo**

Neste capítulo foi apresentado o modelo conexionista de STI para personalização reativa de conteúdos didáticos. Inicialmente foi apresentado o modelo formal que estabelece os parâmetros para a implementação e as pesquisas de desenvolvimento de STIs

conexionistas. Foi apresentado um modelo de implementação de um STI connexionista incorporando conceitos do formalismo proposto neste trabalho.

Diante do exposto neste capítulo, verifica-se a aplicabilidade do formalismo proposto como fundamentação e referência para o desenvolvimento de sistemas tutores connexionistas.

O próximo capítulo apresenta o experimento do modelo proposto e os resultados obtidos. É descrita a metodologia e a forma de realização do experimento ao mesmo tempo em que são apresentadas as soluções de implementação do modelo proposto. No final do capítulo são apresentados os resultados obtidos e a análise dos dados.

# CAPÍTULO 6

## EXPERIMENTOS E RESULTADOS OBTIDOS

### 6.1 - Introdução

Este capítulo apresenta um experimento com o modelo proposto neste trabalho e as conclusões sobre os resultados obtidos.

Inicialmente é apresentada a metodologia e a estruturação do modelo. Em seguida é apresentada uma situação experimental com o modelo proposto. E após a descrição do experimento são apresentados os resultados obtidos e a análise dos dados.

A análise dos dados procura evidenciar as características amostrais dos dados obtidos na etapa inicial do experimento.

### 6.2 – Metodologia do Experimento

Para investigar a validade e a aplicabilidade das técnicas propostas neste trabalho foi desenvolvido um experimento. O objetivo deste experimento é a aquisição de dados para a análise e a fundamentação de conclusões sobre o modelo proposto.

Para o desenvolvimento do experimento é necessário desenvolver uma estrutura de suporte ao experimento, coleta e análise dos dados e as conclusões.

A estrutura de suporte para o experimento consiste de formatação do conteúdo, da definição da rede neural, da definição das regras de especialistas e do desenvolvimento de sistemas para coleta de dados.

A coleta de dados consiste de três etapas. Na etapa inicial os dados são coletados com o objetivo de serem selecionados para o treinamento da RNA e, também, eles serem utilizados na análise e na comparação com as outras etapas. Nestas outras etapas os dados são coletados para a análise e a comparação com as outras coletas.

A análise dos dados ocorre em dois momentos. Em um primeiro momento os dados são analisados para a definição das características e do conjunto de treinamento da rede neural. Ao final das coletas a análise objetiva o estudo comparativo das coletas para fundamentar as conclusões do trabalho.

A Figura 6.1 sintetiza a organização da metodologia do experimento realizado neste trabalho.

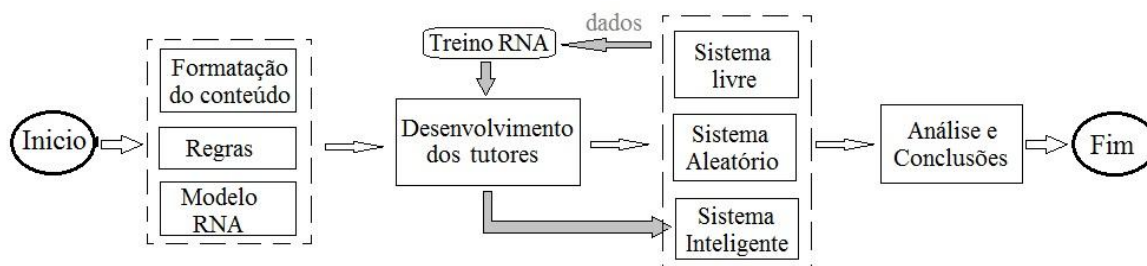


Figura 6.1 – Organização do experimento realizado neste trabalho.

### 6.2.1 – Tipos de tutores desenvolvidos para o experimento

Para a realização do experimento, foram desenvolvidos três sistemas com interfaces de software semelhantes: sistema de navegação livre, sistema de navegação aleatória e sistema de navegação inteligente. A diferença entre esses sistemas é o mecanismo de decisão para a escolha do nível a ser apresentado na organização do conteúdo. O sistema de navegação inteligente emprega as técnicas de modelagem propostas neste trabalho.

Na navegação livre, é o estudante que decide o próximo nível na sequência de apresentação do conteúdo. O objetivo de utilizar essa navegação no experimento é coletar, analisar e selecionar os dados para o treinamento da rede neural do sistema inteligente e também utilizar os dados para a comparação com os dados dos sistemas de navegação aleatória e inteligente. Após essa coleta, é realizada a análise do desempenho da navegação de cada estudante. As melhores navegações são selecionadas conforme os critérios estabelecidos pelos professores participantes do experimento. Alguns dos critérios considerados são: nota, ganho (melhoria), coerência, etc.

No sistema de navegação aleatória, a decisão do próximo nível do conceito a ser apresentado é realizada por uma função de sorteio randômico do software. A sequência geral dos conceitos tem a ordem de apresentação conforme definida pelo professor. Devido à

aleatoriedade do sistema de sorteio do próximo nível, qualquer nível do conceito pode ser apresentado em qualquer ordem. Além da própria aleatoriedade, a sequência de apresentação dos níveis do conteúdo é organizada ao acaso, sem qualquer regra ou lógica. O objetivo da coleta com esse tipo de navegação é realizar a comparação com o sistema de navegação inteligente. Com essa comparação, é possível demonstrar que as ações efetivas do sistema inteligente (hipótese alternativa -  $H_0$ ) não se devem ao acaso (hipótese nula -  $H_n$ ).

Na navegação inteligente, a decisão do próximo conteúdo a ser apresentado é realizada pelo conjunto de técnicas descritas no sistema proposto neste trabalho. O objetivo é validar a aplicabilidade dessas técnicas na organização personalizada e reativa desses conteúdos.

### **6.3 – Realização do Experimento**

O desenvolvimento do experimento não segue sistematicamente e de maneira única as etapas estabelecidas na metodologia. Algumas etapas dependem parcialmente de etapas anteriores. Desta forma, algumas partes de cada etapa permitem um desenvolvimento parcial. Outras etapas como o desenvolvimento do sistema inteligente dependem de informações de etapas posteriores. O refinamento do experimento pode ser realizado com as observações provenientes das etapas posteriores.

#### *6.3.1 – Formatação do conteúdo*

A elaboração do conteúdo deve atender à estrutura do sistema proposto e ser efetuada por especialistas da área que o tema pertence.

A organização do conteúdo, conforme a estrutura proposta é uma parte crítica do sistema. A assertividade na estruturação dos níveis (diferenciação entre eles) em cada conceito contribui para o resultado do processo ensino-aprendizagem.

A seleção do assunto “Introdução ao Processamento de Dados” (IPD) para o conteúdo do tutor foi decorrente de vários fatores. Um deles é o domínio do tema por parte da equipe que participa do projeto. Por outro lado, devem ser ressaltadas as características de atualidade do tema. Ele desperta interesse em uma população extensa, facilitando a participação de vários segmentos sociais.



Após a seleção do tema, foi implementado o conteúdo do tutor conforme a estrutura proposta. Esse conteúdo foi dividido em 15 conceitos, organizados em sequência lógica considerada adequada. O conteúdo de cada conceito foi elaborado em termos de informação geral, visando atender às necessidades específicas de cada nível (avançado, médio, facilitado, exemplos e FAQs).

### 6.3.2 – Definição do perfil do estudante

Para a identificação das características do estudante (perfil) foram utilizados três tipos de instrumentos: um questionário de características psicológicas (perfil pessoal), um questionário de habilidades tecnológicas e um questionário de conhecimentos do assunto a ser apresentado (pré-teste). A Figura 6.2 apresenta a estruturação do perfil do estudante.

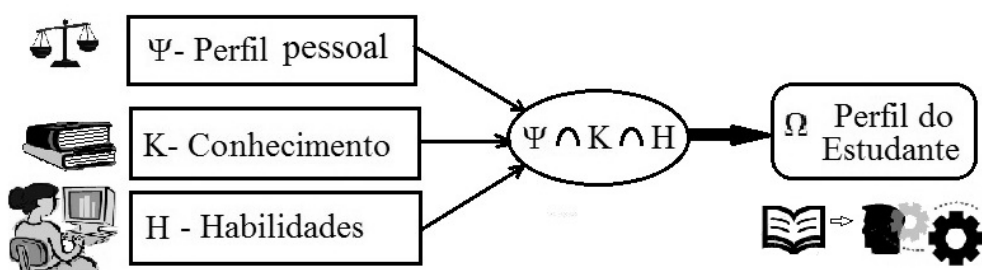


Figura 6.2: Estruturação do perfil do estudante.

O perfil pessoal é o resultado de um teste de características psicológicas. Na área da Psicologia, os testes são utilizados como ferramenta (principal ou auxiliar) no diagnóstico psicológico. Neste trabalho, o questionário é utilizado como um conjunto de variáveis a serem consideradas na personalização da navegação. O objetivo é estabelecer um meio de identificar as características comuns do estudante relacionadas ao grau de aproveitamento na aprendizagem.

O teste utilizado neste trabalho foi o “Inventário de Tipos de Keirsey”, um instrumento validado cientificamente [Keirsey, 1984]. Esta escolha foi fundamentada no fato desse inventário ser um instrumento elaborado por um pesquisador contemporâneo de Jung. O questionário, a metodologia e a forma de avaliação estão publicados livremente em livros e na Internet em vários sites. Esses fatores facilitam a implementação desse teste no sistema, sem alterações na sua metodologia de aplicação. Neste trabalho o questionário fornece oito

unidades que representam as dimensões de personalidade da tipologia. Cada unidade é um valor proporcional ao quantitativo de cada grupo de respostas do questionário. O Anexo 1 apresenta mais detalhes sobre o teste de Keirsey.

O questionário de habilidades obtém características demográficas (sexo, escolaridade, idade, etc.) e a relação do estudante com a tecnologia. As respostas desse questionário são convertidas em sete variáveis. O Anexo 2 apresenta detalhes do questionário e a maneira como as questões são agrupadas em sete variáveis. O valor de cada alternativa varia de um a cinco, de acordo com ordem destas alternativas. A gradação de valores inicia com a primeira alternativa valendo 1 ponto e é incrementada de um ponto a cada alternativa. Os resultados das questões agrupadas são somados e normalizados na faixa de zero a dez, onde o zero representa o valor mínimo e o dez é o valor máximo possível do somatório em cada grupamento.

O pré-teste é o último questionário para a definição do perfil do estudante. O pré-teste avalia o nível de conhecimento relativo ao conteúdo a ser apresentado. Neste trabalho o pré teste é implementado por meio de um conjunto de questões objetivas de múltipla escolha. Ao final da apresentação o resultado do pré-teste é comparado com o resultado do pós-teste para avaliar o nível de retenção do conteúdo apresentado. O pós-teste possui a mesma estrutura do pré-teste, porém ele é aplicado no final do curso. O resultado do pré-teste é convertido em tercil e codificado em duas variáveis. O tercil divide a amostra em três partes. Cada tercil representa 33,33% da amostra.

Conforme o exposto neste capítulo, o perfil do estudante é composto por dezessete valores: 8 (oito) valores do teste do perfil psicológico, 7 (sete) valores do teste de habilidades e 2 (dois) valores do pré-teste.

### *6.3.3 – Definição da rede neural*

Na IA conexionista, o conhecimento é estabelecido e manipulado pela estruturação e pela relação entre as características consideradas no problema. O especialista é que estabelece as características que devem ser consideradas no domínio do problema. O conhecimento pode ser estabelecido por técnicas que estruturam a relação entre as características consideradas no problema.

Uma rede neural artificial é um artefato computacional que apresenta a capacidade de estabelecer uma relação dos dados apresentados em suas entradas e efetuar a classificação em padrões na sua saída.

Neste trabalho, a RNA foi inserida para identificar o perfil do estudante e estabelecer o padrão proximal de aprendizagem mais adequado para esse perfil. Para ser compatível com a diversidade de estudantes, o padrão proximal não deve ser estabelecido em uma quantidade de classes discretas. Os elementos da classe devem ser contínuos para possibilitar estabelecer padrões personalizados para cada estudante.

Para o desenvolvimento deste trabalho foi escolhido o modelo de RNA Perceptron de Múltiplas Camadas (MLP, do inglês "*Mult Layer Perceptron*"). O poder computacional de uma RNA tipo MLP está na capacidade de classificar dados não linearmente separáveis e aprender por treinamento supervisionado. Após o treinamento a RNA tem a capacidade de identificar novos padrões, diferentes dos padrões utilizados no treinamento, estabelecendo uma nova classificação intermediária entre os padrões conhecidos (interpolação). Desta forma, o modelo é especialmente útil em situações nas quais outros métodos para classificação de padrões são ineficientes, seja pela complexidade do problema, seja pela dificuldade de estabelecer a relação entre os parâmetros considerados para a escolha do método.

Após a escolha do modelo MLP é necessário estabelecer a estrutura para a RNA. Estabelecer a estrutura de uma RNA MLP consiste em definir quantos neurônios serão utilizados nas camadas de entrada, saída e intermediária.

