

Universidade de Trás-os-Montes e Alto Douro
ESCOLA DE CIÊNCIAS E TECNOLOGIA
DEPARTAMENTO DE ENGENHARIAS

ADAPT - Plataforma Adaptativa de Ensino à Distância

Tese submetida à Universidade de Trás-os-Montes e Alto Douro
Para obtenção do grau de Doutor em Informática, de acordo com o disposto no
DR - I série-A, Decreto-Lei n.º 74/2006 de 24 de Março e no
Regulamento de Estudos Pós-Graduados da UTAD
DR, 2.ª série - Deliberação n.º 2391/2007

Autor:

Eduardo Jorge Dinis Pratas

Orientador:

Professor Doutor Viriato António Pereira Marinho Marques
Instituto Superior de Engenharia de Coimbra

Coorientador:

Professor Doutor Eduardo José Solteiro Pires
Universidade de Trás-os-Montes e Alto Douro



Vila Real, Março 2019

Universidade de Trás-os-Montes e Alto Douro
ESCOLA DE CIÊNCIAS E TECNOLOGIA
DEPARTAMENTO DE ENGENHARIAS

ADAPT - Plataforma Adaptativa de Ensino à Distância

Tese submetida à Universidade de Trás-os-Montes e Alto Douro
Para obtenção do grau de Doutor em Informática, de acordo com o disposto no
DR - I série-A, Decreto-Lei n.o 74/2006 de 24 de Março e no
Regulamento de Estudos Pós-Graduados da UTAD
DR, 2.a série - Deliberação n.o 2391/2007

Autor:

Eduardo Jorge Dinis Pratas

Orientador:

Professor Doutor Viriato António Pereira Marinho Marques
Instituto Superior de Engenharia de Coimbra

Coorientador:

Professor Doutor Eduardo José Solteiro Pires
Universidade de Trás-os-Montes e Alto Douro

Composição do Júri:

Doutor Vítor Manuel de Jesus Filipe, Universidade de Trás-os-Montes e Alto Douro
Doutora Ana Maria Perfeito Tomé, Universidade de Aveiro
Doutor José Paulo Barroso de Moura Oliveira, Universidade de Trás-os-Montes e Alto Douro
Doutor Viriato António Pereira Marinho Marques, Instituto Politécnico de Coimbra
Doutor Luiz Filipe Rocha de Faria, Instituto Politécnico do Porto
Doutor Luís Filipe Leite Barbosa, Universidade de Trás-os-Montes e Alto Douro

Vila Real, Março 2019

Este trabalho teve como base o projeto ADAPT - Plataforma Adaptativa de Ensino à Distância / GECAD - Grupo de Investigação em Engenharia do Conhecimento e Apoio a Decisão, Ref. PTDC/CPE-CED/115175/2009, financiado por fundos nacionais através da FCT/MCTES (PIDDAC) e cofinanciado pelo Fundo Europeu de Desenvolvimento Regional (FEDER) através do COMPETE – Programa Operacional Fatores de Competitividade (POFC), Ref. FCOMP-01-0124-FEDER-014418.



Agradecimentos

A realização desta tese não teria sido possível sem a existência de vários contributos pelos quais expresso os meus agradecimentos:

Ao Doutor Viriato António Pereira Marinho Marques, meu orientador, pela orientação científica, acompanhamento e pela disponibilidade demonstrada ao longo destes anos de trabalho.

Ao Doutor Eduardo José Solteiro Pires, meu coorientador, pelas correções, críticas e sugestões feitas durante a sua orientação e pela disponibilidade sempre demonstrada.

Aos meus colegas, Pedro Filipe Caldeira Neves, Filipe Azevedo e Luís Dias pelo importante contributo que concederam ao projeto.

Ao Instituto Superior de Engenharia de Coimbra por proporcionar a realização dos vários estudos efetuados e desta forma por possibilitar a concretização deste trabalho.

À FCT por financiar o desenvolvimento do projeto ADAPT com a bolsa de referência PTDC/CPE-CED/115175/2009 FEDER - Eixo I de Programa Operacional Fatores de Competitividade (POFC) / QREN (COMPETE: FCOMP-01-0124-FEDER-014418).

Aos meus pais pelo incentivo, encorajamento e confiança que me facultaram ao longo destes anos.

Por fim, estendo os meus agradecimentos a todos aqueles que das mais variadas formas contribuíram para que a realização deste trabalho fosse possível.

Resumo

A presente tese de Doutorado em Informática tem como objetivo a implementação de um Sistema Tutorial Inteligente (STI), que atinja um nível de eficácia superior aos sistemas tradicionais através da utilização integrada de várias técnicas de Inteligência Artificial (IA).

Os STI são aplicações de computador baseadas em técnicas de IA que captam o perfil e os conhecimentos do aluno e procuram identificar as causas dos seus erros. Estas aplicações tentam seleccionar os conteúdos mais adequados, os exemplos e os problemas, de acordo com o perfil do aluno, cuja apresentação pode incluir simulações e técnicas multimédia. Ao longo dos anos os STI têm vindo a ganhar uma popularidade crescente sendo a sua utilização defendida por várias instituições internacionais (*European Commission, 2011; Organizing for Action, 2012*). Apesar das vantagens que advêm da utilização dos STI, não existe um consenso acerca de que a utilização destes sistemas constitui uma forma mais eficaz de interação educacional. Se por um lado vários estudos como o de *Bolzan e Giraffa (2002)* demonstram que a sua utilização permite obter melhores resultados, por outro lado, vários estudos como o de *VanLehn (2011)* concluíram que a melhoria de desempenho na aprendizagem dos alunos que utilizaram um STI não é significativa.

Este trabalho de Doutorado foi realizado no âmbito do projeto de Investigação e Desenvolvimento *ADAPT - Plataforma Adaptativa de Ensino à Distância, (2016)*, cujo objetivo consistiu na criação de uma plataforma de ensino à distância com a capacidade de adaptar os conteúdos dos cursos às preferências de aprendizagem de cada aluno. A plataforma ADAPT utiliza técnicas de IA, como o raciocínio baseado em casos (RBC), a lógica difusa e a computação evolucionária (CE) no processo de adaptação ao perfil do aluno e da seleção dos materiais do curso a serem exibidos. Para determinar o contributo deste trabalho, foram efetuados vários testes ao longo do tempo de modo a avaliar as capacidades da plataforma. Nestes testes incluem-se a análise estatística efetuada aos resultados obtidos pelos alunos que utilizaram a plataforma onde foram observadas melhorias no seu desempenho e também os testes de usabilidade que confirmaram a preferência dos alunos em relação à utilização da plataforma.

Palavras-chave: Plataforma ADAPT, Ensino à Distância, Sistemas Tutoriais Inteligentes, Raciocínio Baseado em Casos, Lógica Difusa, Computação Evolucionária, Algoritmos Genéticos.

Abstract

The present PhD thesis in Computer Science aims to implement an Intelligent Tutoring System (ITS), which is expected to achieve a higher level of effectiveness than the current systems through the integrated use of several Artificial Intelligence (AI) techniques. ITS are computer applications based on AI techniques that capture the profile and knowledge of the student and try to identify the causes of his mistakes. These applications attempt to select the most appropriate content, examples and problems whose presentation may include simulations and multimedia techniques. Over the years, ITS achieved an increasing popularity and its use is advised by several international institutions ([European Commission, 2011](#); [Organizing for Action, 2012](#)). Despite the advantages arising from the use of ITS, there is no consensus about their benefits and if represents the most effective educational interaction. On the one hand, several studies such as [Bolzan and Giraffa \(2002\)](#) shown that their use allowed to obtain better results, on the other hand, studies such as [VanLehn \(2011\)](#) have concluded that the performance improvement in learning by students who used an STI is not significant.

This PhD work was carried out under the Research and Development project [ADAPT - Plataforma Adaptativa de Ensino à Distância, \(2016\)](#), whose goal was to create an e-learning platform with the ability to adapt the content of a course to each student learning preferences. ADAPT platform uses AI techniques such as, case-based reasoning, fuzzy logic and evolutionary computing for the adaptation process to the student profile and the selection of the course materials to be displayed. In order to evaluate the contribution of this work, several tests were carried out. These tests include the statistical analysis performed on the results obtained by the students who used the platform where improvements in their performance were observed and also the usability tests that confirmed the student's preference regarding the use of the platform.

Key-words: ADAPT Platform, Distance Learning, Intelligent Tutoring Systems, Case Based Reasoning, Fuzzy Logic, Evolutionary Computation, Genetic Algorithms.

Índice Geral

Resumo.....	v
Abstract	vii
Índice Geral.....	ix
Índice de Figuras	xv
Índice de Tabelas.....	xix
Glossário e acrónimos	xxi
Glossário.....	xxi
Acrónimos	xxi
1 Introdução	1
1.1 Preâmbulo	3
1.2 Definição do Problema e Objetivos	4
1.3 Metodologia.....	5
1.3.1 Identificação do Problema e Motivação para a sua Resolução.....	5
1.3.2 Definição dos Objetivos da Solução Proposta.....	6
1.3.3 Conceção e Desenvolvimento.....	6
1.3.4 Demonstração	6
1.3.5 Avaliação.....	7
1.3.6 Contribuições do trabalho desenvolvido.	7
1.4 Estrutura da Tese.....	9
2 Enquadramento	11
2.1 Sistemas Tutoriais Inteligentes	14
2.2 História dos Sistemas Tutoriais Inteligentes	15
2.3 Revisão do Estado da Arte	16
2.3.1 Sistemas Tutores Inteligentes Conversacionais.....	17

2.3.2	Sistemas Tutores Inteligentes Afetivos	18
2.3.3	Sistemas Tutores Inteligentes com reconhecimento de escrita manual.....	19
2.3.4	Sistemas Tutores Inteligentes com <i>Eye Tracking</i>	19
2.3.5	Análise Crítica	20
2.4	Resumo	22
3	Aprendizagem: Teorias, Estilos e Taxonomias.....	23
3.1	Teorias de aprendizagem	25
3.1.1	Teorias comportamentalistas	26
3.1.1.1	Teoria de John Watson.....	27
3.1.1.2	Teoria de Edward Thorndike	28
3.1.1.3	Teoria de Burrhus Frederic Skinner.....	29
3.1.2	Teorias cognitivas.....	30
3.1.2.1	Teoria de Jerome Bruner.....	31
3.1.2.2	Teoria de Jean Piaget	32
3.1.2.3	Teoria de David Ausubel	34
3.1.3	Teorias humanistas	34
3.1.3.1	Teoria de Carl Rogers	35
3.1.3.2	Teoria de George Kelly.....	36
3.2	Estilos de aprendizagem.....	37
3.2.1	Modelo Myers-Briggs Type Indicator	37
3.2.2	Modelo de aprendizagem de Kolb.....	39
3.2.3	Modelo de Felder-Silverman	42
3.2.4	Guia de Estilos de Aprendizagem VARK	43
3.2.5	Estudo comparativo dos modelos	44
3.2.5.1	Modelo Myers-Briggs Type Indicator	45
3.2.5.2	Modelo de Aprendizagem de Kolb	45
3.2.5.3	Modelo de Felder-Silverman	46

3.2.5.4	Guia de Estilos de Aprendizagem VARK.....	46
3.2.5.5	Resumo dos Modelos Analisados	47
3.2.6	Mapeamento com VARK	48
3.2.6.1	Mapeamento Myers-Briggs Type Indicator com VARK.....	48
3.2.6.2	Mapeamento Kolb com VARK	49
3.2.6.3	Mapeamento Felder-Silverman com VARK.....	50
3.2.6.4	Utilização do questionário VARK	51
3.2.7	Análise crítica	51
3.3	Taxonomia de Bloom.....	52
3.3	Resumo	56
4	Tecnologias e Normas Utilizadas	59
4.1	Lógica Difusa.....	61
4.1.1	Função de Pertença.....	62
4.1.2	Operações com Conjuntos Difusos.....	62
4.1.3	Variáveis Linguísticas	64
4.1.4	Regras de Inferência	65
4.1.5	Raciocínio Difuso	66
4.1.5.1	Fuzificação.....	66
4.1.5.2	Inferência	67
4.1.5.3	Agregação	68
4.1.5.4	Desfuzificação.....	68
4.2	Raciocínio Baseado em Casos	69
4.2.1	Fase de Recuperação.....	70
4.2.2	Fase de Reutilização	71
4.2.3	Fase de Revisão	72
4.2.4	Retenção	72
4.3	Algoritmos Genéticos	73