A RNA tem a função de definir o padrão proximal que corresponde aos 5 níveis do conteúdo multinível. Desta forma a RNA tem 5 saídas para indicação do percentual de cada nível no padrão. O sistema também pode ser implementado com 5 RNAs distintas. Entretanto, um dos objetivos do sistema é manter o mínimo de RNAs distintas. Além disto, uma única RNA com 5 saídas pode apresentar uma melhor aproximação na normalização das cinco saídas. RNAs independentes podem requerer um mecanismo extra para corrigir e normalizar a relação entre as saídas.

Para a entrada da RNA são utilizadas as características do perfil do estudante. Desta forma, a RNA tem dezessete entradas. As entradas são distribuídas em oito entradas para o perfil psicológico, sete entradas para as habilidades e duas entradas para o resultado do pré-teste.

Após a definição da entrada e da saída, falta definir as camadas intermediárias. Neste trabalho a definição dessas camadas foi resultado de uma avaliação do treinamento das

variações de estruturas intermediárias. A estrutura escolhida foi a que apresentou o melhor desempenho ao final do treinamento.

Para o treinamento a amostra foi dividida em dois subconjuntos: treinamento e validação. O conjunto de treinamento é utilizado para reajustar os pesos da RNA. O conjunto de validação é utilizado para avaliar o nível de erro com dados diferentes do conjunto de treinamento. Durante o treinamento as curvas de erro dos dois conjuntos seguem a mesma direção tendendo ao valor de erro zero. Em um determinado ponto o erro do conjunto de treinamento continua diminuindo enquanto o erro do conjunto de validação começa a aumentar. O ponto em que ocorre essa divergência indica que a RNA começa a especializar no conjunto de treinamento e deixa de reconhecer os outros padrões do universo do problema. O mínimo global é o ponto do treinamento que o conjunto de validação apresenta a menor taxa de erro. Esse ponto indica o melhor desempenho da rede no treinamento. O mínimo global é o parâmetro de escolha da melhor estruturação da rede entre outras estruturas de rede.

Para a seleção da rede foram realizados 400 treinamentos. Foram treinadas 20 redes em cada estrutura, variando de 2 a 21 neurônios na camada oculta. Dos treinamentos realizados, a rede escolhida possui uma camada oculta de 4 neurônios. A rede selecionada apresentou o melhor equilíbrio na taxa de erro (0,18% no treinamento e 0,32% na validação), com o menor custo de implementação (menor topologia) para o propósito deste trabalho. O erro mínimo global no conjunto de validação foi observado com 343 ciclos de treinamento, conforme pode ser observado na Figura 6.3. Os parâmetros desse ponto foi escolhido para a implementação da rede do sistema responsável pela navegação guiada inteligente.




Figura 6.3: Detalhe da curva de treinamento da RNA selecionada.

A RNA MLP foi estruturada com 17 neurônios na camada de entrada, uma camada intermediária com 4 neurônios e a camada de saída com 5 neurônios. A Figura 6.4 ilustra a estrutura final da RNA selecionada para o experimento deste trabalho.

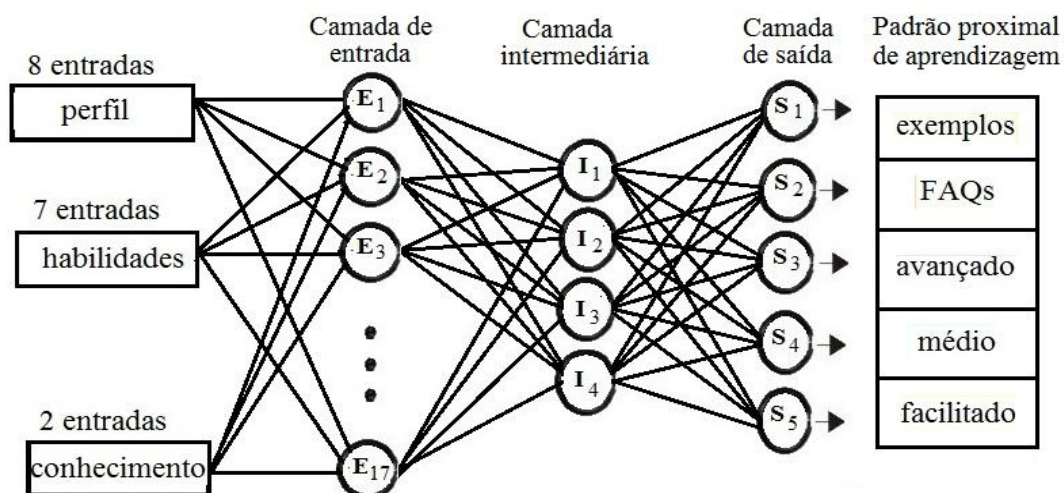


Figura 6.4: Estrutura da RNA selecionada para o experimento deste trabalho.

#### 6.3.4 – Definição de regras de especialistas

Na IA clássica o conhecimento é abstraído, organizado e representado a partir de especialistas. Especialistas são pessoas com conhecimento de um problema e as ações de atuação e decisão no domínio desse problema. Esse especialista estabelece fatos, regras e procedimentos a serem considerados na modelagem do conhecimento em sistemas de IA clássica.

O conjunto de dados que estabelece as ações de reatividade ao estudante foi obtido com um formulário de consulta aos professores que são os especialistas em ensino. Nessa consulta foi solicitado ao professor que fizesse a indicação da ação a ser seguida para cada uma das situações possíveis no conteúdo multinível do tutor.

Foram consultados 27 professores com experiência no ensino superior. Esses professores são os especialistas no sistema deste trabalho. Na pesquisa, o objetivo é determinar uma indicação adequada para cada situação local momentânea do tutor. Os detalhes do formulário de consulta utilizado no experimento podem ser visualizados no ANEXO 3 deste trabalho.

Todos os formulários de resposta dos professores foram tabulados em um único formulário. Após a tabulação das indicações equivalentes para cada situação foi calculada a média. O conjunto de médias resultante formou as regras de indicações para o sistema especialista, responsável por avaliar a situação local do estudante no tutor e estabelecer uma ação reativa.

#### 6.3.5 – *Sistemas de navegação e coleta de dados*

O sistema tutor foi desenvolvido de forma a permitir, com algumas modificações na estrutura da navegação, sua utilização em todas as etapas de coletas (livre ou guiadas).

O sistema com navegação livre é fundamental no experimento deste trabalho. Os dados obtidos com esse sistema são utilizados para ajustar os parâmetros da RNA no navegador do sistema inteligente.

A estrutura do sistema tutor é composta das etapas de introdução, questionários iniciais, tutor, questionário final e resultado dos testes (pré-teste e pós-teste).

A introdução apresenta as informações gerais sobre a organização do sistema tutor, a forma de utilização e o conteúdo que será apresentado.

Os questionários iniciais são compostos de perguntas de características psicológicas, habilidades (tecnológica e sócio cultural) e pré-teste de conhecimentos específicos (conteúdo do tutor).

O tutor contém o conteúdo específico estruturado em uma sequência de conceitos na qual cada conceito é apresentado em níveis (facilitado, médio, avançado, FAQs e exemplos). Após a apresentação de cada nível do conceito é realizado um teste objetivo de múltipla escolha. O objetivo deste teste é avaliar a retenção do nível de conceito apresentado.

O questionário final é composto por um pós-teste do conhecimento específico apresentado no tutor. Esse questionário é semelhante ao pré-teste, no qual é realizada uma questão para cada conceito apresentado no tutor.

As alternativas de respostas dos testes foram estruturadas conforme apresentado na Tabela 6.1. Para cada nível de acerto foi atribuído um valor a ser utilizado nos pontos de avaliação. Após responder a questão, o estudante recebe uma mensagem de indicação do nível de acerto (*feedback*). Esta indicação auxilia a decisão de navegação e permite o sistema filtrar incoerências durante as navegações.

Tabela 6.1: Organização das alternativas dos exercícios do tutor.

Nível de acerto	Mensagem (feed-back)	Descrição da alternativa	Valor
<i>Certa</i>	Parabéns!!! Resposta correta.	Alternativa correta	5
<i>Meio certa</i>	Esta não é a resposta mais correta.	Relacionada com o texto, mas não é a alternativa mais correta.	1
<i>Errada</i>	Resposta incorreta.	Alternativa errada	-5
<i>Não sei</i>	Obrigado pela sinceridade.	Opção de não sortear uma resposta (“chute”)	0

Para o experimento é importante considerar a possibilidade de incoerências durante a navegação no tutor. A Figura 6.5 representa uma situação de análise de incoerência. Nessa figura a situação de incoerência é a escolha da navegação em direção ao nível facilitado quando o indivíduo acertou o teste específico do nível avançado.

Neste trabalho foram consideradas duas situações como incoerentes:

- Escolher o nível avançado, após errar o teste do nível médio ou facilitado; e
- Escolher o nível facilitado, após acertar o teste do nível avançado.




Figura 6.5: Representação de incoerência na navegação.

Nos sistemas desenvolvidos o controle das incoerências é utilizado de maneira distinta. Nas navegações livre e aleatória ele é implementado no sistema navegador. Esse controle é utilizado apenas para a análise e o comparativo dos dados. Na navegação livre as incoerências são utilizadas como elemento de seleção dos dados. Na navegação inteligente o controle de incoerências é implementado como elemento de refinamento na definição da trajetória didática e no sistema aleatório esse controle não é utilizado.

Além das notas dos testes inicial e final, no experimento foi inserido um cálculo da relação entre as duas notas para estabelecer a melhoria do estudante.

Para avaliar a melhoria, a abordagem mais tradicional é a do ganho absoluto da Equação (6.1) que estabelece a relação da diferença entre as notas final e inicial com a nota inicial. Essa abordagem apresenta valores de ganhos bem maiores, porém produz distorções de avaliação. Estudantes com notas iniciais maiores são penalizados em relação aos

estudantes com notas iniciais menores. Por exemplo, um estudante começa com a nota 1,0 (um) e finaliza com a nota 3,0 (três) terá um ganho absoluto de 200%. Outro estudante com a nota inicial 6,0 (seis) e final 9,0 (nove) terá um ganho absoluto de apenas 50%. No caso da nota máxima ser 10,0 (dez) será impossível o segundo estudante atingir 100% de ganho.

$$GanhoAbsoluto = \frac{NotaFinal - NotaInicial}{NotaInicial} * 100\% \quad (6.1)$$

A abordagem do ganho normalizado [Vishnu, 2002], representado pela Equação (6.2), estabelece o ganho em relação à nota máxima e corrige a distorção do ganho absoluto. Essa abordagem descreve o ganho máximo (100%) como sendo a situação na qual o estudante atinge a nota máxima da avaliação no final e representa de forma homogênea a avaliação da melhoria do estudante. Desta forma, o ganho normalizado foi a medida adotada no experimento deste trabalho.

$$GanhoNormalizado = \frac{NotaFinal - NotaInicial}{NotaMáxima - NotaInicial} * 100\% \quad (6.2)$$

#### 6.3.5.1 – Sistema com navegação livre

A coleta com navegação livre (coleta livre) foi realizada para a seleção dos dados necessários para a implementação do sistema proposto, além de servir de ponto de referencia.

A Figura 6.6 representa a estrutura do tutor com navegação livre. A decisão da navegação nesse tutor é controlada pelo estudante.



Figura 6.6: Estrutura do sistema tutor livre.



Após responder o teste de cada nível é apresentada a tela do navegador que oferece ao estudante a liberdade de escolher o próximo destino a seguir. A Figura 6.7 ilustra a tela de navegação do tutor livre.

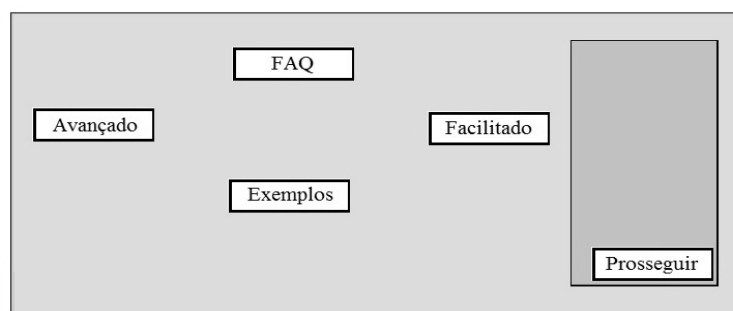


Figura 6.7: Tela de navegação do tutor livre.

Ao término da coleta de dados da navegação livre, foi iniciada a fase de análise dos dados coletados, na qual o objetivo maior é selecionar os padrões de navegações que alcançaram bons resultados conforme os critérios estabelecidos para a seleção das navegações:

- a) conclusão de todo o experimento da navegação livre;
- b) nota final igual ou maior do que 6,0;
- c) ganho mínimo de 50%; e
- d) navegação com no máximo 20% de incoerências.