4.4	<i>Data Mining</i>	79
4.4.1	Tarefas de <i>Data Mining</i>	80
4.4.1.1	Segmentação (<i>Clustering</i>).....	81
4.4.1.2	Classificação	81
4.4.1.3	Sumarização.....	83
4.4.2	Técnicas de <i>Data Mining</i>	84
4.4.2.1	Árvores de Decisão	85
4.4.2.2	Regras de Associação.....	86
4.4.2.3	Redes Neurais Artificiais	88
4.4.2.4	K-means	92
4.5	Normas LOM e SCORM	93
4.6	Resumo	96
5	Modelação e Design.....	99
5.1	Diagrama de Casos de Uso	101
5.2	Diagrama de Atividades.....	105
5.3	Diagrama de Classes	108
5.4	Diagrama de Sequência.....	109
5.5	Modelo Físico	111
5.6	Resumo	114
6	Implementação.....	115
6.1	Linguagem de Programação e Tecnologias de Base de Dados.....	117
6.2	Arquitetura do Sistema	118
6.3	SGA e Objetos de Aprendizagem	119
6.4	Criação e gestão de Guiões	122
6.5	Lógica Difusa e Mapeamento de Conteúdos	125
6.6	Raciocínio Baseado em Casos	129
6.7	Algoritmos Genéticos	134

6.8	<i>Data Mining</i> e pesquisa local.....	138
6.8.1	Motor de busca	138
6.8.2	Classificador de estilos de aprendizagem	142
6.8.3	Trabalho futuro	144
6.9	Resumo	145
7	Avaliação da Plataforma ADAPT	147
7.1	Análise estatística dos resultados obtidos	149
7.2	Testes de Usabilidade.....	152
7.3	Discussão dos Resultados	160
8	Conclusões	163
8.1	Objetivos alcançados.....	166
8.2	Limitações e perspectivas de trabalho futuro	167
	Referências bibliográficas	169
	Apêndices	177
	Apêndice A.....	179
	Apêndice B.....	181

Índice de Figuras

Figura 1 - Arquitetura genérica de um STI.	14
Figura 2 - Os 16 perfis do modelo Myers-Briggs Type Indicator (Pittenger, 1993).....	39
Figura 3 - Ciclo da aprendizagem experiencial de Kolb (Kolb, 1984).	40
Figura 4 - Exemplo do resultado de um teste ILS. Adaptado de Felder e Silverman, (1988). 43	
Figura 5 - Níveis hierárquicos da Taxonomia de Bloom Revista (Anderson e Krathwohl, 2001).....	53
Figura 6 - Processos cognitivos e dimensão do conhecimento (adaptado de Fuller et al., 2007).....	55
Figura 7 - Gráfico da função Triangular.	62
Figura 8 - Conjuntos difusos \tilde{A} e \tilde{I}	63
Figura 9 - Intersecção dos conjuntos difusos \tilde{A} e \tilde{I}	63
Figura 10 - Reunião dos conjuntos difusos \tilde{A} e \tilde{I}	64
Figura 11 - Complementar do conjunto difuso \tilde{A}	64
Figura 12 - Exemplo de possíveis termos linguísticos da variável linguística Temperatura e respetivas funções de pertença.	65
Figura 13 - Fuzificação das variáveis linguísticas de entrada x e y e respetivas funções de pertença.	67
Figura 14 - Termos linguísticos da variável linguística de saída z e respetivas funções de pertença, produzidos pela aplicação das regras fuzzy 1, 2 e 3.	68
Figura 15 - Conjunto difuso resultante do processo de agregação.....	68
Figura 16 - Ciclo de Aamodt e Plaza (Aamodt e Plaza, 1994).	69
Figura 17 - Algoritmo Genético.	75
Figura 18 - Método da roleta baseado em aptidão relativa.	76
Figura 19 - Algoritmo do método de seleção por roleta (Mitchell, 1997).	77
Figura 20 - Algoritmo do método de seleção por Torneio.....	77
Figura 21 - Exemplos de operadores genéticos: Cruzamento num ponto e em dois pontos....	78
Figura 22 - Exemplo do operador genético: Mutação.....	78
Figura 23 - Exemplo de conjunto de dados de treino (<i>training set</i>) e conjunto de dados de teste (<i>test set</i>) (Training, test, and validation sets, 2018).	83
Figura 24 - Exemplo de uma árvore de decisão.	85
Figura 25 - Neurónio natural e perceptrão (adaptado de Tafner et al., 1996).....	88

Figura 26 - Funções de ativação (Kovács, 1996).	89
Figura 27 - Rede neuronal MLP com 2 camadas intermédias, m entradas e 0 saídas (Scielo, 2017).	90
Figura 28 - Exemplo de uma RNA <i>feedback</i> (cíclica) e RNA <i>feedforward</i> (acíclica).	91
Figura 29 - Hierarquia dos elementos que compõem o modelo de dados LOM (IMS Global, 2018).	95
Figura 30 - Diagrama de casos de uso da plataforma ADAPT.	101
Figura 31 - Diagrama de Atividades da plataforma ADAPT.	105
Figura 32 - Diagrama de Classes da plataforma ADAPT.	108
Figura 33 - Diagrama de sequência da utilização da plataforma ADAPT por um professor.	109
Figura 34 - Diagrama de sequência da utilização da plataforma ADAPT por um aluno.	110
Figura 35 - Tabelas da BD responsáveis pela representação dos Guiões Base e guiões adaptados.	112
Figura 36 - Tabelas da BD responsáveis pela representação do questionário ILS e o seu resultado.	112
Figura 37 - Diagrama com a ilustração do modelo físico da base de dados da plataforma ADAPT.	113
Figura 38 - Arquitetura da plataforma ADAPT	118
Figura 39 - Exemplo de um OA (Azevedo, 2013).	120
Figura 40 - Apresentação de um OA no Sistema de Gestão de Aprendizagem.	121
Figura 41 - <i>Interface</i> de Criação/Edição de Guiões.	122
Figura 42 - <i>Interface</i> Pesquisa de Guiões.	123
Figura 43 - <i>Interface</i> Pesquisa de Alunos.	124
Figura 44 - <i>Interface</i> Atribuição de Guiões.	124
Figura 45 - Ficheiro .fcl com o modelo difuso utilizado no ADAPT.	125
Figura 46 - Sistema Difuso utilizado na plataforma ADAPT (MatLab, 2011).	126
Figura 47 - Variável Ativo e respetivas funções de pertença (MatLab, 2011).	126
Figura 48 - Exemplo de algumas regras do sistema difuso.	127
Figura 49 - Processo de inferência difusa (MatLab, 2011).	128
Figura 50 - Conjunto difuso resultante do processo de agregação (MatLab, 2011).	128
Figura 51 - Índices utilizados no processo de indexação de um caso.	130
Figura 52 - <i>Query</i> sql utilizada no retorno de casos da biblioteca de casos.	131
Figura 53 - Exemplo dos resultados obtidos pela <i>query</i> SQL.	133

Figura 54 - Exemplo de um cromossoma.....	136
Figura 55 - Exemplo do operador genético Mutação.....	136
Figura 56 - Exemplo do operador genético Cruzamento em dois pontos.	137
Figura 57 - <i>Interface</i> para introdução de parâmetros dos Algoritmos Genéticos usados no ADAPT.....	137
Figura 58 - Campos utilizados na indexação e respectivas tabelas.....	139
Figura 59 - Exemplo dos resultados obtidos pela query SQL (Neves, 2014).	143
Figura 60 - Frequências das notas finais da unidade curricular se Sistemas Digitais (2012/2013).	150
Figura 61 - Frequências das notas finais da unidade curricular se Sistemas Digitais (2013/2014).	151
Figura 62 - Resumo das frequências das notas finais da unidade curricular se Sistemas Digitais (2012/2013 - 2013/2014).	151
Figura 63 - Resultado do questionário de usabilidade: Nível de Interatividade.	154
Figura 64 - Resultado do questionário de usabilidade: Impacto visual.....	155
Figura 65 - Resultado do questionário de usabilidade: Escrita.	156
Figura 66 - Resultado do questionário de usabilidade: Duração.....	157
Figura 67 - Resultado do questionário de usabilidade: Estrutura.....	158
Figura 68 - Percentagem de alunos que frequentaram a unidade curricular de Sistemas Digitais.	158

Índice de Tabelas

Tabela 1 - Estilos de Aprendizagem segundo Kolb e as suas Aptidões Dominantes.	41
Tabela 2 - Vantagens e Desvantagens dos Modelos.	47
Tabela 3 - Mapeamento entre o Modelo Myers-Briggs Type Indicator e o modelo VARK. ..	48
Tabela 4 - Mapeamento entre o Modelo Kolb e o modelo VARK.	49
Tabela 5 - Mapeamento entre o Modelo Felder-Silverman e o modelo VARK.	50
Tabela 6 - Processos Cognitivos da Taxonomia de Bloom Revista.	53
Tabela 7 - Termos utilizados nos Algoritmos Genéticos (Luke, 2012).	74
Tabela 8 - Exemplo de Regras de Associação.	87
Tabela 9 - Descrição dos Casos de Uso do módulo STI.	103
Tabela 10 - Descrição dos Casos de Uso do módulo SGA.	104
Tabela 11 - Descrição dos Casos de Uso do módulo <i>data mining</i> e pesquisa local.	104
Tabela 12 - Descrição dos processos do Diagrama de Atividades da plataforma ADAPT. ..	106
Tabela 13 - Exemplo de utilização N-Grams (Neves, 2014).	139
Tabela 14 - Análise estatística (Grupo experimental)	150
Tabela 15 - Análise estatística (Grupo de controlo)	151
Tabela 16 - Análise estatística (Resumo)	152
Tabela 17 - Resumo dos resultados obtidos no teste de usabilidade.	159
Tabela 18 - Questionário de avaliação de <i>e-learning</i>	179
Tabela 19 - <i>Index of Learning Styles (ILS)</i>	181
Tabela 20 - Fatores dos <i>Items</i> da solução do questionário Felder-Silverman (Litzinger, et al., 2005).	186

Glossário e acrónimos

Glossário

Curso - plano de estudos constituído por um conjunto de matérias a lecionar, necessário para a obtenção de um certificado ou diploma.

Disciplina - unidade de ensino sobre um determinado ramo do conhecimento, caracterizada por um conjunto de aulas assistidas por alunos sujeitos a um processo de avaliação, com o objetivo de serem aprovados. Constituem uma componente de um curso: por exemplo, Sistemas Digitais é uma disciplina do curso de Informática do Departamento de Engenharia Informática e de Sistemas (DEIS).

Guião - uma sequência de conteúdos (Objetos de Aprendizagem) gerado a partir de um Guião Base, associado a um só aluno ou a vários com perfis VARK semelhantes (ou iguais). Num guião cada nó contém um link para um e apenas um Objeto de Aprendizagem (OA) relativo àquele conteúdo podendo conter também links para OA complementares sugeridos pelo módulo de pesquisa local.

Guião Base - a sequência de conteúdos de uma disciplina. Na plataforma ADAPT são criados pelo professor e cada nó de cada guião possui links para vários Objetos de Aprendizagem respeitantes a esse conteúdo e classificados com diferentes perfis VARK.

Objeto de Aprendizagem - unidade de instrução/ensino que pode ser utilizada, reutilizada ou referenciada durante o processo de aprendizagem.

Sistema de Gestão de Aprendizagem - *software* que dispõe de um conjunto de funcionalidades que permitem armazenar, distribuir e gerir atividades relacionadas com processos de aprendizagem.

Acrónimos

AAM - *Active Appearance Model*

AG - Algoritmo Genético

AI - *Artificial Intelligence*

ATS - *Affective Tutoring System*
BD - Base de Dados
CAI - *Computer Assisted Instructions*
CBR - *Case Based Reasoning*
CBT - *Computer-Based Training*
CD - *Compact disc*
CE - Computação Evolucionária
CEI - Computação Evolucionaria Interativa
CITS - *Conversational Intelligent Tutoring System*
CMOS - *Complementary Metal-oxide-semiconductor*
COA - *Center of Area*
DA - Diagrama de Atividade
DCU - Diagrama de Casos de Uso
DM - *Data Mining*
DS - Diagrama de Sequência
DSE - *Design Science*
EA - Estilo de Aprendizagem
ECL - *Emitter-coupled Logic*
FCL - *Fuzzy Control Language*
FS - *Felder-Silverman*
GUI - *Graphical User Interface*
IA - Inteligência Artificial
IBT - *Internet-Based Training*
ICAI - *Intelligent Computer Assisted Instruction*
IDE - *Integrated Development Environment*
IEC - Computação Evolucionaria Interativa
ILS - *Index of Learning Styles*
ITS - *Intelligent Tutoring Systems*
JVM - *Java Virtual Machine*
LO - *Learning Object*
LOM - *Learning Object Metadata*
LSI - *Learning Style Inventory*
MBTI - *Myers-Briggs Type Indicator*

OA - Objeto de Aprendizagem
PIF - *package interchange file*
RBC - Raciocínio Baseado em Casos
RNA - Redes Neurais Artificiais
SCO - *Sharable content objects*
SCORM - *Sharable Content Object Reference Model*
SD - Sistemas Digitais
SGA - Sistema de Gestão de Aprendizagem
SQL - *Structured Query Language*
STA - Sistemas Tutores Afetivos
STI - Sistema Tutorial Inteligente
SVM - *Support Vector Machines*
TTL - *Transistor-Transistor Logic*
UML - *Unified Modeling Language*
URL - *Uniform Resource Locator*
WBT - *Web-Based Training*
WWW - *World Wide Web*
XML - *eXtensible Markup Language*

1 Introdução

Neste capítulo abordam-se vários assuntos introdutórios que se consideram pertinentes para a compreensão deste trabalho. Desta forma, o capítulo começa com o preâmbulo, de seguida, na [secção 1.2](#) efetua-se a definição do problema e objetivos, na [secção 1.3](#) descreve-se a metodologia seguida e por último na [secção 1.4](#) apresenta-se a estrutura da tese.

1.1 Preâmbulo

Os sistemas de *e-learning* representam abordagens que, com o apoio tecnológico, prestam serviços educacionais de ensino e aprendizagem. Quando os sistemas de *e-learning* adotam técnicas de Inteligência Artificial (IA) que lhes permitem adquirir e representar conhecimento ou fazer inferências, estes sistemas tornam-se inteligentes. Quando um sistema de *e-learning* se adapta às necessidades dos utilizadores através da navegação, interação, disponibilização de conteúdos, avaliação, entre outros, diz-se que o sistema é adaptativo. Esta abordagem deu origem aos chamados Sistemas Tutoriais Inteligentes (STI). Ao longo dos anos os STI têm vindo a ganhar uma popularidade crescente sendo a sua utilização defendida por várias instituições internacionais ([European Commission, 2011](#); [Organizing for Action, 2012](#)).

A origem deste interesse reside no facto dos STI conseguirem alcançar uma série de resultados que dificilmente seriam obtidos com professores humanos por questões económicas e sociais ([Elsom-Cook, 1987](#)). A principal vantagem na utilização de STI reside na capacidade de disponibilizar um sistema de ensino com uma relação de um tutor por aluno. Permitem também uma grande flexibilidade na apresentação do material educativo e uma maior capacidade de resposta às necessidades dos alunos.

Apesar das vantagens que advêm da utilização dos STI, não existe um consenso geral acerca de que o ensino individualizado proporcionado pelos STI é a forma mais eficaz de interação educacional. Se por um lado vários estudos demonstram que a utilização destes sistemas se revelou importante na obtenção de melhores resultados no processo de aprendizagem - sendo exemplo disso um estudo realizado na Universidade de *Carnegie Mellon* em que num teste de programação se verificou que os alunos que utilizaram um STI obtiveram melhores classificações e foram capazes de resolver problemas complexos num menor período de tempo do que outros que não utilizaram o mesmo STI ([Bolzan e Giraffa, 2002](#)) - por outro lado alguns estudos como o de [VanLehn, \(2011\)](#) concluíram que a melhoria de desempenho na aprendizagem dos alunos que utilizaram um STI não é significativa.

A razão pelo fraco desempenho, comparativamente aos tutores humanos, pode estar relacionada com a forma como é efetuado o processo de adaptação ao perfil do aluno que quando feito de

forma incorreta origina abordagens e estratégias de ensino que não vão de encontro às suas necessidades de aprendizagem. Para solucionar este problema o presente trabalho propõe a utilização de técnicas de inteligência artificial, como o raciocínio baseado em casos (RBC), a lógica difusa e a computação evolucionária (CE) durante o processo de adaptação. O RBC é utilizado para imitar a experiência de um professor, armazenando casos passados de sucesso e insucesso a utilizar ou evitar no futuro. A CE é utilizada para melhorar a adaptação de conteúdos do curso de acordo com o perfil do aluno. Por outro lado, a lógica difusa é utilizada para relacionar os conteúdos educativos com o perfil do aluno. Estas técnicas, quando utilizadas em conjunto, permitem a criação de um STI com um processo de adaptação único capaz de superar o desempenho das plataformas de ensino tradicionais.

1.2 Definição do Problema e Objetivos

Como foi referido anteriormente, o STI desenvolvido teve como objetivo ultrapassar as limitações existentes nos sistemas tradicionais mencionados na [secção 1.1](#). Para alcançar este propósito foram realizadas as tarefas descritas de seguida:

- Desenvolvimento do sistema difuso responsável pelo mapeamento de objetos de aprendizagem no perfil do aluno. Este sistema recebe informação referente ao perfil do aluno e determina qual o tipo de conteúdo mais adequado à sua formação;
- Elaboração do paradigma Raciocínio Baseado em Casos que permite efetuar a adaptação dos conteúdos de acordo com a experiência de utilização passada. Os casos passados incluem informação acerca do perfil do aluno, o seu nível cognitivo, os caminhos seguidos na conclusão da disciplina e o seu desempenho;
- Implementação do módulo de Computação Evolucionaria do STI. Este sistema entra em funcionamento quando o sistema RBC não consegue dar uma resposta satisfatória. Este método iterativo parte de uma população inicial de casos do sistema RBC para gerar novas soluções mais adaptadas ao perfil do aluno.
- Implementação do módulo *data mining* e pesquisa local: este módulo é responsável pela deteção de alterações no comportamento do aluno e pela sugestão de conteúdos alternativos através de pesquisas locais;
- Desenvolvimento dos objetos de aprendizagem devidamente catalogados de modo a poderem ser identificados e retornados pelo STI.

A realização e integração das tarefas anteriormente descritas constituíram a base do sistema ADAPT que se crê ser uma contribuição válida para o desenvolvimento da área do *e-learning* e de uma nova geração de STI.

1.3 Metodologia

Para obter um conhecimento de forma sistemática e organizada, a investigação científica deve seguir um conjunto de regras e procedimentos. Os métodos de investigação são constituídos por um conjunto de procedimentos utilizados para adquirir conhecimento científico e assim permitir que uma determinada investigação atinja o seu objetivo. A investigação científica é um processo de construção que tem como meta principal gerar novo conhecimento, e colaborar no desenvolvimento ou refutar conhecimento preexistente. Tendo este trabalho como base um projeto de I&D com o objetivo de desenvolver uma plataforma de *e-learning*, o método de investigação utilizado foi o *Design Science* (DSE). O principal objetivo deste método é o de adquirir conhecimento que permita a conceção e desenvolvimento de artefactos (Van Aken, 2004). Os artefactos são objetos artificiais que podem ser caracterizados em termos de objetivos, funções e adaptações. São normalmente discutidos, particularmente durante a concepção, tanto em termos imperativos como descritivos. Vários investigadores (Hevner, 2004; Nunamaker, 1990; Rossi e Sein, 2003; Takeda et al., 1990; Walls et al., 1992), na área de Sistemas de Informação e outras disciplinas deram o seu contributo para as várias etapas do processo de DSE. Estes investigadores concordam, substancialmente, em vários elementos comuns. O resultado é um modelo que consiste em seis atividades descritas de seguida fazendo referência às atividades realizadas durante o desenvolvimento da plataforma ADAPT. A 1ª atividade consiste em identificar o problema e a motivação para a sua resolução.

1.3.1 Identificação do Problema e Motivação para a sua Resolução

Nos STI verifica-se que existe uma discrepância entre os resultados obtidos por alunos sujeitos a um processo de aprendizagem onde está presente um tutor humano e os alunos que utilizam apenas um STI. Uma das possíveis razões do desempenho inferior reside no facto do processo de adaptação ser feito de forma inadequada.

O presente trabalho centra-se especificamente no processo de adaptação no STI. As principais vantagens dos sistemas de *e-learning* residem no facto de permitir diminuir distâncias e reduzir custos. Se a estas duas vantagens se acrescentar um desempenho idêntico ou superior ao de um

tutor humano, então a solução proposta será de grande valor e representará um passo importante para toda a área do *e-learning*.

1.3.2 Definição dos Objetivos da Solução Proposta

A segunda atividade consiste em definir os objetivos da solução proposta. Neste trabalho o objetivo da solução proposta passa por desenvolver um STI cuja adaptação é efetuada por um conjunto de técnicas de inteligência artificial que através do perfil do aluno e a experiência de casos passados de sucesso e falha determine os melhores conteúdos educativos disponíveis. Cada caso é descrito pelos caminhos seguidos por cada aluno, o seu perfil de aprendizagem e o seu histórico. Desta forma o STI pode orientar o aluno na melhor direção possível ao mesmo tempo que regista a informação relativa ao seu progresso.

1.3.3 Conceção e Desenvolvimento

A terceira atividade diz respeito ao artefacto a ser criado, isto é, o módulo STI. Este módulo terá como principais responsabilidades o processo de registo de atividades do aluno, determinação do seu perfil, criação da sequência de conteúdos a serem exibidos e deteção de alterações do seu comportamento. O STI conta com o apoio de uma base de dados relacional que guarda todas as informações necessárias ao funcionamento da plataforma. Utiliza também um Sistema de Gestão de Aprendizagem (SGA) responsável pela gestão dos objetos de aprendizagem a serem exibidos ao aluno e um módulo de *data mining* e pesquisa local responsável pela sugestão de OA alternativos e também pela deteção de alteração do perfil de aprendizagem do aluno. Durante o seu funcionamento o módulo STI comunica com todos estes módulos trocando informações, realizando desta forma o processo de adaptação e apresentação do curso.

1.3.4 Demonstração

Na atividade de demonstração o STI desenvolvido foi testado na unidade curricular de Sistemas Digitais com o fim de aferir a sua mais-valia. Desta forma, a aplicação foi disponibilizada nos laboratórios do Departamento de Engenharia Informática e de Sistemas do Instituto Superior de Engenharia de Coimbra onde decorreram as aulas do Curso de Especialização Tecnológica “Tecnologia e Programação de Sistemas de Informação”, nos anos letivos de 2012/2013 e 2013/2014. Adicionalmente, foi efetuada uma demonstração das funcionalidades da plataforma

e da sua utilização. Num ambiente de laboratório os alunos fornecem informações importantes, como o seu perfil e o seu caso de uso, permitindo assim avaliar e potenciar todas as capacidades da plataforma.

1.3.5 Avaliação

A atividade de avaliação consiste em avaliar o correto funcionamento do STI e para o efeito foram efetuados vários testes. Estes testes foram realizados por alunos inscritos na unidade curricular de Sistemas Digitais sendo divididos em dois grupos: foi constituído um grupo que utilizou a plataforma com o sistema de inteligência artificial (IA) ligado, outro grupo que usou a plataforma com o sistema de IA desligado. Estes testes permitiram também efetuar correções e melhorias no sistema, ao mesmo tempo que permitiram obter casos de utilização recolhidos em ambiente real.

Imediatamente após a realização do curso disponibilizado pelo STI, foi apresentado um questionário aos alunos (Apêndice A), de modo a que estes pudessem efetuar uma avaliação da plataforma e fornecer *feedback* em relação à utilização da mesma.

1.3.6 Contribuições do trabalho desenvolvido.

Nesta atividade e no âmbito da divulgação científica foram escritos e apresentados vários artigos científicos relativos ao STI da plataforma ADAPT, tendo sido publicados e apresentados em conferências e seminários relacionadas com o tema *e-learning*.

Nestas publicações e seminários foi apresentada a formulação do problema e a sua importância, metodologia, hipóteses, resultados e conclusões. Também foram efetuadas demonstrações das funcionalidades da plataforma.

Identifica-se como principal contribuição deste trabalho a implementação de uma plataforma de *e-learning* tendo por base um STI que com recurso a várias técnicas de IA, que possui a capacidade de criar um curso adaptado ao perfil de cada aluno.

Além deste contributo foi também feito o levantamento de várias matérias relevantes para a área do do *e-learning* e dos STI:

- Revisão do Estado da Arte na área dos STI;
- Estudo das teorias de aprendizagem emergentes ao longo do tempo;
- Descrição de alguns dos modelos de aprendizagem mais utilizados;
- Apresentação das técnicas de Lógica Difusa;

- Descrição do paradigma Raciocínio Baseado em Casos;
- Breve descrição dos Algoritmos Genéticos;
- Breve descrição de técnicas de *data mining*.

São identificadas também como contribuições, no âmbito desta tese de doutoramento, a escrita de artigos científicos e apresentações do trabalho em conferências e seminários, a participação de projetos de investigação e coorientações realizadas. As contribuições associadas a este trabalho de doutoramento são:

Publicações:

- Pratas E., Marques V.M. (2012). *Adaptive E-learning Systems - Foundations and Implementation*, IADIS International Conference *E-learning* - 2012 - Lisboa, Portugal.
- Pratas E., Marques V.M. (2013). *Adaptive E-learning Systems Foundational Issues of the ADAPT Project*. In: Madureira A., Reis C., Marques V. (eds) *Computational Intelligence and Decision Making. Intelligent Systems, Control and Automation: Science and Engineering*, vol 61. Springer, Dordrecht.
- Pratas E., C. Pereira, V. Marques, (2014). *The ADAPT LMS – Interactive E-learning with Fuzzy Logic and CBR*, EDULEARN 2014, Barcelona.