A coleta livre foi realizada com 228 voluntários, estudantes dos períodos iniciais de cursos superiores. Apesar da quantidade, apenas 148 voluntários completaram todo o experimento e esse número passou a ser a referência de navegações válidas da coleta livre. Das navegações válidas, apenas 60 enquadraram nos critérios estabelecidos e foram destinadas para o treinamento da RNA.

#### 6.3.5.1.1– Seleção de dados para o treinamento da RNA

O principal conjunto de dados, que formará o conjunto de treinamento da rede neural que determina o estilo de navegação do aprendiz, é retirado da observação dos melhores casos

obtidos na navegação livre. Nos melhores casos, espera-se, no mínimo, nota final igual ou superior a 5,0 (cinco) e a ocorrência de alguma melhoria.

Neste trabalho, buscando um filtragem satisfatória das boas navegações, os dados foram analisados de diferentes formas, variando nota e ganho normalizado. Para avaliar as notas foi escolhido quatro valores mínimos para as notas finais: 5 (cinco), 6 (seis), 7 (sete) e 8 (oito) e a variação do ganho mínimo foi de 10% a 80%.

Para selecionar um quantitativo representativo da amostra foi pesquisado um ponto no qual a combinação nota e ganho oferece quantidade e qualidade. O gráfico da Figura 6.8 apresenta a curva de desempenho do ganho normalizado para o valor mínimo de cada uma das notas. Nesse gráfico, pode ser verificado que ao estabelecer 7,0 como nota mínima e 50% como ganho mínimo, são selecionados pouco mais de 40 navegações. Após a avaliação de diferentes desempenhos de navegação foram selecionados para o treinamento da RNA as navegações dos estudantes que atingiram no mínimo nota 6,0 (seis) com melhoria igual ou superior a 50%.




Figura 6.8: Curva de desempenho das notas das navegações.

Conforme pode ser observado na Figura 6.8, o ponto escolhido tem boa representatividade proporcionando um tamanho razoável da amostra (60 navegações) com boa qualidade de nota e ganho. Essa escolha foi realizada, supondo que a aplicação da generalização dos padrões a outros estudantes pela RNA pode sugerir um padrão de navegação para atingir resultados satisfatórios.

### 6.3.5.2 - Sistema com navegação inteligente

A estrutura do sistema tutor inteligente (guiado) é a mesma utilizada no sistema tutor livre. A diferença reside na forma de decidir o próximo passo na navegação que, no sistema proposto neste trabalho, é guiada. Nesse tutor, a rede neural determina o padrão de navegação utilizado em toda a interação de tutoria. Em outras palavras, o padrão de navegação do indivíduo permanece inalterado durante toda a navegação. Ao término da leitura do conteúdo e resposta do respectivo teste, os dados são capturados. Esses dados (o nível visitado e o resultado da correção do teste), o padrão de navegação do indivíduo e as regras dos especialistas (regras probabilísticas) definem a decisão do próximo passo na condução do sistema tutor, como ilustrado na Figura 6.9.

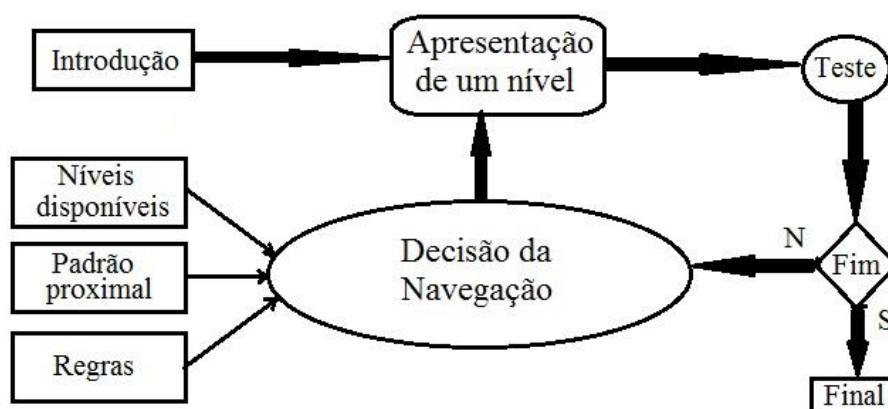


Figura 6.9: Estrutura do sistema inteligente,

A eficiência do sistema proposto é mensurada pelo desempenho da navegação guiada. O objetivo principal é conduzir o aprendiz a alcançar um bom desempenho com base nas trajetórias que desconsideram os recursos (níveis de conceito) desnecessários, inadequados ao perfil do aprendiz.

### 6.3.5.3 – Sistema com navegação aleatória

Para verificar a validade das técnicas empregadas no sistema proposto e assegurar que os resultados não são devido ao acaso (hipótese alternativa) foi estabelecido um sistema de navegação guiada com decisão por sorteio aleatório.

O sistema de navegação aleatória tem uma interface e uma estrutura semelhante ao sistema de navegação inteligente. A diferença entre as navegações reside no sistema de decisão do navegador. A decisão do navegador do sistema aleatório é realizada por um algoritmo que sorteia ao acaso o próximo passo no sistema tutor. Apesar da semelhança na interface e na estrutura, os dados do perfil e as regras não são utilizados no processo de decisão da navegação. No lugar desses componentes foi inserido um mecanismo de geração aleatória para efetuar o sorteio do próximo passo no tutor. A Figura 6.10 ilustra a estrutura do sistema aleatório.

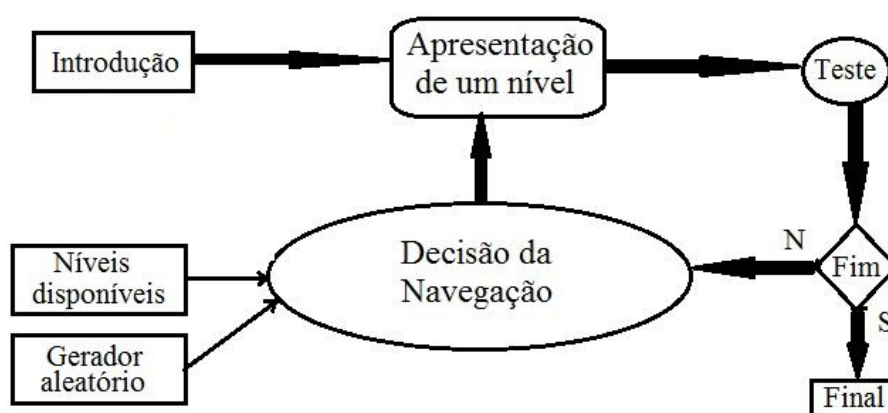


Figura 6.10: Estrutura do sistema aleatório.

### 6.3.6 – Recursos computacionais

A implementação e execução do experimento foi realizada em ambiente cliente servidor WWW. A programação foi realizada empregando HTML e ASP®. A Tabela 6.2 mostra os recursos computacionais utilizados neste trabalho.

Tabela 6.2: Recursos computacionais utilizados neste trabalho

HARDWARE	SOFTWARE
Processador Intel Core 2 duo 2.9 Mhz, 4Gb de memória RAM e Disco rígido de 320Gb	ASP, HTML, Acess, Matlab e Excel,

## 6.4 – Análise dos Resultados Obtidos

A análise e a comparação dos dados coletados com as navegações livre, aleatória e inteligente possibilita estabelecer as conclusões sobre as técnicas propostas.

Durante a execução do experimento foi realizado um total de 290 navegações, porém apenas 210 foram consideradas navegações válidas para a análise dos dados. Foram desconsideradas 80 navegações no sistema de navegação livre. As 210 coletas válidas estão distribuídas conforme listado a seguir:

- 148 coletas com a navegação livre;
- 31 coletas com a navegação aleatória; e
- 31 coletas com a navegação inteligente

Durante a primeira etapa do experimento foi realizado um total de 228 navegações. Deste total, 148 foram consideradas navegações válidas para a análise dos dados. A desconsideração de 80 navegações no sistema de navegação livre ocorreu por vários problemas como reajustes no processo, estudantes que não completaram a navegação, falhas no sistema, etc. Após a coleta de dados com a navegação livre, os dados foram analisados e selecionados para o treinamento da rede neural do sistema inteligente.

Para a continuidade do experimento, além da coleta livre, foram realizadas 62 coletas com sistemas guiados. Dessas coletas, 31 foram realizadas com um sistema empregando as técnicas propostas neste trabalho (navegação inteligente) e 31 com um sistema de decisão aleatório. Ao final das coletas, foi realizada a análise dos dados e a avaliação comparativa entre as navegações.

A Tabela 6.3 apresenta os resultados obtidos da análise das amostras, originada da Estatística Descritiva. A análise descritiva proporciona a visualização das características e do comportamento das amostras nas navegações do experimento. Nessa tabela podem ser observadas várias informações importantes que podem ser conclusivas. Dentre os pontos analisados, podem ser destacadas as medidas de variabilidade e a tendência central das amostras.

Nas três navegações, as notas iniciais médias estão próximas, em torno de 4,16 – um indicativo de que os participantes amostrais com conhecimento inicial regular sobre o assunto

abordado. A coleta livre apresentou a média inicial maior (4,56), enquanto as navegações aleatória (3,99) e inteligente (3,92), assim podem ser consideradas praticamente iguais.

Tabela 6.3: Análise descritiva dos dados.

Ítem	Nota inicial			Nota final			Ganho normalizado		
Navegação	Livre	Aleatória	Inteligente	Livre	Aleatória	Inteligente	Livre	Aleatória	Inteligente
Média	4,56	3,99	3,92	6,87	5,93	7,21	39,59	32,60	58,02
Erro padrão	0,15	0,39	0,40	0,14	0,39	0,33	2,70	4,93	4,63
Mediana	4,40	3,47	4,00	6,80	5,73	6,93	42,08	32,31	56,82
Moda	3,60	5,60	4,00	8,80	5,73	6,27	0,00	0,00	100,00
Desvio padrão	1,78	2,17	2,21	1,66	2,16	1,83	32,87	27,42	25,79
Amplitude total	8,13	7,47	7,73	8,53	7,47	7,20	169,57	89,17	83,33
Mínimo	0,67	0,13	0,00	1,47	1,87	2,80	-69,57	-10,91	16,67
Máximo	8,80	7,60	7,73	10,00	9,33	10,00	100,00	78,26	100,00

A média das notas finais entre as coletas foi de 6,6, indicando ter ocorrido melhoria. Neste caso, a maior média foi alcançada pela navegação inteligente (7,21), seguida pela livre (6,87) e, por último, a navegação aleatória (5,93).

Na observação das médias, o fato mais interessante está na média da melhoria (ganho normalizado). A navegação inteligente (sistema proposto neste trabalho) alcançou a média 58,02% de melhoria (a mais alta das três coletas), seguida da navegação livre (39,59%) e da navegação aleatória (32,60%). Neste ponto, é importante ressaltar que a melhoria mínima de 50% foi um dos critérios para a seleção do conjunto para o treinamento da rede.

O desvio padrão é uma medida de variabilidade que indica a estabilidade ou a homogeneidade dos elementos do conjunto. O valor do desvio padrão das notas iniciais apresenta um conjunto mais homogêneo na navegação livre e um grupo mais heterogêneo na navegação inteligente.

O desvio padrão da nota final indicou a navegação livre com menor variação (1,66), em seguida a navegação inteligente (1,83) e, por último, a navegação aleatória (2,16).

A comparação do desvio padrão das notas iniciais e finais indicou uma redução dos desvios nas navegações livre e inteligente após a apresentação do conteúdo. Na navegação aleatória praticamente não ocorreu redução da variabilidade inicial e final. A redução de 17,2% do desvio padrão na navegação inteligente foi a melhor entre as navegações, apesar do

desvio padrão nas notas finais da navegação inteligente (1,83) ser maior do que o desvio da navegação livre (1,66). Nesta ultima navegação, a redução foi de 6,7% e na navegação aleatória foi de apenas de 0,4%.

Quanto à melhoria da aprendizagem (ganho normalizado), o desvio padrão observado indica a navegação inteligente como a amostra mais homogênea, seguida pela amostragem aleatória e, por último, a amostra da navegação livre.

A Tabela 6.4 compara os valores médios observados nos experimentos. É possível verificar que a navegação inteligente apresentou, sem incoerências, maiores valores na média da nota final e do ganho normalizado com menor tempo de execução do curso e menor quantidade de níveis de conceito apresentados.

Tabela 6.4: Comparativo do desempenho médio das navegações.

<b>Navegação</b>	<b>Tempo de apresentação (minutos)</b>	<b>Níveis apresentados</b>	<b>Incoerências</b>	<b>Nota final</b>	<b>Ganho normalizado</b>
<i><b>Livre</b></i>	37,88	35,34	0,63	6,87	39,59
<i><b>Aleatória</b></i>	35,97	45	1,06	5,93	32,60
<i><b>Inteligente</b></i>	26,80	26,71	0	7,21	58,02

Pode-se observar na Tabela 6.4 que a maior variabilidade observada na coleta aleatória nas notas finais e no ganho normalizado podem ser um indicativo de que a ausência de método e de didática na organização do conteúdo multinível podem não contribuir para o aprendizado. Adicionalmente, o melhor desempenho obtido com a navegação inteligente pode indicar que as técnicas empregadas no sistema inteligente foram importantes para o resultado final.