Conferências e Seminários:

- ISCIES - International Symposium on Computational Intelligence for Engineering Systems, DEIS-ISEC, 2011.
- FENGE – Feira de Engenharia de Coimbra, DEIS-ISEC, 2014.
- Apresentação do projeto ADAPT numa ação de divulgação a alunos de Escolas Secundárias, DEIS-ISEC, 2014.

Relatórios Técnicos:

- ADAPT – Plataforma Adaptativa de Ensino à Distância - 1º Relatório, 2011.
- ADAPT – Plataforma Adaptativa de Ensino à Distância - 2º Relatório, 2012.
- ADAPT – Plataforma Adaptativa de Ensino à Distância - 3º Relatório, 2013.
- FCT Relatório de Progresso Final, 2014

Participação nas orientações de alunos:

- Filipe Azevedo, “Desenvolvimento de Conteúdos para a Plataforma ADAPT”, projeto do 3º ano do LEI, DEIS-ISEC, 2013. Trabalho de Conclusão de Curso, Licenciatura em Licenciatura em Eng^a Informática - Instituto Politécnico de Coimbra. Orientação da responsabilidade da Doutora Anabela de Jesus Gomes.

- Pedro Filipe Caldeira Neves, Sistema de Recomendação Inteligente para uma Plataforma de *E-learning*, DEIS-ISEC, 2014. Dissertação apresentada para a obtenção do grau de Mestre em Informática e de Sistemas - Instituto Politécnico de Coimbra. Orientação da responsabilidade do Doutor Viriato António Pereira Marinho Marques e do Doutor Carlos Manuel Jorge da Silva Pereira.
- Luís Dias, Projecto e desenvolvimento de um LMS (Learning Management System) básico, concebido para suportar as solicitações dos restantes componentes do projecto ADAPT, em particular de um ITS (Intelligent Tutoring System), GECAD-ISEP, 2011. Orientação da responsabilidade do Doutor Luiz Faria.

As participações nas orientações mencionadas anteriormente resultaram do projeto ADAPT - Plataforma Adaptativa de Ensino à Distância / GECAD - Grupo de Investigação em Engenharia do Conhecimento e Apoio a Decisão, Ref. PTDC/CPE-CED/115175/2009.

1.4 Estrutura da Tese

A tese está dividida em oito capítulos:

No [capítulo 1](#) de introdução apresenta-se o preambulo, a definição do problema e objetivos, a metodologia adoptada e por último é descrita a estrutura da tese.

No [capítulo 2](#) realiza-se um enquadramento onde se efetua uma breve descrição dos Sistemas Tutoriais Inteligentes (STI), a sua história e a revisão do estado da arte nesta área.

No [capítulo 3](#) apresentam-se as principais teorias e estilos de aprendizagem. Adicionalmente é feita referência à taxonomia de Bloom.

No [capítulo 4](#) descrevem-se as tecnologias utilizadas no desenvolvimento da plataforma ADAPT nomeadamente a Lógica Difusa, o Raciocínio Baseado em Casos, os Algoritmos Genéticos e por fim as tarefas e técnicas de *data mining* empregues.

No [capítulo 5](#) ilustram-se os diagramas criados na fase inicial do trabalho com a finalidade de descrever as principais interações entre os objetos da plataforma, nomeadamente Casos de Uso, de Atividade e de Sequência.

No [capítulo 6](#) enumeram-se os aspetos mais importantes relacionados com o desenvolvimento da plataforma: é referida a linguagem de programação e as tecnologias de Base de Dados (BD). Apresentam-se os aspetos relacionados com os objetos de aprendizagem (OA) e os Guiões dos quais fazem parte. Adicionalmente explica-se como é feito o mapeamento dos objetos com o perfil do aluno através de Lógica Difusa. Este capítulo apresenta ainda o modo como o

Raciocínio Baseado em Casos, *data mining* e Algoritmos Genéticos foram aplicados no STI da plataforma ADAPT.

No [capítulo 7](#) apresentam-se os resultados da avaliação efetuada à plataforma ADAPT e os resultados dos testes de usabilidade.

Por último, no [capítulo 8](#), apresentam-se as conclusões que incluem os objetivos alcançados, as limitações encontradas e as perspetivas de trabalho futuro.

2

Enquadramento

O termo *e-learning* inclui todas as formas de ensino e aprendizagem, suportadas por tecnologia. Os sistemas de informação, independentemente de o ensino ser ou não on-line, servem como meios de apoio ao processo de aprendizagem. Este apoio envolve experiências educacionais através da tecnologia fora e dentro da sala de aula. Abreviaturas como CBT (*Computer-Based Training*), IBT (*Internet-Based Training*) ou WBT (*Web-Based Training*) têm sido utilizados como (quase) sinónimos para *e-learning*.

A aprendizagem com o auxílio de computadores ou CBT e os sistemas que utilizavam instruções assistidas por computador conhecidos como *Computer Assisted Instruction* (CAI) foram os primeiros sistemas criados numa tentativa de ensinar através do recurso a computadores. Nestes tipos de sistemas, a aprendizagem não era individualizada de acordo com o perfil do aluno.

Embora ambos os sistemas CBT e CAI sejam eficazes no processo de aprendizagem dos alunos, eles não fornecem o mesmo tipo de atenção individualizada que um aluno poderia receber de um professor humano (Bloom, 1984).

No início da década de setenta alguns investigadores definiram um novo objetivo para os sistemas CAI: utilizaram o tutor humano como sendo o seu modelo educacional e tentaram aplicar técnicas de inteligência artificial para construir um modelo “inteligente” de aprendizagem com o auxílio de computadores. Esta abordagem deu origem aos chamados Sistemas Tutoriais Inteligentes também conhecidos como *Intelligent Tutoring Systems* (ITS). Os ITS oferecem uma grande flexibilidade na apresentação do material educativo e uma maior capacidade de resposta às necessidades dos alunos. Estes sistemas conseguem ser “inteligentes” através de decisões pedagógicas sobre como ensinar com base em informações que possuem acerca do aluno.

Na [secção 2.1](#) deste capítulo são descritos os STI e a sua arquitetura genérica, na [secção 2.2](#) é apresentada a história dos STI, na [secção 2.3](#) é feita uma revisão do estado da arte, na [secção 2.3.5](#) é efetuada uma análise crítica aos STI apresentados e por último na [secção 2.4](#) é feito um resumo deste capítulo.

2.1 Sistemas Tutoriais Inteligentes

Sistemas Tutoriais Inteligentes (STI) são aplicações de computador baseadas em técnicas de IA que capturam o perfil e os conhecimentos do aluno e procuram identificar as causas dos seus erros. Estas aplicações procuram selecionar os conteúdos mais adequados, os melhores exemplos e os problemas cujas apresentações podem incluir simulações e técnicas de multimédia. Os STI têm como objetivo possibilitar a aprendizagem de forma significativa e eficaz, utilizando uma variedade de tecnologias. Nos últimos anos os STI têm vindo a ganhar uma popularidade crescente sendo a sua utilização defendida por várias instituições internacionais. Exemplo disso é a Estratégia de Lisboa que reconhece a importância dos sistemas de *e-learning*: “*The Lisbon Strategy is the EU's response to facing the challenges of globalisation, demographic change and the knowledge society. [...] There are three overall objectives: improving the quality and effectiveness of education and training systems; facilitating access to education and training systems; and opening up EU education and training systems to the wider world*” (European Comission, 2011).

A razão deste interesse reside no facto dos STI conseguirem alcançar uma série de resultados que dificilmente seriam alcançados com professores humanos por razões económicas e sociais (Elsom-Cook, 1987). Uma das vantagens na utilização de um STI é a possibilidade de disponibilizar um sistema de ensino com uma relação de um tutor por aluno.

Anderson (1987) também constatou uma vantagem significativa para o tutor inteligente, em termos de tempo de aprendizagem que os estudantes necessitam para obterem o mesmo nível de competência. A arquitetura genérica de um STI é ilustrada na Figura 1.

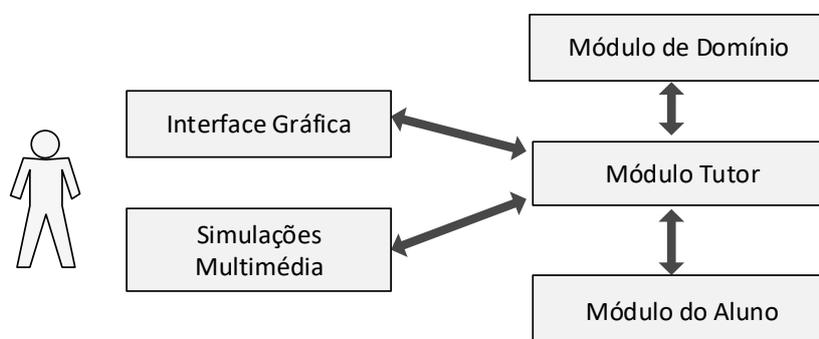


Figura 1 - Arquitetura genérica de um STI. Adaptado de Pratas e Marques, (2013).

O módulo de domínio, também conhecido como módulo cognitivo tenta levar em conta todos os passos necessários para resolver um problema. Este modelo contém as regras e estratégias de resolução de problemas no domínio a ser aprendido. O módulo de domínio pode

desempenhar várias funções, como por exemplo disponibilizar conhecimento especializado, avaliar o desempenho do aluno ou ser responsável pela deteção de erros.

O módulo do aluno é responsável por determinar o estado cognitivo do aluno e a sua evolução durante o processo de aprendizagem. O modelo do aluno monitoriza o comportamento do estudante durante o seu processo de resolução de problemas a fim de detetar se ocorreram erros ou desvios relativamente ao módulo de domínio.

O módulo tutor recebe informações provenientes dos módulos de domínio e do aluno e seleciona a melhor estratégia a seguir. Em qualquer ponto do processo de resolução de problemas o aluno pode solicitar ajuda sobre o que fazer a seguir.

A *interface* gráfica do utilizador permite a interação com o sistema através de elementos gráficos que apresentam simulações em multimédia.

2.2 História dos Sistemas Tutoriais Inteligentes

A utilização de máquinas inteligentes na aprendizagem data de 1924, quando Sidney Pressey criou uma máquina mecânica para ensinar alunos sem a necessidade da presença de um professor humano (Fry, 1960). A máquina de Pressey permitia ao utilizador responder às questões e introduzir dados retornando de imediato o resultado correspondente através da exibição da sua pontuação num contador (Shute e Psotka, 1994). No entanto, a máquina de Pressey não foi considerada inteligente pelo facto de ser mecânica (Shute e Psotka, 1994) mas marcou um precedente para os sistemas futuros.

Ao longo da década de cinquenta surgiram novas perspectivas sobre a aprendizagem. Skinner, um behaviorista da Universidade de Harvard, que acreditava que deviam ser os alunos a construir as suas próprias respostas, criou uma máquina de ensino constituída por um sistema mecânico incremental que recompensava os alunos quando forneciam as respostas corretas às perguntas efetuadas (Fry, 1960). Após a segunda guerra mundial, os sistemas mecânicos foram substituídos por máquinas eletrónicas. Ainda na década de cinquenta, os investigadores Allen Newell, Shaw Clifford, e Simon Herb criaram um programa denominado de “*The Logic Theorist*” capaz de criar provas lógicas e teoremas. Este programa tinha a capacidade de exibir e manipular símbolos complexos e até mesmo gerar novas informações sem intervenção

humana sendo considerado, por alguns investigadores como o primeiro programa de Inteligência Artificial.

Estes avanços serviram de base à criação de um novo campo que ficou conhecido como Inteligência Artificial, oficialmente batizado em 1956 por John McCarthy (apud Buchanan, 2006). A última parte da década de sessenta foi marcada pelo aparecimento de novos projetos tendo como princípio a Instrução Assistida por Computador (Computer-assisted Instruction - CAI) que aproveitaram os últimos avanços alcançados nas ciências da computação. Um exemplo desses projetos é o PLATO, um programa educativo capaz de efetuar apresentações, animações e também armazenar e disponibilizar grandes quantidades de materiais educativos. Foi desenvolvido por Donald Bitzer na Universidade de Illinois, no início da década de setenta (Chambers e Sprecher, 1983). Enquanto os sistemas CAI estavam a ganhar popularidade, Jaime Carbonell sugeriu que os computadores pudessem agir como professores, em vez de serem utilizados apenas como uma ferramenta (Carbonell, 1970). Esta nova perspectiva que incidia sobre a utilização de computadores de forma inteligente como ferramenta de ensino passou a ser denominada por Intelligent Computer Assisted Instruction (ICAI) ou por Sistemas Tutoriais Inteligentes (STI).