#### *6.4.1 – Teste de correlação do padrão proximal de aprendizagem*

Neste ponto pode ser observada a eficiência do sistema proposto neste trabalho. Porém, é importante verificar a validade das técnicas no resultado final. Como a proposta deste trabalho é de Sistemas Tutores Inteligentes conexionistas, é importante investigar a atuação da Rede Neural Artificial (RNA) nesse sistema. Para a investigação foi empregado o teste de correlação de Pearson. O coeficiente de correlação de Pearson, mede o grau e a

direção (positiva ou negativa) da correlação entre duas variáveis de escala métrica [Walpole, 2007; Agresti, 2009].

Para execução do teste de correlação, foram analisados os dados da navegação inteligente. O perfil global indicado pela RNA (padrão proximal de aprendizagem  $L_{\Omega}$ ) para cada um dos 31 componentes foi comparado com o perfil individualizado efetivamente observado na navegação (conteúdo organizado pelo sistema). Após o levantamento dos perfis globais (indicado e observado) de cada elemento da amostra, foi realizado o estudo estatístico por meio da correlação de Pearson entre os perfis da amostra para verificar a validade da RNA no sistema.

O percentual de visitação dos perfis globais de navegação (RNA e observado) no nível fácil está representado na Figura 6.11 para cada componente da amostragem. Pode ser observado, nessa figura, que as “tendências” indicadas pelo perfil da rede ( $L_{\Omega}$ ) são acompanhadas pelo perfil observado. A correlação de 0,952 observada no nível fácil sugere o fato das indicações da rede neste nível estarem fortemente correlacionadas com o perfil efetivamente observado nas navegações realizadas. As diferenças de percentual de visitação podem ser explicadas pelas correções impostas pelas regras simbólicas e, também, pela característica do sistema probabilístico.




Figura 6.11: Correlação do nível facilitado.

As correlações de menor valor no sistema foram verificadas nos níveis médio e exemplos. Convém salientar que os valores são positivos e distantes do valor nulo, isso indica



que existe correlação. Nas Figuras 6.12 e 6.13 são apresentadas, respectivamente as correlações dos níveis médio e exemplos. É interessante observar que a curvas do nível médio são bem semelhantes enquanto a do nível exemplos é mais desordenada, porém com muitos pontos percentualmente coincidentes.




Figura 6.12: Correlação do nível médio/próximo.




Figura 6.13: Correlação do nível exemplos.

As melhores correlações foram verificadas nos níveis avançado e FAQs com valor 1,0 (um). É importante salientar o fato da RNA não ter indicado o nível avançado para nenhum dos elementos da amostra e foi verificada a não existência de navegações no nível. No nível FAQs a RNA indicou apenas um dos componentes amostrais para a navegação no nível e pode ser observado que apenas ele foi conduzido para esse nível. O gráfico da Figura 6.14 apresenta a correlação dos perfis estudados no nível FAQs.




Figura 6.14: Correlação do nível FAQs.

O valor da correlação geral observada foi de 0,875, indicando uma forte correlação positiva entre os perfis. Este nível de correlação é um forte indício de que a atuação da RNA no sistema é fortemente responsável pela definição do caminho a ser percorrido pelo estudante no tutor. Na Tabela 6.5 é apresentado o estudo completo dos cálculos das correlações global e de cada nível.

Tabela 6.5: Correlação de Pearson RNA x observado.

Nível	Geral	Fácil	Médio	Avançado	FAQs	Exemplos
Correlação	0,875	0,952	0,694	1	1	0,529

Pode-se observar na Tabela 6.5 que a os resultados obtidos utilizando a correlação de Pearson entre os perfis indicado pela RNA e o efetivamente observado em cada componente da amostra, indicam uma correlação linear positiva forte. A correlação observada sugere a indicação do padrão proximal de aprendizagem  $L_{\Omega}$  apresentado pela RNA como fortemente atuante na organização do conteúdo a ser apresentado ao estudante. Eventuais diferenças entre os perfis justificam-se pela decisão probabilística e as correções apresentadas pela inserção das regras simbólicas que buscam corrigir as situações locais pedagogicamente incorretas.

## 6.5 – Conclusões

Neste capítulo foi apresentado uma implementação do modelo proposto neste trabalho, o experimento realizado e a análise dos dados coletados no experimento.

A análise estatística dos dados indicou que o modelo proposto neste trabalho tem capacidade de organizar conteúdos personalizados. Os resultados obtidos indicam que a personalização oferecida pelo sistema proporcionou melhores resultados nas notas finais, melhoria e tempo de estudo.

O teste de correlação mostrou que a RNA tem uma relevante importância no sistema, cuja função é estabelecer os parâmetros para a personalização.

Diante do exposto no capítulo, verifica-se a viabilidade do modelo em sua organização formal e na sua implementação.

O próximo capítulo apresenta as conclusões e as contribuições desta tese, os trabalhos futuros que poderão ser desenvolvidos a partir deste trabalho e as publicações originadas deste trabalho.

## PARTE III

---

### Conclusões

# CAPÍTULO 7

## CONCLUSÕES E CONTRIBUIÇÕES

### 7.1 – Introdução

A eficiência do experimento implica em uma abordagem científica desde seu planejamento até a emissão do relatório. A adoção desses critérios permite que os dados certos sejam coletados no menor tempo possível e com o mínimo de custos. Contudo, a coleta de dados eficiente e apropriada exige um planejamento de experimentos baseado em três princípios básicos: réplica, aleatoriedade e formação de blocos.

Este capítulo apresenta as conclusões e as contribuições desta tese, os trabalhos futuros e as publicações originadas nesta tese.

### 7.2 – Conclusões

O sistema proposto neste trabalho apresentou um modelo formal para o emprego em sistemas tutores inteligentes conexionistas com conteúdo multinível. Nesse sistema a personalização reativa é proporcionada por uma combinação híbrida de técnicas conexionistas, regras simbólicas e decisão probabilística.

A primeira parte do formalismo procurou estabelecer a organização de um conteúdo com várias alternativas de apresentação. Essa organização procurou representar a disponibilidade de recursos para as intervenções do professor na mediação do conhecimento. O formalismo do conteúdo multinível apresentou a possibilidade de distribuição dos recursos em um plano. Esta distribuição possibilita estabelecer a relação no processo de decisão do recurso a ser utilizado e, também, uma referência para a inserção e o posicionamento de novos recursos.

A representação do processo dinâmico da construção personalizada e reativa do conteúdo foi formalizada com o emprego de equações diferenciais parciais pelo método das diferenças finitas. A flexibilidade proporcionada pelo método viabiliza a modelagem reativa dos diferentes momentos de construção da apresentação do conteúdo no sistema.

O formalismo proposto para os componentes de entrada do sistema estabeleceu as considerações sobre a identificação do perfil do estudante. Esta definição foi importante para o processo de personalização. Este processo requer um grande número de variáveis proporcionalmente ao nível de personalização desejado. Conforme os objetivos e os recursos da personalização, esse processo pôde ser simplificado pelo estabelecimento de padrões. Neste trabalho, o formalismo apresentado para a personalização indicou que o emprego de várias dimensões possibilitou uma maior região de abrangência para os centróides de um padrão.

O problema de estabelecer o padrão pela intersecção de várias regiões foi solucionado com o emprego de uma RNA do tipo MLP. O paradigma de aprendizado supervisionado da MLP proporcionou a organização necessária para estabelecer uma associação do perfil do estudante com um padrão proximal de aprendizagem. Neste trabalho foi utilizada a tipologia psicológica de Jung para demonstrar a capacidade do modelo para associar as características do estudante (definidas pelo projetista) com estratégias de organização do estudo (observadas por meio de exemplos). Em um primeiro plano, essa associação apresentou um conteúdo mais próximo da estrutura do estudante, o que pode ser um fator favorável para a aceitação do conteúdo apresentado. Outro aspecto dessa abordagem é o fato de propiciar uma ferramenta para auxiliar estudantes com dificuldades de organização do estudo individual. A organização automática do conteúdo pode proporcionar uma melhor aceitação de conteúdos didáticos. A consequência dessa melhor aceitação pode ser o desenvolvimento do interesse e da capacidade de organizar o estudo, contribuindo para elevação da auto estima do estudante.

Na perspectiva da zona de desenvolvimento proximal (ZPD), o sistema funciona como mediador no processo de desenvolvimento da aprendizagem. O sistema estabelece um padrão proximal de aprendizagem para o estudante, proveniente de outro estudante com perfil semelhante. Durante o estudo, conforme as ações do estudante, o sistema reajusta a apresentação, semelhante a ação de mediação do professor. No sistema proposto neste trabalho, a ação de mediação do professor foi implementada com a combinação de regras simbólicas e um mecanismo de decisão probabilístico.

A organização do experimento procurou estabelecer os critérios e os métodos que permitissem obter os dados necessários para estruturar o modelo proposto. A metodologia de

coletar dados com diferentes sistemas proporcionou a disponibilidade dos dados necessários para a análise comparativa da validade das técnicas propostas.

A análise dos dados coletados mostrou que a estrutura multinível possibilitou diferentes formas de organizar o conteúdo que resultaram em uma melhoria no valor médio das notas finais. Os dados do experimento indicaram que o sistema inteligente proporcionou uma boa organização dos conteúdos com bons resultados em termos das médias finais, da melhoria da aprendizagem e do tempo de estudo.

As validade das técnicas empregadas no sistema proposto foram verificadas por testes estatísticos que comprovaram a validade do emprego de redes neurais artificiais na proposta de desenvolvimento de sistemas tutores conexionistas.

A disponibilidade de alternativas de recursos didáticos proporcionada pelo formato do conteúdo multinível pode ser um fator favorável em ambientes virtuais de aprendizagem e no estudo individual. A organização da apresentação pelo sistema proposto pode amenizar a ausência de um professor no momento em que ocorrerem dificuldades localizadas.

Diante do exposto, foi comprovada a hipótese principal deste trabalho sobre o estabelecimento de uma organização formal para o desenvolvimento de sistemas tutores conexionistas. Também foram comprovadas as hipóteses secundárias em relação a viabilidade do sistema e melhores resultados em termos de notas, tempo e organização dos conteúdos.

Conforme apresentado neste trabalho, verificou-se a viabilidade do formalismo e das técnicas do modelo proposto para a implementação de sistemas tutores inteligentes conexionistas como recurso auxiliar em processos educacionais.

### **7.3 – Contribuições**

As principais contribuições deste trabalho foram:

- Proposta de um formalismo matemático para estabelecer os parâmetros de desenvolvimento de sistemas tutores conexionistas;
- Organização e estrutura formal de um conteúdo didático multinível;
- Emprego do conceito de zona de desenvolvimento proximal para estabelecer o conceito de padrão proximal de aprendizagem;
- Metodologia para estabelecer as características de entrada para a definição do perfil do estudante;

- Emprego de redes neurais artificiais para reconhecer o perfil do estudante e associar a um padrão proximal de aprendizagem;
- Aplicação do método das diferenças finitas para o ajuste da trajetória didática, na organização do conteúdo didático;
- Complementar o padrão pessoal da RNA com conhecimentos de especialistas em ensino para proporcionar os mecanismos de ação e mediação no ajuste da navegação do estudante;
- Utilização do conceito de distribuições de probabilidade para integrar as indicações globais (fornecidas pela rede neural MLP) com as indicações locais (de especialistas), configurando um sistema híbrido;
- Apresentação de uma metodologia para definir o conjunto de treinamento da rede neural utilizada; e
- Correlação das características do estudante com a navegação personalizada e melhoria no aprendizado.

#### **7.4 – Trabalhos Futuros**

A proposta deste trabalho e a riqueza dos dados obtidos no experimento podem propiciar outras investigações. Novas investigações podem contribuir para consolidar o emprego de sistemas tutores inteligentes conexionistas como recurso auxiliar nos processos educacionais em ambientes virtuais de aprendizagem. As possibilidades de emprego do sistema proposto nesta tese podem favorecer o apoio a processos educacionais em sistemas de educação tanto presenciais como a distância.

A partir deste trabalho é possível estabelecer novos trabalhos, tais como:

- Formas de definir e inserir novos níveis conceituais no modelo proposto;
- Investigação das características mais adequadas e a correlação com as ações no processo de organização do estudo individual;
- Estudo de casos dos dados do experimento realizado;
- Melhorias no processo de reatividade em situações locais;
- Investigação de estratégias diferenciadas para a organização do



conteúdo; e

- Aplicação do modelo em tecnologias assistivas; etc.

## 7.5 – Publicações Originadas Neste Trabalho

- MELO, F. R.; FLÔRES, E. L. ; CARVALHO, S. D.; MARTINS, W.; CARRIJO, G. A.; VEIGA, A. C. P. Multilevel didatic content for reative personalization on intelligent tutor systems. (aprovada e em fase de publicação) In: SBA - Revista da Sociedade Brasileira de Automática. São Paulo: UNICAMP, 2012.
- MELO, F. R. ; FLÔRES, E. L. ; CARVALHO, S. D.. Multilevel content's structure for personalization in connexionist intelligent tutor systems. In: 8th Intenational Conference on Information Systems and Technology Management, 2011, São Paulo. Abstract and Proceedings of 8th CONTECSI. São Paulo : TECSI EAC FEA USP, 2011.
- MELO, F. R. ; FLÔRES, E. L. ; CARVALHO, S. D.; CARRIJO, G. A. ; VEIGA, A. C. P. Estruturação Reativa de Conteúdos por Diferenças Finitas em Sistemas Tutores Inteligentes Conexionistas. In: IX Conferência de Estudos em Engenharia Elétrica, 2011, Uberlândia. IX CEEL. Uberlândia : CEEL UFU, 2011.
- MELO, F. R. ; CARVALHO, S. D. ; FLÔRES, E. L. ; MARTINS, W. ; PEREIRA, R. C. ; CARRIJO, G. A. ; VEIGA, A. C. P. CONTEÚDOS DIDÁTICOS PERSONALIZADOS POR PADRÕES PROXIMAIS DE APRENDIZAGEM EM SISTEMAS TUTORIAIS INTELIGENTES. In: VIII CEEL, 2010, Uberlândia. VIII Conferência de Estudos em Engenharia Elétrica. Uberlândia : PET Eletrica - UFU, 2010.
- MELO, F. R. ; CARVALHO, S. D. ; MARTINS, W. ; NALINI, L. E. G. ; FLÔRES, E. L. . CONEXIONISMO EM SISTEMAS TUTORES INTELIGENTES. In: VII CEEL - Conferência de Estudos em Engenharia Elétrica, 2009, Uberlândia. Anais do VII CEEL - Conferência de Estudos em Engenharia Elétrica, 2009.

- MELO, F. R. ; CARVALHO, S. D. ; MARTINS, W. ; NALINI, L. E. G. ; FLÔRES, E. L. . SISTEMAS TUTORES CONEXIONISTAS NO PROCESSO DE ORGANIZAÇÃO DE CONTEÚDOS DIDÁTICOS PERSONALIZADOS. In: VI CEEL - Conferência de estudos em engenharia Elétrica, Uberlandia - MG. 2008,

Trabalhos submetidos aguardando parecer:

- MELO, F. R. ; FLÔRES, E. L. ; CARVALHO, S. D.; MARTINS, W.; CARRIJO, G. A. ; VEIGA, A. C. P. Proximal Learning Patterns for Intelligent Tutoring Systems. In: Pattern Recognition. Elsevier, 2012.
- MELO, F. R. ; FLÔRES, E. L. ; CARVALHO, S. D.; MARTINS, W.; CARRIJO, G. A. ; VEIGA, A. C. P. Organization of Didactic Contents for Personalized Distance Learning Environments. Computer and Education, Elsevier, 2012.

## **7.6 – Considerações Finais Deste Capítulo**

Este capítulo apresentou as conclusões e as contribuições desta tese, os trabalhos futuros que poderão ser desenvolvidos a partir desta tese e as publicações originadas neste trabalho.

## REFERÊNCIAS BIBLIOGRÁFICAS

- AGRESTI, A., FRANKLIN, C. Statistics Art and Science of Learning from data. 2ª Edition, Pearson. 2009.
- ALENCAR, W. S., Sistemas Tutores Inteligentes Baseados em Redes Neurais, Goiânia, 2000. Dissertação (Mestrado em Engenharia Elétrica e de Computação) - UFG - Universidade Federal de Goiás.
- ASSMAN, H. Reencantar a Educação: rumo à sociedade aprendente. Rio de Janeiro. Editora Vozes. 2007.
- BARAJAS, F. V. A formal model for the requirements diagrams of SysML. IEEE Latin-America Transactions, vol. 8, nº 3, 2010.
- BARLOW, J. A. The teaching and the teaching machine. Auto-instructional Devices, 1961.
- BARROS, E. A. and JUNQUEIRA, F. C. Modelagem matemática de um giroscópio sintonizado dinamicamente. SBA Controle & Automação, vol 16, nº 2, São Paulo, 2005.
- BERENS, L. Type & Temperament. Volume 19, Number 2, 1996. Disponível em <http://www.aptccentral.org> Acesso em Set 2011.
- BOYCE, W. E. e DIPRIMA, R. C. Equações diferenciais elementares e problemas de valores de contorno. 9ª Ed. Rio de Janeiro, LTC, 2010
- BRAGA, A. P., CARVALHO, A. P. L. e LUDERMIR, T. B. Redes Neurais Artificiais – Teorias e Aplicações. 2ª Ed. Rio de Janeiro, LTC, 2007.
- BUFFONI, S. S. O. Apostila de introdução aos métodos numéricos - parte I. Universidade Federal Fluminense, 2002.
- CARVALHO, S. D. ; MARTINS, W. . AN INTELLIGENT TUTORING SYSTEM BASED ON SELF-ORGANIZING MAPS DESIGN, IMPLEMENTATION AND EVALUATION. In: International Conference On Intelligent Tutoring Systems, 2004, Maceió-Al. Proceedings of International Conference On Intelligent Tutoring Systems, p. 573-579, 2004.
- CARVALHO, S. D., Mapas Auto-Organizáveis Aplicados a Sistemas Tutores Inteligentes, Goiânia, 2002. Dissertação (Mestrado em Engenharia Elétrica e de Computação) - UFG - Universidade Federal de Goiás.
- CATANIA, A. C. Learning. Prentice Hall, Upper Saddle River, New Jersey, USA, 1998.

- CATANIA, A. C. Learning. Prentice Hall, Upper Saddle River, New Jersey, USA, 1998
- CEREDA, P. R. M. and ZORZO, S. D. Access control model formalism using adaptive automaton. IEEE Latin-America Transactions, vol. 6, nº 5, 2008.
- CHAIKLIN, S., The Zone of Proximal Development in Vygotsky's Analysis of Learning and Instruction in Kozulin et. al, Cambridge University Press. 2003.
- CHAPRA, S. and CANALE, R. Numerical Methods for Engineers. 6th edition, New York, McGraw-Hill Science/Engineering/Math; 2009.
- COCCO, A. P. Modelo de adaptação de ensino utilizando agentes pedagógicos. Tese de doutorado, Universidade Federal do Rio Grande do Sul, Porto Alegre, Brasil, 2004
- CORREA Filho, M. A Arquitetura de Diálogos entre Agentes Cognitivos Distribuídos. Rio de Janeiro: COPPE/UFRJ, 1994. (Tese de Doutorado).
- CRONBACH, L.J. Fundamentos da Testagem Psicológica, 5ª Edição, Editora Artes Médicas, Porto Alegre, Rio Grande do Sul, 1999.
- CRUZ, C. L., PATINO, H. D. and CARELLI, R. Nuevo algoritmo evolutivo baseado em El modelado matemático de La evolución de una espécie. IEEE Latin-America Transactions, vol. 3, nº 4, 2005.
- CYBENKO, G. Contínuos valued Neural Networks with two Hidden Layers are Sufficient. Technical report, Departament of Computer Science, Tufts University. 1988.
- DAHLBERG, I. Teoria do conceito. Ciência da Informação, v. 7, n. 2, p. 101-107, Rio de Janeiro, 1978.
- DANIELS, M. Self-Discovery the Jungian Way: The Watchword Technique. London & New York: Routledge, 1992.
- DANTE, L. R. Matemática: Contexto e aplicações. 3ª Ed., São Paulo, Atica, 2008.
- DASTBAZ, M., MUSTAFA, A. e STONEHAM, R. Issues in Design and Development of Personalised E-Learning Systems. Proceedings of the ED-MEDIA 2006. World Conference on Educational Multimedia, Hypermedia & Telecommunications. Orlando. USA. 2006.
- DE VANEY, A. & BUTLER, R. P. Voices of the founders: early discourses in educational technology. Em Jonassen, D. H. The handbook of research for educational communications and technology. The Association for Educational Communications and Technology, Bloomington : IN, USA, 2001.
- DEVIJVER, P.A., and Kittler, J. Pattern Recognition : A Statistical Approach. Prentice Hall Int. 1982.

- DEWEY, J. Democracia e Educação. Ed. Nacional. São Paulo. 1979.
- DEWEY, J. Psychology and social practice. Psychological Review, 1900.
- DOLZ, J. e SCHNEUWLY, B. Sequências didáticas para o oral e a escrita: apresentação de um procedimento. In: SCHNEUWLY, B. e DOLZ, J., Gêneros orais e escritos na escola. Campinas, SP: Mercado das Letras, 2004.
- DUDA, R.O., HART, P.E. and STORK, D.G. Pattern Classification. 2nd Ed. Wiley, USA, 2001.
- DUQUE, N. J. e GUZMAN, J. C. AI Planning for Automatic Generation of Customized Virtual Courses, *Frontiers in Artificial Intelligence and Applications*. IOS Press, Vol 117. Ámsterdam, 2005.
- DUQUE, N. O. e JIMÉNEZ, D. J. Artificial intelligence for automatic generation of Customized courses. *Proceedings of the ED-MEDIA 2006-World Conference on Educational Multimedia, Hypermedia & Telecommunications*, USA, 2006.
- EBERSPÄCHER, H. F. e KAESTNER, C. A. A. A arquitetura de um sistema de autoria para construção de tutores inteligentes hipermídia e seu posicionamento na informática educativa - IV Congresso RIBIE, Brasília, 1998
- FAUSETT, L. V. Fundamentals of neural networks. Prentice Hall, 1994.
- FONSECA, U. A. Sistema Tutor Inteligente baseado em aprendizado por reforço. Dissertação de Mestrado. Universidade Federal de Goiás. Goiânia, Brasil, 2007.
- FONTENLA, J., CAEIRO, M. and LLAMAS, M. A SOA Architecture to improve the tailorability and extensibility of e-learning Systems. *IEEE Latin-America Transactions*, vol. 8, nº 2, 2010.
- FU, K. S. Digital Pattern Recognition. 2nd Ed., Springer Verlag, 1980.
- FU, L. M. Neural networks in computer intelligence. McGraw-Hill, 1994.
- GAGE, N. L. Handbook of research on teaching. Rand McNally, Inc., Chicago, USA, 1963.
- GARRISON, D. R., & Shale, D. Mapping the boundaries of distance education: Problems in defining the field. *The American Journal of Distance Education*, 1987.
- GIRAFFA, L. M. M & VICCARI, R. M. The Use of Agents Techniques on Intelligent Tutoring Systems. Instituto de Informática-PUC/RS. Porto Alegre, 1997.
- GIRAFFA, L. M. M. Fundamentos de Teorias de Ensino-Aprendizagem e sua Aplicação em Sistemas Tutores Inteligentes. Instituto de Informática-UFRGS. Porto Alegre. Novembro, 1995.
- GIRAFFA, L. M. M. Uma arquitetura de tutor utilizando estados mentais. PPGC da UFRGS.

- Porto Alegre, 1999.
- GOLDSTEIN, E. B. Sensation and perception. Pacific Grove, CA : Brooks/Cole Publishing Company, 1999.
- GONZALES, R. C. e WOODS, R. E. Processamento digital de imagens. 3ª Ed. São Paulo, Pearson Prentice Hall, 2010.
- GONZÁLEZ, L. A. G. and RUGGIERO, W. V. Collaborative e-learning and learning objects. IEEE Latin-America Transactions, vol. 7, nº 5, 2009.
- GREGORY, R. J., (2007). Psychological Testing: History, Principles, and Applications. 5ª Edition, Pearson.
- GRIFFITHS, D. V. and SMITH, I. M. Numerical Methods for Engineers. 2nd edition, London, Chapman and Hall, 2006.
- HAYKIN, S. Redes Neurais: princípios e prática. 2.ed. – Porto Alegre, RS, Bookman, 2001.
- HEBB, D. O. The organization of behavior. Wile, New York, New York: 1949.
- HIMONAS, A., HOWARD, A. Cálculo: conceitos e aplicações. Tradução Biasi, R. S., Rio de Janeiro, LTC, 2005.
- HODGES, W. Model theory. Cambridge University Press, Cambridge 1997.
- HOGAN, T. P., (2006). Introdução a prática de testes psicológicos Rio de Janeiro, LTC.
- HOLLAND, J. G. & SKINNER, B. F. The analysis of behavior: a program for self-instruction. New York, NY : McGraw-Hill Book Company, Inc., 1961.
- HORTON, W. K. Designing Web-based Training. USA, Wiley, 2000
- JIMÉNEZ, J. Un Modelo de Planificación Instruccional usando Razonamiento Basado en Casos en Sistemas MultiAgente para entornos integrados de Sistemas Tutoriales Inteligentes y Ambientes Colaborativos de Aprendizaje Apoyados em Computador. Tesis doctoral. Colombia. 2006.
- JONASSEN, D. H. Applications and limitations of hypertext technology for distance learning. Trabalho apresentado no Distance Learning Workshop, Armstrong Laboratory, San Antonio, USA, 1992.
- JONASSEN, D. H. The handbook of research for educational communications and technology. The Association for Educational Communications and Technology, Bloomington, USA, 2001.
- JONASSEN, D. H., WANG, S. The Physics Tutor: Integrating Hypertext and Expert Systems, Journal of Educational Technology Systems, vol. 22(1), pp. 19-28, 1993.
- JUNG, C. G. O homem e seus símbolos. Tradução de Pinho, M. L. 2ª Ed. Rio de Janeiro,

Nova Fronteira, 2008

JUNG, C. G., *Psychological Types*, Bollingen Series XX, volume 6, Princeton University Press, 1971, 1976.