Carbonell (1970) foi o criador do primeiro STI denominado de SCHOLAR. Este programa tentava envolver o aluno num diálogo sobre a geografia da América do Sul. A comunicação entre o programa e o aluno era efetuada através de uma sequência de perguntas e respostas. Enquanto os sistemas CAI utilizavam uma perspectiva behaviorista sobre a aprendizagem que se baseava nas teorias de Skinner, os STI baseavam-se nas áreas de psicologia cognitiva, ciência da computação e inteligência artificial (Shute e Psozka, 1994).

O aparecimento do microcomputador no final da década de setenta e início dos anos oitenta alavancou o desenvolvimento destes sistemas. Na transição dos sistemas CAI para os sistemas ICAI/STI, o computador tem de distinguir não apenas entre a resposta correta e incorreta, mas o tipo de resposta incorreta para ajustar o tipo de instrução. Estes sistemas têm de ser capazes de ensinar uma tarefa adaptando-se dinamicamente a diferentes situações.

2.3 Revisão do Estado da Arte

Apesar dos avanços alcançados, os STI continuam a ter limitações em áreas como o diálogo, a escrita, e a componente emocional e afetiva. Várias abordagens têm vindo a ser estudadas e testadas de forma a melhorar estas áreas e tornar os STI mais eficazes.

Uma das áreas que tem sido alvo de investigação é a incorporação de diálogos no processo de interação com o utilizador. Desta forma, os tutores têm a capacidade de compreender e interpretar o tom e a inflexão do educando de modo a fornecer *feedback* através de um diálogo permanente. A capacidade de diálogo pode ser utilizada para pedir questões específicas de modo a ajudar e orientar o aluno permitindo-lhe construir o seu próprio conhecimento (Graessner et al., 2001). A integração de diálogos mais sofisticados nos STI tem sido foco de várias investigações de modo a discutir as limitações atuais e criar abordagens mais construtivas para os STI (Graesser et al., 2005).

Outro tipo de STI são os que têm capacidade de reconhecimento de escrita, uma funcionalidade em que a entrada de dados é feita através de escrita manual que utiliza uma caneta desenvolvida especificamente para esse efeito. Este tipo de *input* possui vantagens que as interações tradicionais não conseguem oferecer (Anthony et al., 2012).

Os Sistemas Tutores Afetivos (STA) (Picard, 1997) utilizam dispositivos embutidos para detetar a emoção do aluno entre outros sinais considerados significativos e deste modo adaptarem-se ao estado emocional do aluno.

Na [secção 2.3.1](#) apresentam-se os STI Conversacionais, que utilizam várias técnicas que incluem a captura das expressões faciais do utilizador para determinar o seu estado afetivo, a captura e análise da sua voz, a pose das mãos entre outras características, de modo a tornar o *feedback* o mais personalizado possível. De seguida, na [secção 2.3.2](#), descrevem-se os STI afetivos que imitam um tutor humano ao manter um diálogo com o aluno. Este diálogo é potenciado ao utilizar um agente tridimensional que utiliza simulações interativas de modo a aumentar o interesse do aluno assim como a profundidade da aprendizagem. Na [secção 2.3.3](#) apresenta-se um tutor que utiliza como entrada de dados uma caneta de modo a facilitar a introdução de elementos manuscritos, como é o caso do ensino em áreas como a matemática, onde é necessária a escrita de equações assim como outras expressões complexas. Na [secção 2.3.4](#) apresenta-se o tutor *Gaze*, um STI que utiliza um sistema para monitorizar a posição e os movimentos dos olhos do aluno com o fim de identificar estados de desatenção e falta de concentração do aluno para depois tentar reorientar os seus padrões de atenção. Por último, na [secção 2.3.5](#) efetua-se uma análise crítica aos STI apresentados nesta secção.

2.3.1 Sistemas Tutores Inteligentes Conversacionais

Os *Conversational Intelligent Tutoring Systems*, conforme proposto por Rajkumar e Ramalingam (2015) têm como objetivo melhorar a comunicação e a eficácia no processo de

aprendizagem, utilizando para o efeito várias técnicas de reconhecimento do estado afetivo do aluno. Estas técnicas no seu conjunto constituem uma abordagem multimodal para recolher as várias emoções do aluno provenientes de expressões faciais, gestos corporais e diálogo.

Nas técnicas multimodais incluem-se a utilização de: *Active Appearance Model* (AAM) para a extração de características faciais; *Camshift* que permite capturar a pose e orientação da mão o que permite classificar vários movimentos das mãos e braços como por exemplo braços cruzados, braços virados para cima, mãos a segurar a cara, e outros; a nível de diálogo algumas das características analisadas são a frequência, os fonemas, o nível vocal, e outras características. Estas técnicas permitem detetar emoções no aluno como aborrecimento, confusão, medo, envolvimento, felicidade e neutro. Um tutor virtual é utilizado para interagir com o aluno. Este tutor armazena conceitos cognitivos num modelo de dados modular e utiliza este modelo para planear o seu comportamento. Para alcançar este objetivo, a arquitetura do tutor virtual é combinada com estímulos atuais do aluno, um modelo comportamental armazenado em memória que representa uma variedade de informação onde estão incluídas, a experiência obtida no passado, as necessidades e os conhecimentos do mundo existentes.

2.3.2 Sistemas Tutores Inteligentes Afetivos

O *AutoTutor* (D’Mello e Graesser, 2012) é um STI afetivo que procura imitar as estratégias de pedagogia e motivação utilizadas pelos tutores humanos mantendo um diálogo com o aluno ao mesmo tempo que cria um modelo com os estados cognitivos do aluno, o que permite adaptar dinamicamente a interação a cada um dos estudantes. Para além destas características, o *AutoTutor* deteta o estado emocional do aluno monitorizando as características faciais, a linguagem corporal e analisando as repostas dadas oralmente. Para captar as respostas orais do aluno é utilizado como *input* o sistema de reconhecimento de discurso *Dragon Naturally SpeakingTM*. Por sua vez, a interação com o aluno é efetuada por um agente virtual que utiliza animações, expressões faciais, gestos e sons.

Relativamente aos problemas destinados a serem resolvidos pelos estudantes, apresentados pelo *AutoTutor*, estes são mapeados em taxonomias com diversos níveis de dificuldade (Bloom, 1956). Em alguns dos cursos apresentados, como por exemplo os conteúdos do curso de informática, são classificados em três níveis de dificuldade: fácil, médio e difícil. O comportamento de um STI pode ser caracterizado através de um *loop* externo e de um *loop* interno (VanLehn, 2006). No *AutoTutor* o *loop* externo é constituído por lições didáticas e problemas. O *loop* interno é constituído por interações colaborativas enquanto o aluno tenta

responder a uma questão ou resolver um problema. O *AutoTutor* tem como objetivo ajudar os alunos a aprender os conceitos principais da física newtoniana assim como conhecimentos acerca de informática, sem descorar a aquisição de pensamento crítico.

2.3.3 Sistemas Tutores Inteligentes com reconhecimento de escrita manual

Um STI com capacidade de reconhecimento de escrita manual possui várias vantagens. Estas capacidades têm benefício especialmente em áreas como a matemática onde é necessário a escrita de equações algébricas. Adicionalmente, *inputs* baseados em canetas digitais são fáceis de utilizar, aumentando a naturalidade da interação ao remover a barreira existente com o objetivo que se pretenda alcançar (Abowd, 1999). Esta tecnologia nem sempre foi eficaz e acessível ao ponto de poder ser utilizada em salas de aula. Contudo, nos últimos anos, com a descida dos preços em dispositivos como os tablets e outros aparelhos digitais fizeram com que o seu uso se tornasse generalizado. No entanto, uma desvantagem desta tecnologia que ainda está por resolver consiste no facto desta não ser totalmente confiável ao apresentar erros consideráveis no processo de reconhecimento da escrita introduzida. Uma solução possível, proposta por Anthony et al. (2012), que permite reduzir parte desses erros de reconhecimento e tornar o processo mais fiável, é considerar o contexto do problema a ser resolvido. Esta abordagem, em que a utilização do contexto é tida em conta, permitiu uma redução de erros no processo de reconhecimento em cerca de 18% assim como das interações de recuperação de erros de reconhecimento em um em cada quatro problemas. Com esta proposta são exploradas as potencialidades da escrita através da utilização de uma caneta digital como mecanismo de entrada de dados num STI em que o domínio é, por exemplo, a área da matemática ou da física. Segundo vários estudos conduzidos pelos criadores deste STI, conclui-se que esta alternativa é preferível à utilização do teclado pois permite aos alunos a escrita de equações de forma mais rápida e com menos erros.

2.3.4 Sistemas Tutores Inteligentes com *Eye Tracking*

D’Mello et al. (2012) propõem um STI designado por *Guru*, que tem como objetivo envolver o aluno no processo de aprendizagem ao detetar e responder a emoções tais como aborrecimento e falta de envolvimento, de forma dinâmica. O tutor utiliza um dispositivo de *Eye Tracking* para monitorizar os padrões do olhar do aluno e identificar quando ele está aborrecido ou não está atento. Nesta situação o tutor tenta captar a atenção do aluno através de técnicas de diálogo de

modo a reorientar os seus padrões de atenção através do recurso a animações de um agente pedagógico. Este agente apresenta os conteúdos educacionais de forma conversacional através de um discurso sintetizado produzido pelo “motor” de produção de discurso *NeoSpeech&Kate*. Este discurso é exibido em simultâneo à medida que são apresentadas imagens relacionadas com esses conteúdos. Os alunos por sua vez têm a possibilidade de introduzir as respostas aos problemas numa área específica da aplicação.

O STI *Guru* foi construído com o objetivo de apoiar os alunos em tópicos de biologia como por exemplo respiração celular, mitoses e sucessão ecológica, entre outros.

2.3.5 Análise Crítica

Nesta secção faz-se uma análise crítica dos STI descritos anteriormente.

O STI Conversacional proposto por [Rajkumar e Ramalingam \(2015\)](#) utiliza várias técnicas de reconhecimento do estado afetivo do aluno com o objetivo de melhorar a comunicação e a eficácia no processo de aprendizagem. Segundo os seus criadores, o tutor virtual existente na aplicação melhora o processo de aprendizagem ao criar um ambiente interativo através da modelação do comportamento cognitivo do aluno. Os alunos que utilizaram este STI manifestaram um menor aborrecimento e um maior envolvimento devido à interação com o tutor virtual.

O *AutoTutor* é um STI que cria um modelo com os estados cognitivos do aluno com base no seu estado emocional, sem que este tenha de efetuar qualquer intervenção, o que constitui uma abordagem muito vantajosa. Contudo, apesar dos esforços em criar um ambiente interativo e dinâmico, em alguns momentos a interação conversacional torna-se aborrecida e até irritante para uma pequena percentagem de alunos. Outra limitação importante é o facto de por vezes o diálogo ser interrompido quando não era suposto. Segundo os autores isto acontece em situações em que a modelação do modelo cognitivo do aluno é imperfeita ou o discurso do aluno foi incorretamente classificado. Adicionalmente o número de respostas às eventuais perguntas dos alunos é restrito. Para que todo o processo interativo seja eficaz, é importante que estas questões sejam resolvidas.

Os STI que incorporam o reconhecimento de escrita possuem uma vantagem considerável quando a matéria de ensino a lecionar é da área da matemática ou afins. Vários estudos demonstraram que algumas crianças sentem dificuldades na utilização dos teclados tradicionais,

considerando a entrada de dados trabalhosa fazendo com que percam a sua linha de raciocínio, um sinal de uma elevada carga cognitiva, mesmo apesar do aumento da utilização de computadores por parte das crianças (Read et al., 2000). Existem evidências de que as crianças escrevem mais fluentemente quando utilizam um sistema com reconhecimento de escrita manual comparativamente à *interface* tradicional que utiliza rato e teclado na escrita de texto livre (Read et al., 2001).

O STI *Guro* utiliza um dispositivo de *Eye Tracking* para monitorizar os padrões do olhar do aluno e identificar quando este está aborrecido e não está atento. A deteção efetuada de forma automática do aborrecimento ou falta de interesse por parte do aluno é uma mais-valia mas pode não ser uma solução fidedigna em todas as situações. Uma possível desvantagem reside no facto do sistema partir do princípio de que quando o aluno desvia o olhar noutra direção que não o da câmara ele está aborrecido ou desconcentrado. Isto pode induzir o STI em erro ao fazer interpretações erradas e levá-lo a tomar decisões que não sejam as mais corretas. Outra desvantagem reside na falta de sensibilidade na captação do olhar do aluno. Segundo os autores cerca de 33% dos participantes foram excluídos do estudo pelo facto do sensor do sistema de *Eye Tracking* não detetar alterações nos padrões do olhar do aluno. Estes dois fatores indicam um problema de fiabilidade nesta tecnologia e indiciam que talvez deva ser utilizada como uma tecnologia auxiliar no processo de tomada de decisões do STI e não como a principal fonte de decisão.