JUNG, C. G., *Psychological Types*, trans. By H. G. Baynes, ver. By R.F.C. Hull. Princeteon, NJ: Princeton University Press, 1971 (originally published in 1921).

KEIRSEY, D. and BATES, M. *Please Understand Me – Character & Temperament Types*, Intelligence, Prometheus Nemesis Book Company, USA, 1984.

KEIRSEY, D. *Please Understand Me II – Temperament, Character, Intelligence*, Prometheus Nemesis Book Company, USA, 1998.

KOHONEN, T. *Self-Organizing Maps*. Berlim: Springer, 2001

KOZULIN, A., GINDIS, B., AGEYEV, V., MILLER, S. *Vygotsky's Educational Theory in Cultural Context*, Cambridge: Cambridge University Press. 2003

LAZARUS, R. S. e MONAT, A. *Personalidade*, Zahar Editores, Rio de Janeiro, 1984.

LEE, W. W. & Owens, D. L. *Multimedia-based instructional design: computer-based training, web-based training, and distance learning*. Jossey-Bass/Pfeiffer, San Francisco : CA, USA, 2000.

LIBÂNEO, J. C. *Didática*. São Paulo. Editora Cortez. 1994.

LUCENA, M W. F. P. *O uso das tecnologias da informática para o desenvolvimento da educação*. Rio de Janeiro: COPPE/UFRJ, 1994.

LUGGER, G. F. *Inteligência Artificial: estruturas e estratégias para a solução de problemas complexos*. 4ª Ed – Porto Alegre, Bookman, 2004

MALPASS, L. F.; Hocutt, M. O.; Martin, E. & Givens, P. *O comportamento humano: um programa para a auto-aprendizagem*. Editora Renes, Rio de Janeiro, 1970.

MARKLE, S. M. *Good frames and bad: a grammar of frame writing*. New York, NY: John Wiley & Sons, Inc., 1969.

MARTINS, W.; MELO, F. R. ; MEIRELES, V. ; NALINI, L. E. G. . *A Novel Hybrid Intelligent Tutoring System And Its Use Of Psychological Profiles And Learning Style*. In: ITS 2004 - 7º International Conference On Intelligent Tutoring Systems, 2004, MACEIÓ - AL - BRAZIL. *Intelligent Tutoring Systems: 7th International Conference, ITS 2004, Maceió Alagoas Brazil, August 30 - September 3, 2004*. Proceedings, vol. 3220. p. 830-832, 2004.

MCCULLOCH, W. S. ; PITTS, W. H. *A logical calculus of the ideas immanent in neural nets*, Bulletin of Mathematical Biophysics, vol. 5, 1943.

- MEIRELES, V. Sistemas Tutores Inteligentes Híbridos Baseados em Estilos de Aprendizagem. Dissertação de Mestrado. Universidade Federal de Goiás. Goiânia, Brasil, 2003.
- MELO, F. R. Sistemas Tutores Inteligentes Híbridos Baseados em Características Psicológicas. Dissertação de Mestrado. Universidade Federal de Goiás. Goiânia, Brasil, 2003.
- MELO, F. R. MARTINS, W. NALINI, L. E. G. MEIRELES, V. Generalizador Neural de Espaços de Aprendizagem em Sistemas Tutores Inteligentes, XVII Simpósio Brasileiro de Informática na Educação - SBIE. Brasília. 2006.
- MELO, F. R., MEIRLES, V., MARTINS, W. e NALINI, L. E. G. Sistemas inteligentes na organização de conteúdos didáticos personalizados. Revista de Ciências Exatas e Tecnologia, vol II, nº 2, Valinhos, SP, 2007.
- MELO, F. R.; FLÔRES, E. L.; CARVALHO, S. D. Multilevel content's structure for personalization in connexionist intelligent tutor systems. In: 8th International Conference on Information Systems and Technology Management, 2011, São Paulo. Abstract and Proceedings of 8th CONTECSI. São Paulo : TECSI EAC FEA USP, 2011.
- MELO, F. R.; FLÔRES, E. L. ; CARVALHO, S. D.; MARTINS, W.; CARRIJO, G. A.; VEIGA, A. C. P. Multilevel didatic content for reative personalization on intelligent tutor systems. (aprovada e em fase de publicação) In: SBA - Revista da Sociedade Brasileira de Automática. São Paulo: UNICAMP, 2012.
- MÉNDEZ, N. D. D., CARRANZA, D. O., VICARI, R. e SILVEIRA, R. A. Modelo Inteligente Generico para Adaptatividad de Cursos Virtuales. Novas Tecnologias na Educação. vol. 6, nº 1, CINTED-UFRGS, 2008
- MINSKY, M. L.; PAPERT, S. S. Perceptrons: an introduction to computational geometry. MIT Press, Cambridge, MA 1969.
- MYERS, I. B., and MYERS, P. B. Introdução à Teoria dos Tipos Psicológicos; tradução e edição da Coaching Psicologia Estratégica, São Paulo, 1997.
- MYERS, I. B. and McCaulley, M. H. Manual: A Guide to the Development and Use of the Myers-Briggs Type Indicator. Palo Alto, Ca.: Consulting Psychologists Press, 1985.
- OAKESHOTT, M. Learning and teaching. Em R. S. Peters (Ed.) The Concept of Education. London: Routledge & Kegan Paul, 1967.
- OBUKHOVA, L. F., and KOREPANOVA, I. A. The Zone of Proximal Development: A Spatiotemporal Model. Journal of Russian & East European Psychology, 2009.



- PARK, O. "Functional Characteristics of Intelligent Computer-Assisted Instruction: Intelligent Features", Educational Technology, pp. 7-14. June 1988.
- PARK, O., PEREZ, R. S. and SEIDEL, F. J, "Intelligent CAI: Old Wine in New Bottles or a New Vintage ?", em KEARSLEY, G., "Artificial Intelligence and Instruction - Applications and Methods" , 1987.
- PATTEN, J. V., Chao, C. I. and REIGELUTH, C. M. A review of strategies for sequencing and synthesizing instruction. Review of Educational Research, 56(4), 437-471, 1986
- PEDRINI, H. e SCHWARTZ, W. R. Análise de imagens digitais – Princípios, algoritmos e aplicações. São Paulo, Thomson Learning, 2008.
- PERRATON, H. A theory for distance education. Em D. Sewart, D. Keegan, & B. Holmberg (Ed.), Distance education: international perspectives. New York: Routledge, 1988.
- PHELAN, K. C.; Mendoza-Diaz, N. V. & Mathews, S. An example of converting a traditional course into distance learning: an open discussion. Trabalho apresentado na 9th Annual International Distance Education Conference, Austin, Texas, USA, 2002.
- PIERCE, W. D. and EPLING, W. F. Behavior analysis and learning. Prentice Hall, Upper Saddle River, New Jersey, USA, 1999.
- PINTO, B. Q., LOPES, C. R., e FERNANDES, M. Planejamento Instrucional Reativo para o Sequenciamento Automático do Currículo. XIV Simpósio Brasileiro de Informática na Educação - NCE - IM/UFRJ, 2003.
- QUINDERE, P. S. G. Adaptabilidade Temática em Sistemas Tutores Inteligentes Híbridos Dissertação de Mestrado. Universidade Federal de Goiás. Goiânia, Brasil, 2008.
- REZENDE, S. O. Sistemas Inteligentes – fundamentos e aplicações. Barueri, SP : Manole, 2005.
- RISSOLI, V. R. V. Uma proposta metodológica de acompanhamento personalizado para aprendizagem significativa apoiada por um assistente virtual de ensino inteligente. Tese de doutorado, Universidade Federal do Rio Grande do Sul, Porto Alegre, Brasil, 2007
- ROSENBERG, M. J. E-Learning strategies for delivery knowledge in the digital age. McGraw-Hill, New York : NY, USA, 2001.
- ROSENBERG, M. J. E-Learning strategies for delivery knowledge in the digital age. McGraw-Hill, New York : NY, USA, 2001.
- ROSENBERG, M. J. E-Learning strategies for delivery knowledge in the digital age. McGraw-Hill, New York : NY, USA, 2001.

- ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological Review*, v. 65, 1958.
- ROSSEAU, J. J. Discurso sobre a origem e os fundamentos da desigualdade entre os homens. In: Rousseau (Os pensadores). Abril Cultural. São Paulo. 1983.
- RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning internal representation by error propagation. In *Parallel distributed processing: explorations in the microstructures of cognition*. MIT Press, 1986.
- RUSSEL, S. e NORVIG, P. *Inteligência Artificial*. Tradução da segunda edição. Rio de Janeiro, Elsevier, 2004.
- SAVIANI, D. *Pedagogia Histórico Crítica: primeiras aproximações*. São Paulo: Editora Cortez, 1991.
- SCHRAMM, W. The research on programmed instruction: an annotated bibliography. Office of Education (OE-34034), Government Printing Office, Washington, D. C., USA, 1964.
- SCHULTZ, D. P. e SCHULTZ, S. E., (2008). *Teorias da Personalidade*, São Paulo, Cengage-Learning.
- SHERRY, L. Issues in distance learning. *International Journal of Educational Telecommunications*, 1996.
- SILVA, S. M., SILVA, E. M. e SILVA, E. M. *Matemática básica para cursos superiores*. 1ª Ed., São Paulo, Atlas, 2008.
- SKINNER, B. F. Are theories of learning necessary? *Psychological Review*, 57, 193-216, 1950.
- SKINNER, B. F. *The technology of teaching*. New York, Appleton-Century-Crofts, 1968.
- TAYLOR, R. P. *The computer in school: tutor, tools, tutor*. New York: Teachers College Press, 1980.
- TEIXEIRA, O. S., JOTA, F. G. and TEIXEIRA, M. H. Modelagem, controle e otimização do processo de reaquecimento de placas. *SBA Controle & Automação*, vol 18, nº 1, São Paulo, 2007.
- THORNDIKE, E. L. *Educational psychology*. vol. II. The psychology of learning. New York : NY, Teachers College, 1921.
- THORNDIKE, E. L. *Human learning*. New York : NY, Appleton-Century-Crofts, 1931.
- TOSCHI, M. S. Processos Comunicacionais em EAD: políticas, modelos e teorias. *Revista Latino Americana de Tecnologia Educativa*, Vol. 3, nº 2, 2004.

- VARGAS, J. A. R. and HEMERLY, E. M. Observação adaptativa neural com convergência assintótica na presença de parâmetros variantes no tempo e distúrbios. SBA Controle & Automação, vol 19, nº 1, São Paulo, 2008.
- VASILEVA, T et al. Experimental Data About Knowledge Evaluation in a Distance Learning System, Faculty of Electrical Engineering and Computer Science, Skopje, Macedonia, 2001.
- VASSILEVA, J: Reactive Instructional Planning to Support Interacting Teaching Strategies, in Proceedings of the 7-th World Conference on AI and Education, Washington, 1995.
- VICCARI, R. M. & GIRAFFA, L. M. M. Sistemas Tutores Inteligentes: Abordagem Tradicional vs. Abordagem de Agentes. XII Simpósio Brasileiro de Inteligência Artificial. Curitiba. Outubro, 1996.
- VICCARI, R. M. Um Tutor Inteligente para a programação em Lógica-Idealização, Projeto e Desenvolvimento, Universidade de Coimbra, 1990. (Tese de Doutorado).
- VYGOSTSKY, L. S. A formação social da mente. 6ª edição. São Paulo. Martins Fontes. 1996.
- VYGOSTSKY, L. S. Pensamento e linguagem. 6ª edição. São Paulo. Martins Fontes. 1998.
- VISHNU, K. L. et. All. An Instrument for Assessing Knowledge Gain in a First Course in Circuit Theory. Department of Electrical and Computer Engineering Old Dominion University, 2002.
- WALPOLE, R. E., MYERS, R. H., MYERS, S. L., YE, K. Probability & Statistics for Engineers & Scientistis. 8ª Edition, Pearson. 2007.
- WIDROW, B. & HOFF, M. E. Adaptative switching circuits. Institute of Radio Engineers, Western Eletronic Show and Convention, 1960.
- ZHANG, Y., e FARREL, J. N. Conteúdos Didáticos: uma comparação entre estudantes de ensino à distancia e estudantes presenciais. Contrapontos - volume 3 - n. 2 - p. 297-311 - Itajaí, 2003.

# ANEXO 1

## IDENTIFICAÇÃO DO PERFIL PESSOAL

### A) Composição Tipológica

- **Variáveis**

#### **Energia ( E - I )**

Para qual sentido, primariamente, as pessoas direcionam suas energias?

Esta questão tem por objetivo descobrir se a energia é direcionada externamente, no mundo ativo, por meio das palavras ou se é direcionada internamente, no mundo dos pensamentos e emoções. Quando a energia é direcionada para o exterior, ela é chamada de extroversão, denotada pela letra E. Se for direcionada para o interior é chamada de introversão, denotada pela letra I.

#### **Atenção ( S - N )**

Como as pessoas processam informações?

Esta questão tem por objetivo descobrir se o processamento é voltado para conhecer novos fatos em termos familiares ou se é voltado para visualizar novas possibilidades e potencial. O primeiro caso é do tipo “Sensitivo”, denotado pela letra S (Sensation). O segundo caso é o tipo “Intuitivo”, denotado pela letra N (Intuition).

### **Decisão ( T – F )**

Como as pessoas decidem?

Esta questão tem por objetivo descobrir se as decisões são fundamentadas na lógica e considerações objetivas ou fundamentadas em valores pessoais. O primeiro caso é classificado como tipo “Pensamento”, denotado pela letra T (Thinking). O segundo caso, tende para o tipo “Sentimento”, denotado pela letra F (Feeling).

### **Vivência ( J – P )**

Como as pessoas organizam sua vida?

As pessoas podem organizar suas vidas de forma estruturada, tomando decisões conscientes dos resultados ou então de forma flexível e exploratória. No primeiro caso, é classificado como tipo “Julgador”, denotado pela letra J (Judgement) e o segundo caso é do tipo “Perceptivo”, denotado pela letra P (Perception).

- **Tipologia psicológica Myers-Briggs**

Esta tipologia (Myers & Briggs, 1997) apresenta uma descrição geral das principais características de cada tipo representado pelas 16 combinações possíveis das variáveis psicológicas.

### **ENFJ**

O tipo ENFJ é composto dos elementos extroversão, intuição, sentimento e julgar. Proeminente líder de grupos é receptivo e responsável, podendo apresentar uma nova proposta ou liderar um debate grupal com facilidade e tato. Procura tratar as coisas com a devida consideração para com os sentimentos das pessoas. São excelentes comunicadores, líderes naturais que sabem motivar e persuadir os outros. É consciencioso, metódico e resoluto, não perdem de vista seus objetivos e espera que os outros façam o mesmo. Gosta de trabalhar com

pessoas criativas e vivazes em um ambiente ativo, desafiador, e que tenha atividades variadas. Quando confrontado com reveses consegue encará-los como um novo desafio. Rápido para executar tarefas, está sempre com pressa; tende a ficar impaciente e frustrado com a lentidão.

## **ENFP**

O tipo ENFP é composto dos elementos extroversão, intuição, sentimento e percepção. É capaz de fazer quase qualquer coisa que o interesse e geralmente pode encontrar fortes razões para justificar qualquer coisa que queira. Sabe se comunicar muito bem e inspirar ações. Valoriza a liberdade e a autonomia. Costuma confiar mais em sua capacidade de improvisação do que em seu preparo anterior. Possui uma imaginação rica e uma grande agilidade mental. Pode estar indo para uma direção em um momento e, no outro, seguir o caminho inverso.

## **ENTJ**

O tipo ENTJ é composto dos elementos extroversão, intuição, pensamento e julgamento. Sua energia básica é dirigida para liderar. Geralmente é bom em quase tudo que exija raciocínio lógico e comunicação inteligente. Costuma ser bem informado e gosta de aumentar sempre seu conhecimento sobre as coisas. Movimenta-se com naturalidade na direção de posições que lhes permitam tomar a dianteira e mobilizar recursos para atingir objetivos ambiciosos. Aprecia a confrontação e gosta de se envolver em intercâmbios intelectualmente estimulantes. Encara os obstáculos como desafio; fica atento à resolução dos problemas, tira conclusões e segue em frente. Monta um plano de ação para realizar as tarefas e consegue finalizá-las antes do previsto. Busca soluções estratégicas para conseguir o que quer. Não aceita ser convencido, a não ser por argumentações razoáveis e coerentes. É engenhoso e competente para resolver problemas complexos.

**ENTP**

O tipo ENTP é composto dos elementos extroversão, intuição, pensamento e percepção. É inovador e engenhoso para inventar novas maneiras de fazer as coisas, têm uma excelente habilidade analítica e expediente para resolver problemas desafiadores, especialmente os teóricos. Gosta de mudança e variedade e resiste a fazer qualquer coisa que o limite, aprisione ou aborreça. Gosta de enfrentar riscos e está atento a todas as possibilidades. Valoriza a liberdade e a independência. Tende a voltar-se para um novo interesse a cada instante. É habilidoso para encontrar razões lógicas para qualquer coisa que queiram, mas pode negligenciar atribuições de rotina.

**ESFJ**

O tipo ESFJ é composto dos elementos extroversão, sensação, pensamento e julgamento. É o mais sociável de todos os tipos. Gosta de fazer as coisas de modo organizado e rotineiro. É solidário e diligente em tarefas organizacionais e não se desvia das regras sociais. Seu maior interesse é por coisas que afetam direta e visivelmente a vida das pessoas. Não gosta de lidar com problemas em bases teóricas ou filosóficas.

**ESFP**

O tipo ESFP é composto dos elementos extroversão, sensação, pensamento e percepção. Emana entusiasmo e otimismo. É polido, engenhoso, inteligente e muito generoso. Dá-se melhor em situações que necessite bom senso e habilidade prática. Tem senso prático e gosta de novas experiências. Enfatiza o positivo.

**ESTJ**

O tipo ESTJ é composto dos elementos extroversão, sensação, pensamento e julgamento. Sua maior habilidade está na administração. Está mais voltado para o ambiente externo que o cerca e é de muita responsabilidade. São bons para tomar decisões objetivas e

esforçam-se para atingir seus objetivos. Gostam de enfrentar desafios e sabem como conseguir o que querem. É prático e realista e não se interessa por assuntos para os quais não vê uso, mas pode aplicar-se à eles quando necessário.

## **ESTP**

O tipo ESTP é composto dos elementos extroversão, sensação, pensamento e percepção. É altamente competitivo, empreendedor e negociador por excelência. Procura tirar proveito das situações, resolvendo de modo imediato problemas objetivos. Aprecia coisas mecânicas e esportes. Não gosta de longas explicações. Prefere lidar com coisas reais que podem ser manuseadas, montadas e desmontadas. Gosta de enfrentar riscos, desafios e aventuras. Usam a lógica para resolver os problemas concretos e chegam rapidamente ao âmago das questões. Têm ótima memória para registrar fatos. Trabalham bem sob pressão. Segue as regras apenas quando elas servem para fazê-los chegar no ponto almejado. Gostam de ocupações agitadas e estressantes que envolvam resistência, força e risco.

## **INFJ**

O tipo INFJ é composto dos elementos de introversão, intuição, sentimento e julgamento. É um tipo sensível, profundo e algumas vezes místico. Sua personalidade complexa é sempre intrigante para os outros e também para ele próprio. É sério ao considerar valores pessoais e convicções. Tem imaginação e vida interior rica e valoriza a integridade pessoal. O maior esforço é voltado para o trabalho, no qual o faz melhor em ambiente pouco agitado. Consciente e preocupado com os outros, é notado pelos seus firmes princípios e tende a liderar um grupo por suas claras convicções de como melhor servir o bem comum.

## **INFP**

O tipo INFP é composto dos elementos introversão, intuição, sentimento e percepção. Tem uma alta capacidade para atenção e possui um alto senso de honra, derivado de valores internos. Detesta regras, ordens, planejamentos e prazos. Gosta de aprender e estar envolvido



em projetos próprios. Não apreciam regras, ordens, programação e prazo. Valorizam a autonomia, não gostam de interrupções e preferem fazer as coisas sozinhos para ter certeza de que serão realizadas direito. Conseguem trabalhar pacientemente em tarefas complexas. Tem convicções apaixonadas e persegue ideais.

## **INTJ**

O tipo INTJ é composto dos elementos de introversão, intuição, pensamento e julgamento. É o mais seguro e pragmático de todos os tipos. Um construtor de sistemas e implementador de modelos teóricos. Independente e individualista, tem muita perspicácia e visão. É hábil em criar teorias e métodos. Estimula a si mesmo e aos outros para alcançar seus objetivos e autodesenvolvimento. É engenhoso e criativo ao resolver problemas.. Geralmente tem idéias originais e grande motivação para concretizá-las. Quando está atuando em áreas de seu interesse possui excelente força para organizar uma tarefa e concluí-la sem auxílio. Prefere sempre fazer as coisas a seu modo.

## **INTP**

O tipo INTP é composto dos elementos introversão, intuição, pensamento e percepção. Valoriza a precisão no pensar e no falar. Para ele, é importante ser preciso e conciso. Têm uma vida interior bastante rica de pensamentos e idéias. Sua curiosidade é dirigida à busca do entendimento do Universo. Aprecia as atividades teóricas ou científicas, gosta de resolver problemas por meio da análise lógica.

## **ISFJ**

O tipo ISFJ é composto dos elementos introversão, sensação, sentimento e julgamento. Frequentemente trabalha nos bastidores, ajudando os outros. Demonstra respeitar a ética profissional e completa suas tarefas nos prazos. Seu interesse não é técnico, mas relacional. Tem excelente memória para detalhes. É muito caprichoso, leal, autodisciplinado e atencioso. Age de acordo com o esperado e não questiona a maneira convencional de fazer as coisas.

## **ISFP**

O tipo ISFP é composto dos elementos introversão, Sensação, Sentimento e Perceber. Interessado nas artes finas, expressa-se primariamente por meio de ação ou na forma de arte. Seu sentido é mais aguçado do que os outros tipos. Paciente, sabe aceitar as coisas como são e não faz julgamentos. Geralmente evita desavenças e não impõe aos outros suas opiniões e valores. É modesto e não aprecia liderar, porém é fiel seguidor. Pode ser um pouco lento na realização de tarefas, por gostar de apreciar o momento presente e não querer estragá-lo com excessiva pressa. Vive no presente e aprecia as coisas simples da vida. É muito exigente consigo mesmo e busca a perfeição. Sente-se encurralado por regras excessivas, estruturas inflexíveis e burocracia. Lida melhor com o que é mais urgente no momento. Pode se sentir sobrecarregado pela sua própria indecisão, falta de direção e desorganização.

## **ISTJ**

O tipo ISTJ é composto dos elementos introversão, sensação, pensamento e julgamento. Geralmente é calado e sério, buscando atividades que exijam concentração e detalhamento. Gosta de atividades práticas e lógicas nas quais estejam bem claros “o que é” e “como deve fazer”. Procura manter todas as suas atividades muito bem organizadas e aceita trabalhos que exijam altos graus de responsabilidade. Dedicar-se à uma atividade de maneira disciplinada e realista. Têm facilidade de concentração.

## **ISTP**

O tipo ISTP é composto dos elementos introversão, sensação, pensamento e percepção. De ação impulsiva, para ele vida deveria ser seguir os impulsos em lugar de propósitos. As pessoas deste tipo preferem agir do que conversar. Gostam de aventura e desafios. Resolvem bem as crises. Se saem bem em trabalhos com ferramentas, máquinas ou quaisquer outros que requerem habilidade manual. Acumulam informações e acontecimentos na memória. Interessados em causa e efeito e em como e porque as coisas mecânicas funcionam, dedicam-se em organizar fatos e coisas utilizando princípios lógicos e práticos. São quietos; isolam-se para observar os acontecimentos.

## B) Classificador de Keirsey

O questionário é composto de setenta questões com duas alternativas. Foi elaborado por David Keirsey e Marilyn Bates [Keirsey, 1998].