Outros padrões monitorizados com resultados mais eficazes, são as características faciais e a linguagem corporal, utilizados atualmente nos STI Afetivos marcando a tendência atual nesta área (Rajkumar e Ramalingam, 2015; D’Mello e Graesser, 2012). Adicionalmente, a voz dos alunos é um padrão relevante que tem sido monitorizado, em vários STI, uma vez que permite extrair informação relativa aos seus estados afetivos. Uma tendência que tem merecido especial atenção por parte dos investigadores, na geração atual de STI, é a utilização de tutores virtuais que comunicam oralmente com o aluno ao mesmo tempo que apresentam expressões faciais tornando todo o processo de interação mais envolvente e mais parecido com a interação obtida a partir de um tutor humano.

2.4 Resumo

Neste capítulo apresentou-se a arquitetura genérica de um STI, constituída pelos seguintes módulos: Módulo de Domínio, Módulo do aluno e o Módulo Tutor. O Módulo de Domínio contém as regras e estratégias de resolução de problemas no domínio a ser aprendido. O Módulo do aluno é responsável por determinar o estado cognitivo do aluno e a sua evolução durante o processo de aprendizagem. Por último, o Módulo Tutor é responsável por determinar o estado cognitivo do aluno e a sua evolução durante o processo de aprendizagem. Este módulo recebe informações provenientes dos módulos de domínio e do aluno e seleciona a melhor estratégia a seguir ([secção 2.1](#)).

A história dos STI teve origem quando Sidney Pressey criou uma máquina mecânica para ensinar alunos sem a necessidade da presença de um professor humano. Numa fase posterior, os sistemas mecânicos foram substituídos por máquinas eletrónicas. Os investigadores Allen Newell, Shaw Clifford, e Simon Herb criaram um programa denominado de “The Logic Theorist” capaz de criar provas lógicas e teoremas sem intervenção humana e é considerado por alguns investigadores como o primeiro programa de Inteligência Artificial. Estes avanços serviram de base à criação de um novo campo que ficou conhecido como Inteligência Artificial. A fase seguinte foi marcada pelo aparecimento de novos projetos tendo como princípio a Instrução Assistida por Computador. Na década de setenta Jaime Carbonell sugeriu que os computadores pudessem agir como professores, em vez de serem utilizados apenas como uma ferramenta. Esta nova perspetiva que incidia sobre a utilização de computadores de forma inteligente passou a ser denominada por *Intelligent Computer Assisted Instruction* ou por Sistemas Tutoriais Inteligentes ([secção 2.2](#)).

Atualmente os STI continuam a sofrer avanços utilizando várias técnicas como o diálogo, a escrita, a componente emocional e afetiva. Exemplos destes casos podem-se considerar: os Sistemas Tutores Afetivos que utilizam dispositivos embutidos para detetar a emoção do aluno entre outros sinais considerados significativos e assim adaptarem-se ao estado emocional do aluno; os STI Conversacionais, que utilizam várias técnicas que incluem a captura das expressões faciais do utilizador para determinar o seu estado afetivo e finalmente STI como o *Gaze* que utiliza um sistema para monitorizar a posição e os movimentos dos olhos do aluno com o fim de identificar estados de desatenção ([secção 2.3](#)).

3

Aprendizagem: Teorias, Estilos e Taxonomias

A aprendizagem é o processo que permite adquirir ou modificar competências, habilidades, conhecimentos, comportamento ou valores, através do estudo, experiência, formação, raciocínio ou observação. Ao longo do tempo este processo foi analisado através de diferentes perspectivas, dando origem a diferentes teorias de aprendizagem. Estas teorias têm como base modelos que visam explicar o processo de aprendizagem realizado pelos seres humanos e assim reconhecer a dinâmica inerente ao ato de aprender e ensinar.

Na [secção 3.1](#) apresentam-se as principais teorias de aprendizagem, as suas visões e os seus fundamentos: existem vários fatores que podem afetar a aprendizagem de um aluno. Esses fatores incluem os métodos de ensino, as formas de expor e apresentar informações ou a sequência dos conteúdos a apresentar. Ao longo dos anos foram propostos vários modelos de estilos de aprendizagem para determinar as preferências do aluno relativamente ao seu processo de entendimento e como efetua o processamento da informação.

Na [secção 3.2](#) apresentam-se os estilos de aprendizagem tidos em consideração no desenvolvimento da plataforma ADAPT. Este estudo é importante uma vez que um dos objetivos da plataforma é adaptar os conteúdos educativos ao estilo de aprendizagem (EA) de cada aluno. De modo a proceder à adaptação, além de classificar o aluno em relação às suas preferências de aprendizagem é necessário também proceder à classificação dos conteúdos. Esta classificação é feita através da utilização do Guia de Estilos de Aprendizagem VARK descrito na [secção 3.2.4](#). Na [secção 3.2.5](#) é apresentado o estudo comparativo dos modelos referidos. Na [secção 3.2.6](#) é analisada a melhor forma de mapear os conteúdos educativos com os perfis de aprendizagem do aluno e na [secção 3.2.7](#) é efetuada uma análise crítica aos temas abordados neste capítulo.

Na [secção 3.3](#) apresenta-se a Taxonomia de Bloom e a Taxonomia de Bloom Revista.

3.1 Teorias de aprendizagem

Para ensinar, o professor realiza um conjunto de ações orientadas para alcançar determinados objetivos de aprendizagem que têm em vista, designadas por estratégia de ensino ([Pinto-Ferreira, 2009](#)).

As teorias da aprendizagem procuram explicar a relação entre o conhecimento preexistente e o novo conhecimento apresentando múltiplas visões sobre o processo de aprendizagem, as circunstâncias em que este ocorre e os seus resultados. Uma teoria da aprendizagem dá uma explicação geral das observações efetuadas ao longo do tempo. Pode ser modificada, e ser

aceite durante alguns períodos de tempo para depois ser rejeitada. Contudo, há sempre partes da teoria que continuam a ser válidas (Costa-Lobo, 2011).

Estas teorias possuem um denominador comum que pressupõe que todos os indivíduos são agentes ativos na procura e construção do conhecimento, dentro de um determinado contexto. Das várias abordagens sugeridas destacam-se as teorias comportamentalistas, as teorias cognitivas e as abordagens humanistas. Estas teorias são descritas nas secções seguintes.

3.1.1 Teorias comportamentalistas

O comportamentalismo considera o comportamento como uma forma funcional e reacional dos seres vivos. Esta teoria possui duas vertentes: o comportamentalismo metódico e o comportamentalismo radical. O criador da vertente do comportamentalismo metódico, foi John B. Watson. O comportamentalismo metódico possui uma filosofia empírica e considera que o ser humano aprende a partir do ambiente que o rodeia. Considera também que o ser humano não possui nenhuma herança biológica ao nascer desprovido de qualquer informação. O comportamentalismo metódico possui uma vertente determinista e sendo baseada no estímulo-resposta (E-R), considera que o comportamento humano é previsível, isto é, se ocorrer um antecedente X, então o evento Y ocorrerá como consequência (Primo, 2009).

Outra vertente é o comportamentalismo radical, criada por Burrhus Frederic Skinner. Ao contrário do comportamentalismo metódico, esta vertente é contrária à ideia de que o ser humano seja desprovido de qualquer porte fisiológico e genético. Esta é uma das principais diferenças entre as duas vertentes comportamentalistas em que Skinner considera o comportamentalismo não como um estudo científico do comportamento, mas sim, uma Filosofia da Ciência que se preocupa com os métodos e objetos de estudo da psicologia (Sério, 2005).

Outra corrente importante é o Associacionismo, tendo Edward L. Thorndike (1874-1949) como principal representante. O Associacionismo parte do princípio de que a aprendizagem se dá por um processo de associação das ideias começando pelas mais simples até às mais complexas. Para aprender um conteúdo complexo, um indivíduo necessita de aprender primeiro as ideias mais simples, pertencentes ao conteúdo em questão. Um dos seus contributos para o comportamentalismo foi a Lei do Efeito. Esta lei defende que durante o processo de aprendizagem uma conexão é fortalecida quando seguida de uma consequência satisfatória. Além da Lei do Efeito, Thorndike propôs mais duas leis, a Lei da Prontidão e a Lei do Exercício apresentadas na [secção 3.1.1.2](#).

De seguida efetua-se uma descrição das vertentes comportamentalistas mais populares. Os psicólogos associados a estas vertentes foram: Watson, que foi o fundador da corrente comportamentalista no mundo ocidental; Thorndike pela sua influência na psicologia da educação; e Skinner pelo facto da sua teoria ser até hoje influente no meio educacional.

3.1.1.1 Teoria de John Watson

John Broadus Watson (1878-1958) nasceu em Nova Iorque, foi um psicólogo tendo-se doutorado em Neuropsicologia e é considerado o fundador do comportamentalismo.

Watson realizou experiências em seres humanos e animais tendo sido influenciado pelo trabalho de Pavlov (Watson, 1913). Para Watson a psicologia constituía uma parte das Ciências Naturais, sendo o seu objeto de estudo o comportamento, investigado através de experiências que envolviam estímulos e respostas. Pavlov centrou a sua investigação mais nos estímulos do que nas consequências dos mesmos, uma abordagem com origem nos critérios epistemológicos do positivismo, que conheceu quando estudou Filosofia.

Segundo Watson, a aprendizagem é realizada através do condicionamento clássico proposto por Pavlov, em que um estímulo neutro que ocorre um número suficiente de vezes como estímulo incondicionado, passa a evocar a mesma resposta do último, substituindo-o. As emoções humanas também poderiam ser explicadas pelo processo de condicionamento. Ou seja, o medo, por exemplo, poderia ser condicionado juntando um estímulo incondicionado com um estímulo neutro. O determinismo das suas ideias aparece expresso numa frase sua: *“dêem-me uma dúzia de crianças saudáveis, bem formadas, e o meu próprio mundo preparado para fazê-las crescer, e garanto que qualquer uma que eu escolha ao acaso, posso transformá-la em qualquer tipo de especialista que eu quiser - médico, advogado, artista, ou gerente e, sim, até mesmo mendigo ou ladrão, independentemente dos seus talentos, inclinações, tendências, habilidades, vocações e raça dos seus antepassados”* (Watson, 1924).

Na perspetiva do ensino, Watson considera que é da responsabilidade do professor promover o maior número de vezes possível a associação de uma resposta desejada a um determinado estímulo de modo a que o aluno possa adquirir novos conhecimentos. Assim, o professor deverá proporcionar ao estudante, o mais rapidamente possível, um vínculo entre a resposta que ele quer que o aluno aprenda e o estímulo com que ela está relacionada.

Apesar de influente, várias críticas têm sido feitas a este paradigma. Uma delas prende-se com as descobertas alcançadas no ramo das neurociências, que vieram trazer novo conhecimento

sobre o funcionamento interno do cérebro, contrariando a ideia do comportamentalismo de que todo comportamento pode ser explicado sem ter em conta os processos cognitivos.

3.1.1.2 Teoria de Edward Thorndike

Edward Lee Thorndike (1874-1949) foi um psicólogo estadunidense e é considerado o pai da psicologia educacional moderna. É também o principal representante do Associativismo e formulou a primeira teoria de aprendizagem na Psicologia.

O termo Associacionismo considera que a aprendizagem se dá por um processo de associação das ideias que vão das mais simples às mais complexas. Deste modo, para aprender uma matéria complexa, é necessário primeiro aprender as ideias mais simples associadas a essa matéria. Thorndike parte do pressuposto de que a aprendizagem é um conjunto de conexões estímulo-resposta (E-R). A sua teoria da aprendizagem descreve o modo como estas conexões podem ser fortalecidas ou enfraquecidas.

Thorndike foi um defensor do reforço e um dos seus grandes contributos para o comportamentalismo foi a Lei do Efeito. Esta lei defende que durante o processo de aprendizagem uma conexão é fortalecida quando seguida de uma consequência satisfatória. Nesta situação é mais provável que a mesma resposta seja dada novamente na presença do mesmo estímulo. Caso contrário, se a conexão for seguida de um “estado irritante” a resposta é enfraquecida e provavelmente não será repetida.

Para seguir este paradigma o professor deverá proporcionar ao aluno um reforço positivo que pode passar por um elogio caso o aluno tenha dado a resposta correta ou um reforço negativo que por exemplo pode ser uma punição no caso do aluno dar uma resposta errada.

Além da Lei do Efeito, Thorndike propôs mais duas leis, a Lei da Prontidão e a Lei do Exercício. A Lei da Prontidão afirma que quando um organismo se encontra num estado em que as unidades de transmissão, as conexões E-R, estão prontas a transmitir, então a transmissão é satisfatória. Se a unidade de transmissão não estiver pronta, então a transmissão é perturbada (Thorndike, 1932).