- 1- Numa festa você
  - ☐ interage com muitos, incluindo estranhos
  - ☐ interage com poucos, seus conhecidos
- 2- Você se considera mais
  - ☐ realista do que especulativo
  - ☐ especulativo do que realista
- 3- É muito pior
  - ☐ ter a "cabeça nas nuvens", ser sonhador
  - ☐ ser escravo da rotina
- 4- Você é mais impressionado(a) por
  - ☐ princípios
  - ☐ emoções
- 5- Você é mais atraído(a) pelo
  - ☐ convincente
  - ☐ comovente
- 6- Você prefere trabalhar
  - ☐ com prazos de entrega
  - ☐ sem amarrações
- 7- Você tende a escolher
  - ☐ cuidadosamente
  - ☐ impulsivamente
- 8- Nas festas você geralmente
  - ☐ permanece até tarde, com energia crescente
  - ☐ retira-se mais cedo, com energia decrescente
- 9- Você se sente mais atraído(a) por
  - ☐ pessoas sensatas
  - ☐ pessoas criativas

- 10- Você se interessa mais pelo
- ☐ real
  - ☐ possível
- 11- Ao julgar os outros, você se inclina mais para as
- ☐ leis do que para as circunstâncias
  - ☐ circunstâncias do que para as leis
- 12- Ao tratar com outras pessoas, você tende a ser mais
- ☐ objetivo(a)
  - ☐ pessoal
- 13- Você é mais
- ☐ pontual
  - ☐ descompromissado(a)
- 14- Incomoda-lhe mais ter as coisas
- ☐ inacabadas
  - ☐ concluídas
- 15- No seu grupo social você em geral
- ☐ está a par do que acontece com os outros
  - ☐ está por fora das novidades
- 16- Ao realizar as tarefas de rotina, você prefere fazê-las
- ☐ da maneira usual
  - ☐ da sua própria maneira
- 17- Os escritores deveriam
- ☐ dizer as coisas com clareza
  - ☐ expressar as idéias com o uso de analogias
- 18- Você é mais atraído(a)
- ☐ pela consistência das idéias
  - ☐ pelas relações humanas harmoniosas
- 19- Você se sente mais confortável fazendo julgamentos baseados
- ☐ na lógica
  - ☐ em valores pessoais
- 20- Você prefere as coisas
- ☐ negociadas e decididas
  - ☐ não negociadas e indefinidas

- 21- Você se definiria como mais
- ☐ sério(a) e firme
  - ☐ condescendente
- 22- Ao telefonar você
- ☐ está seguro(a) de que dirá tudo o que precisa
  - ☐ ensaia de antemão o que irá dizer
- 23- Os fatos
- ☐ "falam por si mesmos"
  - ☐ ilustram princípios
- 24- Os visionários o(a)
- ☐ aborrecem
  - ☐ fascinam
- 25- Você é mais frequentemente uma pessoa
- ☐ calculista
  - ☐ acolhedora
- 26- É pior ser
- ☐ injusto(a)
  - ☐ impiedoso(a)
- 27- Usualmente, deve-se permitir que as coisas aconteçam
- ☐ por seleção e escolha cuidadosa
  - ☐ fortuitamente e ao acaso
- 28- Você se sente melhor
- ☐ depois de ter comprado, adquirido
  - ☐ tendo a opção de comprar
- 29- Na companhia de outras pessoas, você
- ☐ inicia a conversação
  - ☐ espera ser abordado(a)
- 30- O senso comum é
- ☐ raramente questionável
  - ☐ frequentemente questionável
- 31- Com frequência, as crianças
- ☐ não se fazem úteis o suficiente
  - ☐ não exercitam suficientemente a imaginação

- 32- Ao tomar decisões, você se sente mais confortável seguindo
- ☐ as normas
  - ☐ a intuição
- 33- Você se considera mais
- ☐ firme do que gentil
  - ☐ gentil do que firme
- 34- Você considera mais admirável a habilidade
- ☐ para se organizar e ser metódico(a)
  - ☐ a habilidade para se adaptar e ser maleável
- 35- Você valoriza mais o
- ☐ fechado, definido
  - ☐ aberto, com opções
- 36- Uma interação nova e pouco rotineira com outras pessoas
- ☐ o(a) estimula e revigora
  - ☐ consome as suas reservas de energia
- 37- Você é, mais frequentemente,
- ☐ uma pessoa do tipo prático
  - ☐ uma pessoa do tipo fantasioso
- 38- Você tem uma maior propensão a ver
- ☐ como as outras pessoas são úteis
  - ☐ como os outros vêem
- 39- É mais satisfatório
- ☐ discutir um assunto a fundo
  - ☐ chegar a um acordo sobre um assunto
- 40- O que mais comanda você é
- ☐ a sua cabeça
  - ☐ seu coração
- 41- Você se sente mais à vontade com um trabalho
- ☐ que siga um acordo pré-estabelecido
  - ☐ que se desenvolva sem um plano estabelecido
- 42- Você tende a buscar
- ☐ sistemático
  - ☐ imprevisto

- 43- Você prefere
- ☐ muitos amigos com contatos superficiais
  - ☐ poucos amigos com contatos intensos
- 44- Você se deixa guiar mais pelos
- ☐ fatos
  - ☐ princípios
- 45- Você se interessa mais por
- ☐ produção e distribuição
  - ☐ projeto e pesquisa
- 46- É mais elogioso ser considerado(a)
- ☐ uma pessoa muito lógica
  - ☐ uma pessoa muito sentimental
- 47- Você se autovaloriza mais por ser
- ☐ decidido(a), firme
  - ☐ dedicado(a), devotado(a)
- 48- Com mais frequência, você prefere
- ☐ uma afirmação final e inalterável
  - ☐ uma afirmação preliminar e provisória
- 49- Você se sente mais confortável
- ☐ depois de tomar uma decisão
  - ☐ antes de tomar uma decisão
- 50- Com ou para pessoas que não conhece, você
- ☐ conversa longamente e com facilidade
  - ☐ tem pouco a dizer
- 51- Você confia mais em
- ☐ sua experiência
  - ☐ sua intuição
- 52- Você se considera
- ☐ mais prático(a) do que criativo(a)
  - ☐ mais criativo(a) do que prático(a)
- 53- Você aprecia mais em outra pessoa
- ☐ a clareza do raciocínio
  - ☐ a força dos sentimentos

- 54- Você está mais inclinado(a) a ser
- ☐ justo(a), imparcial
  - ☐ compreensivo(a)
- 55- Na maioria das vezes, é preferível
- ☐ ter certeza de que esteja tudo acertado
  - ☐ deixar que as coisas simplesmente aconteçam
- 56- Nos relacionamentos, a maior parte das coisas deveriam ser
- ☐ renegociáveis
  - ☐ casuais e circunstanciais
- 57- Quando o telefone toca você
- ☐ se apressa para atender primeiro
  - ☐ espera que alguém atenda
- 58- Você aprecia mais em si mesmo(a)
- ☐ forte senso de realidade
  - ☐ a imaginação viva
- 59- Você se sente mais atraído(a)
- ☐ pelos fundamentos
  - ☐ pelas implicações
- 60- Parece-lhe pior ser muito
- ☐ apaixonado(a), veemente
  - ☐ objetivo(a)
- 61- Você se vê, basicamente, como
- ☐ cabeça-dura
  - ☐ coração-mole
- 62- Atrai-lhe mais uma situação
- ☐ estruturada e programada
  - ☐ não estruturada e imprevista
- 63- Você se considera uma pessoa mais
- ☐ rotineira do que original
  - ☐ original do que rotineira
- 64- Você tende a ser uma pessoa
- ☐ de fácil aproximação
  - ☐ algo reservada



- 65- Você prefere textos
- ☐ mais literais
  - ☐ mais figurativos e simbólicos
- 66- É mais difícil para você
- ☐ identificar-se com os outros
  - ☐ utilizar-se dos outros
- 67- Você prefere possuir
- ☐ a clareza da razão
  - ☐ a força da compaixão
- 68- É maior defeito
- ☐ não saber discernir
  - ☐ ser crítico
- 69- Você prefere os acontecimentos
- ☐ planejados
  - ☐ imprevistos
- 70- Você se considera uma pessoa mais
- ☐ ponderada e cuidadosa do que espontânea
  - ☐ espontânea do que cuidadosa e ponderada

### **Folha de respostas**

Após a realização do teste, as respostas as questões são tabuladas conforme o exemplo de folha de respostas preenchida no Quadro A1. Cada coluna agrupa um número de questões que fará a definição do tipo. As respostas “a” e “b” são contabilizadas ao final de cada coluna. Após as somas de cada coluna, o valor maior define a letra de cada dicotomia. No exemplo, o primeiro par de colunas, na qual o resultado é 6 e 4 fica como está. Os resultados do segundo, quarto e sexto pares são transportados para baixo dos resultados dos pares de número 3, 5 e 7, respectivamente, e somados. Os valores finais são transformados em percentagens e transferidos para o quadrinho dos tipos. O resultado revela uma pessoa do tipo ESFP (Tipologia Myers-Briggs). No exemplo da folha de resposta, a discriminação entre as variáveis J e P é forte, enquanto que a discriminação entre T e F é fraca. Às vezes pode ocorrer um empate; por exemplo, o resultado de T/F poderia ter sido 50/50. Nesse caso o tipo é simbolizado por ESXJ, em que o X identifica o vetor sem discriminação clara.

Quadro A1: Folha de Respostas do Teste de Keirsey

1			2						3						4					
	a	B		a	b		a	b		a	b		a	b		a	b		a	b
1	X		2	X		3	X		4		X	5		X	6		X	7	X	
8	X		9	X		10	X		11		X	12		X	13		X	14	X	
15		X	16	X		17	X		18		X	19	X		20		X	21		X
22		X	23		X	24		X	25	X		26	X		27		X	28		X
29		X	30		X	31		X	32	X		33		X	34	X		35		X
36	X		37	X		38	X		39	X		40	X		41		X	42		X
43		X	44	X		45	X		46		X	47		X	48		X	49	X	
50	X		51	X		52		X	53	X		54	X		55	X		56		X
57	X		58		X	59	X		60		X	61		X	62		X	63		X
64	X		65	X		66		X	67		X	68	X		69		X	70		X
	6	4		7	3		6	4		4	6		5	5		2	8		3	7
	↓	↓		↓	↓	→	7	3		↓	↓	→	4	6		↓	↓	→	2	8
	6	4				+	13	7				+	9	11				+	5	15
%	60	40					65	35					45	55					25	75

E	I	S	N	T	F	J	P
60	40	65	35	45	55	25	75

## ANEXO 2

### QUESTIONÁRIO DE HABILIDADES

Questão	Variável
Normalmente, por quanto tempo você utiliza computadores?	1
Como é sua habilidade na utilização do teclado?	
Com qual item você trabalha melhor?	
No geral, como você se classifica em relação ao uso dos computadores	
Você utiliza e-mail?	
Como é seu nível de utilização do Windows?	2
Como é seu nível de utilização do Linux?	
Como é seu nível de utilização de editores de texto tais como Word e similares?	
Como é seu nível de utilização de planilhas eletrônicas tais como Excel e similares?	
Como é seu nível de utilização de editores de apresentação tais como Powerpoint e similares?	
Como é seu nível de utilização de Sistemas Gerenciadores de Banco de Dados tais como Access e similares?	
Como é seu nível de utilização de editores gráficos tais como Coreldraw, Photoshop e similares?	3
Qual sua faixa etária?	
Qual seu grau de instrução?	
Quanto tempo você se dedica à leitura/estudo por semana?	
Qual seu estado civil?	
Qual seu sexo?	7

## ANEXO 3

### FORMULÁRIO DE ATUAÇÃO DOCENTE

Prezado professor,

Conforme foi apresentado previamente a organização do conteúdo multinível, este formulário é uma parte do processo do experimento.

Cada quadro a seguir representa as situações possíveis após a apresentação de um conceito ao estudante. Cada situação equivale ao resultado do teste após a apresentação do conteúdo.

Solicita-se sua colaboração no sentido de preencher o formulário com o seu percentual de indicação para cada um dos outros níveis após o resultado do teste que avalia a situação do estudante depois da apresentação de um nível do conceito.

As indicações devem ter valores na faixa de 0 a 100. Sendo que o valor 0 (zero) indica a menor probabilidade de indicação para o nível e o valor 100 (cem) indica a maior probabilidade de indicação para o nível.

Pede-se sua atenção no preenchimento de cada linha. A soma do percentual de indicação de todos os níveis deve ser sempre um valor igual a 100.

**Nível apresentado: MÉDIO**

Resposta do teste	Próximo nível (probabilidade de indicação)				
	Facilitado	Avançado	FAQs	Exemplos	Próximo
<i>Errada</i>					
<i>Não sabe</i>					
<i>Meio certa</i>					
<i>Certa</i>					

**Nível apresentado: FACILITADO**

Resposta do teste	Próximo nível (probabilidade de indicação)				
	Facilitado	Avançado	FAQs	Exemplos	Próximo
<i>Errada</i>	0,00				
<i>Não sabe</i>	0,00				
<i>Meio certa</i>	0,00				
<i>Certa</i>	0,00				

**Nível do conceito apresentado: AVANÇADO**

Resposta do teste	Próximo nível (probabilidade de indicação)				
	Facilitado	Avançado	FAQs	Exemplos	Próximo
<i>Errada</i>		0,00			
<i>Não sabe</i>		0,00			
<i>Meio certa</i>		0,00			
<i>Certa</i>		0,00			

**Nível apresentado: FAQs**

Resposta do teste	Próximo nível (probabilidade de indicação)				
	Facilitado	Avançado	FAQs	Exemplos	Próximo
<i>Errada</i>			0,00		
<i>Não sabe</i>			0,00		
<i>Meio certa</i>			0,00		
<i>Certa</i>			0,00		

**Nível apresentado: EXEMPLOS**

Resposta do teste	Próximo nível (probabilidade de indicação)				
	Facilitado	Avançado	FAQs	Exemplos	Próximo
<i>Errada</i>				0,00	
<i>Não sabe</i>				0,00	
<i>Meio certa</i>				0,00	
<i>Certa</i>				0,00	