A Lei do Exercício, também conhecida como Lei do Uso e do Desuso, afirma que quanto maior a utilização da conexão E-R, mais forte esta se tornará. O contrário também se verifica. Thorndike afirmava que a prática apenas origina uma melhoria se for seguida de uma informação retroativa positiva ou de uma recompensa.

A Lei da Prontidão e do Exercício tem várias implicações no ensino. Uma das implicações é que para que ocorra o fortalecimento das conexões é necessário praticar (lei do uso). O enfraquecimento ou esquecimento das conexões ocorre quando a prática sofre uma interrupção (lei do desuso) (Cooper, 2009).

É da responsabilidade do professor inculcar aos alunos a prática das respostas desejadas através de exercícios que fortalecem as conexões a serem aprendidas e, em simultâneo, descontinuar a prática de conexões indesejáveis. Em suma, é necessário praticar de modo a melhorar o desempenho. É necessário também que haja prontidão de modo a que a concretização de uma ação seja satisfatória (Godfrey e Thorndike, 1949). Deste modo, se o professor demonstrar ao aluno que a sua resposta é a desejada, mais predisposto este estará para responder de uma certa maneira. Como exemplo desta lei pode-se considerar: no decorrer de uma aula, um aluno que vá ao quadro resolver um exercício e este ter sido resolvido de forma correta, o professor atribuir-lhe um elogio. Desta forma obteve-se o fortalecimento das conexões E-R através da prática ao mesmo tempo que foi mostrado ao aluno que esta era a resposta desejada.

3.1.1.3 Teoria de Burrhus Frederic Skinner

Burrhus Frederic Skinner (1904-1990) foi um psicólogo norte-americano formado em Harvard tendo sido o principal representante do condutivismo nos EUA. Os condutivistas explicam o comportamento animal e humano numa lógica de respostas a diferentes estímulos. Skinner criou a vertente radical do comportamentalismo que é contrária à ideia de que o ser humano seja desprovido de qualquer porte fisiológico e genético defendido pelo comportamentalismo metódico. Matos (1995) afirma que o termo radical foi utilizado por duas razões: por negar radicalmente a existência de algo que escapa ao mundo físico, isto é, que não tenha uma existência identificável no espaço e no tempo (como a mente, a consciência e a cognição) e por radicalmente aceitar todos os fenómenos comportamentais. Skinner acreditava nos padrões de estímulo-resposta de uma conduta condicionada e considerava que a mente não era relevante para a compreensão da razão. Segundo Skinner o meio é responsável pelas mudanças no comportamento, uma vez que as consequências da resposta influenciam a ação futura e porque estas consequências ocorrem no meio exterior. Tudo o que a pessoa faz é o resultado direto da sua história pessoal de reforços e punições. Deste modo, o ensino é um processo de condicionamento através do uso do reforço das respostas que se querem obter. Na perspetiva de Skinner o processo de aprendizagem é constituído por duas etapas: a primeira etapa consiste em ordenar sequencialmente os passos necessários à obtenção da instrução desejada; a segunda

etapa consiste em executar o programa delineado, reforçando as respostas corretas correspondentes aos objetivos pretendidos.

Os maiores contributos do condicionamento operante são o “ensino programado” e as “máquinas de ensinar” (Moreira, 1999), que consistem numa técnica onde são expostos um por um os elementos do conteúdo a ser ensinado, numa sequência em que o aluno passa a uma etapa posterior só depois de ter aprendido a etapa anterior. Este método tem como vantagem adaptar-se ao ritmo de cada aluno, promovendo a sua capacidade de evolução. A “Instrução Programada” criada por Skinner pode ser considerada como uma das primeiras abordagens na utilização do computador na educação, sendo as suas ideias utilizadas ainda hoje na construção de muitas aplicações de *software* como por exemplo, tutoriais e cursos de línguas, entre outros.

3.1.2 Teorias cognitivas

As teorias cognitivas estudam o processo de cognição, em que um indivíduo atribui significado à realidade no qual se encontra. Estudam o processo de compreensão, transformação, armazenamento e uso da informação envolvido na cognição. O cognitivismo dedica-se a estudar aquilo que é ignorado pelas teorias comportamentalistas, a cognição, o ato de conhecer a realidade envolvente. As teorias cognitivas consideram a aprendizagem como um processo de armazenamento de informação em que o conteúdo de um determinado assunto é organizado de uma determinada forma. Assim, procuram não só definir como os indivíduos percebem e coordenam as suas interações com o ambiente, mas também como aprendem e reutilizam a informação integrada nas suas memórias de longo prazo.

Das principais teorias cognitivistas, destacam-se o Construtivismo, o Interacionismo e a Aprendizagem Significativa.

- O Construtivismo é uma das abordagens do cognitivismo que estuda como o indivíduo constrói a sua estrutura cognitiva utilizada na aquisição do conhecimento e quais os processos de pensamento presentes no homem desde a sua infância até a idade adulta;
- O Interacionismo considera relevante a cultura envolvente e a experiência de um indivíduo no processo de construção do seu conhecimento.
- A Aprendizagem Significativa tem em conta o processo que ocorre quando uma nova informação se relaciona com outras informações já presentes na estrutura cognitiva. Desta forma, para ensinar adequadamente é preciso ter em conta o que o aluno já sabe.

As teorias cognitivas mais recentes e com bastante influência no processo de ensino são as de Bruner, Piaget e Ausubel.

3.1.2.1 Teoria de Jerome Bruner

Bruner (1915-1916) acreditava que era possível ensinar qualquer assunto a qualquer criança em qualquer estágio de desenvolvimento (Bruner, 1975). Segundo Bruner, para o processo de aprendizagem ser eficaz o importante é a estrutura da matéria, as suas relações e as suas ideias. No processo de ensino, Bruner defende o processo da descoberta através da exploração de alternativas. Este processo consiste na apresentação de conteúdos de ensino, criando um ambiente com várias alternativas, resultando no aparecimento de relações e similaridades.

O professor não deve expor os conteúdos da matéria de forma explícita, mas criar condições para que sejam os alunos a atingir os objetivos propostos. Ao professor cabe a responsabilidade de atuar como um guia e apresentar as ferramentas necessárias ao aluno para que este descubra por si próprio o que é suposto aprender.

A Teoria da Aprendizagem por Descoberta defende que o processo de aprendizagem deve ter em conta dois aspetos: o primeiro é existir predisposição por parte do aluno para a aprendizagem; o segundo é a forma como um conjunto de conhecimentos deve estruturar-se de modo que este seja interiorizado da melhor forma possível. Bruner afirma que “*é possível ensinar tudo aos alunos desde que se utilizem procedimentos adaptados aos seus estilos cognitivos e às suas necessidades*” (Bruner, 1975). Isto significa que é fundamental a interação entre os alunos e o professor, o tipo de instrução que o professor pretende ensinar e a representação dessa mesma instrução. Nesta conceção o aluno assume um papel ativo na sua aprendizagem, e ao professor cabe o papel de organizador da estrutura curricular e das informações contidas nessa estrutura que vai guiar o aluno de encontro aos objetivos pretendidos. Bruner refere que “*A educação é uma complexa procura no sentido de ajustar uma cultura às necessidades dos seus membros e de ajustar os seus membros e seus modos de conhecer às necessidades da cultura*” (Bruner, 2000). O autor considera que o desenvolvimento psicológico é independente do meio ambiente social e cultural e defende que a educação tem a função de mediar entre o aluno e o meio histórico-cultural no qual este se desenrola (Barros, 1998).

3.1.2.2 Teoria de Jean Piaget

Jean Piaget (1896-1980) nasceu na Suíça, tendo-se doutorado em biologia pela Universidade de Neuchâtel. O tema central do seu trabalho foi sobre a natureza do conhecimento humano. A teoria de Piaget tem como objetivo principal estudar a origem dos processos mentais e como esses processos são construídos ao longo da vida de um indivíduo (Piaget, 1953). Para Piaget o conhecimento resulta das ações e interações de um sujeito com o ambiente em que está inserido. O conhecimento é uma construção que é elaborada desde a infância, por meio de interações do sujeito com os objetos que procura conhecer, sejam eles do mundo físico ou do mundo cultural. O conhecimento resulta de uma inter-relação do sujeito que conhece com objeto a ser conhecido (Moreira, 1999). Piaget distingue quatro períodos de desenvolvimento cognitivo: estágio sensório-motor, estágio pré-operacional, estágio das operações concretas e o estágio das operações formais. Cada uma dessas fases é caracterizada por formas diferentes de organização mental que possibilitam as diferentes maneiras do indivíduo relacionar-se com a realidade que o rodeia (Coll e Gilliéron, 1987):

- **Estádio sensório-motor (0 - 2 anos):** é neste período que a inteligência se adapta ao meio essencialmente através de processos sensório-motores. A grande aquisição do estágio sensório-motor é o conceito de objeto permanente, sinal do aparecimento da capacidade de representação simbólica. A inteligência prática dá lugar à inteligência representativa, permitindo a interiorização simbólica das ações, isto é, a capacidade de resolver mentalmente problemas e de usar a linguagem. Um exemplo deste estágio é o bebê ver o que está à sua frente, agarrar o que está ao seu alcance e mamar o que é posto na sua boca. Aprimorando estas tarefas, o bebê é capaz de ver um objeto, pegá-lo e levá-lo à boca.
- **Estádio pré-operacional (2 - 7 anos):** é neste estágio surge na criança a capacidade de substituir um objeto ou acontecimento por uma representação. Esta substituição é possível graças ao aparecimento da linguagem. Para Piaget a linguagem é considerada como uma condição necessária mas não suficiente para o desenvolvimento da criança, uma vez ser necessária a reorganização da ação cognitiva que não é obtida através da linguagem, conforme afirma (La Taille, 1992). Por esta razão este estágio é também conhecido como o estágio da Inteligência Simbólica e caracteriza-se, pela interiorização de esquemas de ação construídos no estágio anterior. Exemplo: mostram-se à criança duas pequenas bolas de plasticina com massas iguais, mas entretanto dá-se a uma delas a forma cilíndrica. A

criança nega que a massa continua igual não conseguindo relacionar as duas situações pelo fato de as formas serem diferentes.

- **Estádio das operações concretas (7 - 12 anos):** neste estágio a criança desenvolve noções de tempo, espaço e velocidade, sendo capaz de relacionar vários aspectos e abstrair certas partes da realidade. Piaget considera que é neste estágio que se reorganiza o pensamento. Se no estágio anterior a criança não conseguia perceber que a quantidade era a mesma independentemente do formato do copo, neste estágio já percebe que a quantidade de matéria é a mesma, pois já compreende noções como volume, peso, espaço, tempo, etc. Por Exemplo: ao despejar-se a água contida em dois copos, noutros com formatos diferentes, e perguntar à criança se as quantidades continuam iguais. Neste estágio a resposta será afirmativa uma vez que a criança já consegue diferenciar aspectos e é capaz de “refazer” a ação.
- **Estádio das operações formais (12 anos em diante):** neste estágio que a criança realiza raciocínios abstratos, sem necessitar de recorrer ao contacto com a realidade. Abandona o domínio do concreto para passar às representações abstratas sendo nesta fase que desenvolve a sua identidade, podendo neste período existir problemas existenciais e dúvidas entre o certo e o errado. É nesta fase que as estruturas cognitivas da criança alcançam o seu nível mais elevado de desenvolvimento e estão aptas a aplicar o raciocínio lógico a todos os tipos de problemas. Exemplo: se lhe pedirem para analisar o provérbio “grão a grão, enche a galinha o papo”, a criança processa a informação com a lógica da metáfora e não com a imagem de uma galinha a comer grãos.

Piaget propôs as suas ideias alinhadas com as teorias construtivistas na década de 30 tendo atingido popularidade na década de 80, no início do declínio do comportamentalismo. As ideias de Piaget têm influenciado o ensino na área de Ciências de um modo geral e da Física em particular, devido ao facto de terem mostrado que as crianças desenvolvem espontaneamente noções sobre o mundo físico e que o ensino deve ser compatível com o nível de desenvolvimento mental da criança.

3.1.2.3 Teoria de David Ausubel

A teoria da assimilação, também conhecida como teoria da aprendizagem significativa, foi desenvolvida pelo psicólogo americano David Ausubel (1918-2008) na década de 60 (apud Moreira, 1999). É uma teoria cognitivista que tenta explicar os mecanismos internos e a forma como é feita a estruturação do conhecimento na mente do aluno. Segundo Ausubel o armazenamento da informação na mente humana é um processo organizado de forma hierárquica na qual elementos mais específicos do conhecimento são ligados a conceitos e ideias. Ausubel considera que o conhecimento prévio serve de matriz organizacional para a compreensão e fixação de novos conhecimentos quando estes “se ancoram” em conhecimentos especificamente relevantes (subsunçores) preexistentes na estrutura cognitiva. Por “subsunçor” considera-se um conceito, uma ideia, uma proposição já existente na estrutura cognitiva, capaz de servir de “ancoradouro” a uma nova informação de modo que esta adquira um significado para o indivíduo.

Ausubel acredita na importância da aprendizagem por descoberta, e valoriza a aula do tipo expositiva. Segundo (Ausubel, 2000), a aprendizagem passa por dois processos: o primeiro é o processo de descoberta: o aluno deve aprender “sozinho” e deste modo deve descobrir algum princípio, relação ou lei; o segundo processo é o de receção, em que o aluno recebe a informação pronta e o seu trabalho consiste em atuar sobre o material a fim de relacioná-lo com ideias relevantes existentes na sua estrutura cognitiva. Para (Ausubel 1963) o processo de aprendizagem significativa é o mecanismo humano, por excelência, para adquirir e armazenar a vasta quantidade de ideias e informações representadas em qualquer campo de conhecimento. A ideia mais importante da teoria de Ausubel e as suas implicações no ensino podem ser resumidas na seguinte frase: “*se se tivesse que reduzir toda a psicologia educacional a um só princípio, diria o seguinte: o fator isolado mais importante que influencia a aprendizagem é aquilo que o aprendiz já sabe*” (Ausubel, 1968).

3.1.3 Teorias humanistas

O conceito principal das teorias humanistas é o ensino centrado no aluno. Esta corrente defende que o aluno deve possuir liberdade para aprender e valoriza o seu desenvolvimento pessoal. O pensamento, sentimentos e ações devem fazer parte do ensino e encontram-se interligados. A noção de desenvolvimento pessoal tem origem no conceito de desenvolvimento apresentado por Rogers e traduz-se na convicção de que o ser humano tem a capacidade de tomar

consciência da sua experiência, de a avaliar, verificar, corrigir, o que exprime a sua tendência inerente ao desenvolvimento para a maturidade, ou seja para a autonomia e para a responsabilidade. Outro defensor da corrente humanista foi George Kelly. Segundo este autor os indivíduos formam uma construção cognitiva do ambiente, onde são criados padrões em que as relações sociais são organizadas. Kelly considera que para compreender a personalidade de alguém é necessário conhecer os seus padrões.

3.1.3.1 Teoria de Carl Rogers

Carl Rogers (1902-1987) nasceu nos EUA, formado-se em História pela Universidade de Chicago em 1924 e doutorou-se em Psicologia Educacional pela Universidade de Columbia (1931). Rogers, afirmava que o processo de aprendizagem era semelhante ao papel de um psicólogo e o aluno tem o mesmo papel que o paciente. O professor tem como tarefa facilitar o processo de educação que é conduzido pelo aluno à sua maneira.

A teoria de Rogers surgiu como uma terceira via em relação ao comportamentalismo e à psicanálise de Freud. Esta teoria oponha-se às ideias de análise apenas do comportamento defendida pelo comportamentalismo e da importância dada ao inconsciente e seu determinismo, defendido pela Psicanálise.

A abordagem de Rogers é considerada humanista por se basear numa conceção otimista do homem ao considerar que o desenvolvimento das capacidades pessoais assim como a sanidade mental são características do desenvolvimento humano. Segundo Rogers o organismo de todos os seres vivos possui uma tendência para se atualizar e para ser autónomo. Estas características constituem a força motriz que faz mover os seres vivos. Nesta abordagem, foram criados dois conceitos e que são considerados pontos fundamentais para a compreensão do seu modelo terapêutico: a tendência atualizante e a não diretividade.

A tendência atualizante conduz não só à satisfação das necessidades básicas do organismo, como também as mais complexas. Esta noção permite a confirmação do *Self* assim como também a preservação do organismo, facultando assim, a consonância entre a experiência vivida e a sua simbolização (Capelo, 2000).

Além da tendência atualizante Rogers propõe o conceito de não diretividade. A definição de não diretividade passa, pelo acreditar que “*o indivíduo tem dentro de si amplos recursos para a auto compreensão, para alterar o seu autoconceito, as suas atitudes e o seu comportamento auto dirigido*” (Rogers, 1989). Neste paradigma o aluno é visto como uma pessoa no seu todo e desta forma o ensino deve facilitar a sua autorrealização, visando uma aprendizagem que

engloba as aprendizagens afetiva, cognitiva e psicomotora. De acordo com Rogers o objetivo final de um sistema de ensino, deve ser a formação de pessoas “plenamente atuantes”. Para Rogers os alunos precisam ser compreendidos e não avaliados, julgados ou ensinados. A aprendizagem envolve a pessoa como um todo, incluindo os seus sentimentos assim como o seu intelecto. Além disso, aprender a aprender, ou seja, ser independente, criativo e autoconfiante é mais fácil quando a autocrítica e a autoavaliação assumem um papel principal e a avaliação por outros possui uma importância secundária.

3.1.3.2 Teoria de George Kelly

George Kelly (1905-1967) nasceu no Kansas, EUA. Formou-se em física e estudou sociologia educacional na Universidade de Kansas onde obteve um Mestrado. Foi professor de Psicologia na Universidade do Estado de Ohio e a sua obra mais relevante foi: Uma Teoria da Personalidade - A Psicologia dos Constructos Pessoais (Kelly, 1963). Kelly elaborou uma teoria formal, com o postulado “*Os processos de uma pessoa são psicologicamente canalizados pelas formas com que ela antecipa eventos*” (Kelly, 1963) e onze corolários, sendo estes: Corolário da Construção, Experiência, Organização, Individualidade, Dicotomia, Faixa, Escolha, Modulação, Fragmentação e Sociabilidade. Segundo Kelly, para compreender a personalidade de alguém é necessário conhecer os seus padrões e a forma como organiza a construção do seu mundo. A essas teorizações que as pessoas fazem perante as situações da sua vida e perante as outras pessoas, são denominados de Constructos pessoais. Um constructo é a maneira de um indivíduo ver a vida, é uma hipótese elaborada intelectualmente para interpretar e explicar os eventos que ocorrem diariamente. Um indivíduo tem a expectativa que os seus constructos irão prever e explicar a realidade e testa esses constructos constantemente. Deste modo, um indivíduo baseia o seu comportamento nos constructos ao mesmo tempo que avalia os resultados obtidos. No ensino a tarefa do professor consiste em apresentar aos estudantes, situações em que os seus constructos pessoais possam ser articulados e desafiados pelos constructos formais de uma visão científica. De acordo com o ponto de vista de Kelly, o essencial é que o conhecimento formal e suas teorias científicas seja apresentado como hipotético e passível de reconstrução e avaliação por parte do aluno.

3.2 Estilos de aprendizagem

Nesta secção apresentam-se os vários modelos de estilos de aprendizagem que foram considerados no projeto e no desenvolvimento da plataforma ADAPT. Os modelos foram selecionados por serem os mais utilizados na literatura e por se considerar que se enquadram no objetivo que se pretende atingir com o referido projeto. Este objetivo consiste em determinar o estilo de aprendizagem de um aluno e com base na informação obtida, adequar a apresentação dos conteúdos. Os modelos de estilos de aprendizagem são geralmente entendidos como algo que tenta determinar a melhor forma de uma pessoa aprender. Partem do pressuposto que cada pessoa tem um estilo de aprendizagem diferente e preferido com o intuito de obter melhores resultados. Os modelos analisados são: o modelo *Myers-Briggs Type Indicator*, o modelo de aprendizagem de Kolb, o modelo de estilos de aprendizagem de Felder-Silverman e o modelo VARK.

3.2.1 Modelo Myers-Briggs Type Indicator

Um dos instrumentos de avaliação da personalidade utilizado para a classificação de indivíduos é o modelo Myers-Briggs Type Indicator (Myers e McCauley, 1985). Foi concebido por Katherine Briggs e por Isabel Briggs Myers, com base no trabalho de Carl Jung. No modelo Myers-Briggs Type Indicator (MBTI), cada indivíduo possui uma predisposição para ser *extrovertido* (E) ou *introvertido* (I), *sensorial* (S) ou *intuitivo* (N), *pensativo* (T) ou *sentimental* (F), e *julgador* (J) ou *perceptivo* (P). Estas características são agrupadas em quatro dimensões: *Extrovertido/Introvertido*, *Sensorial/Intuitivo*, *Pensativo/Sentimental* e *Julgador/Perceptivo* (Myers, 1980).

A dimensão *Extrovertido/Introvertido* refere-se à preferência pelo mundo externo ou interno onde são apresentados dois opostos:

(E) Extrovertido - indivíduos deste tipo preferem estímulos exteriores. Sentem-se mais confortáveis a trabalhar com pessoas e a realizarem trabalho em equipa. Gostam de realizar várias atividades. Têm preferência por estudos rápidos e superficiais.

(I) Introvertido - sentem-se mais confortáveis quando o seu trabalho envolve ideias e consiste em examinar a informação interiormente. São mais teóricos e gostam de refletir antes de agir. Possuem maior apetência para estudos profundos e demorados.

A dimensão **Sensorial/Intuitivo** refere-se à percepção ou recolha de informação e é descrita do seguinte modo:

(S) Sensorial - este tipo de aluno recebe a informação principalmente através dos sentidos. Indivíduos sensoriais gostam de coisas práticas e com utilidade. Preferem concentrar-se em factos e gostam de detalhes;

(N) Intuitivo - percebe significados e relações que estão fora dos sentidos. Aborrecem-se com atividades rotineiras e são mais produtivos quando encontram algo diferente. Os indivíduos classificados como intuitivos necessitam de se sentirem inspirados, sendo nesta situação os mais inovadores.

A dimensão **Pensativo/Sentimental** refere-se ao julgamento ou à avaliação da informação e é caracterizada do seguinte modo:

(T) Pensativo - toma decisões com base em regras. Têm tendência para serem lógicos e consistentes. Gostam de prever o resultado lógico das alternativas de ação e tomam decisões com base na causa e efeito;

(F) Sentimental - os indivíduos sentimentais gostam de tomar decisões com base em sentimentos e emoções. Consideram em primeiro lugar aquilo que é importante para eles independentemente da lógica e decidem com base em valores pessoais.

A dimensão **Julgador/Perceptivo** refere-se à atitude que um indivíduo tem perante o mundo e é descrita da seguinte forma:

(J) Julgador - possui uma atitude crítica e de avaliação, vive de forma ordenada, planeada e controlada seguindo caminhos lógicos e estruturados. Apreciam a rotina e não gostam de surpresas. Estes indivíduos geralmente são apáticos e passivos;

(P) Perceptivo - este tipo de indivíduo gosta de fazer coisas criativas, de forma não linear, seguindo caminhos aparentemente desorganizados e desconexos. São curiosos e apreciam a inovação e a flexibilidade.

As combinações das preferências nas quatro dimensões anteriormente descritas originam 16 perfis diferentes de personalidade, com características distintas, e que são apresentadas na Figura 2. O perfil é obtido através da realização de um questionário em que o resultado consiste na combinação das quatro características com maior pontuação.

<u>ISTJ</u>	<u>ISFJ</u>	<u>INFJ</u>	<u>INTJ</u>
<u>ISTP</u>	<u>ISFP</u>	<u>INFP</u>	<u>INTP</u>
<u>ESTP</u>	<u>ESFP</u>	<u>ENFP</u>	<u>ENTP</u>
<u>ESTJ</u>	<u>ESFJ</u>	<u>ENFJ</u>	<u>ENTJ</u>

Figura 2 - Os 16 perfis do modelo Myers-Briggs Type Indicator (Pittenger, 1993).

Considerando um exemplo em que o perfil obtido foi do tipo ISTJ o resultado seria apresentado através da percentagem das preferências com maior pontuação: **Introversão (47%)**, **Sensorial (1%)**, **Pensativo (34%)**, **Julgador (41%)**. Este resultado significa uma preferência moderada de **Introversão** sobre **Extraversão (47%)**,

preferência marginal ou inexistente de **Sensorial** sobre **Intuição (1%)**, preferência moderada de **Pensativo** sobre o **Sentimental (34%)** e preferência moderada de **Julgador** sobre **Perceptivo (41%)**.

O modelo MBTI é frequentemente utilizado nas áreas de orientação profissional, dinâmicas de grupo, preparação para cargos de liderança, aconselhamento matrimonial, desenvolvimento pessoal, entre outros.

3.2.2 Modelo de aprendizagem de Kolb

O modelo de aprendizagem de Kolb é um modelo experiencial uma vez que considera a aprendizagem como um processo em que o conhecimento é criado através da transformação da experiência (Kolb, 1984). A essência do modelo consiste na descrição do ciclo de aprendizagem fazendo a descrição de como um indivíduo gera, a partir da sua experiência, os conceitos que determinarão o seu comportamento em novas situações, bem como a forma como esse indivíduo modifica esses conceitos com a finalidade de melhorar a sua aprendizagem.

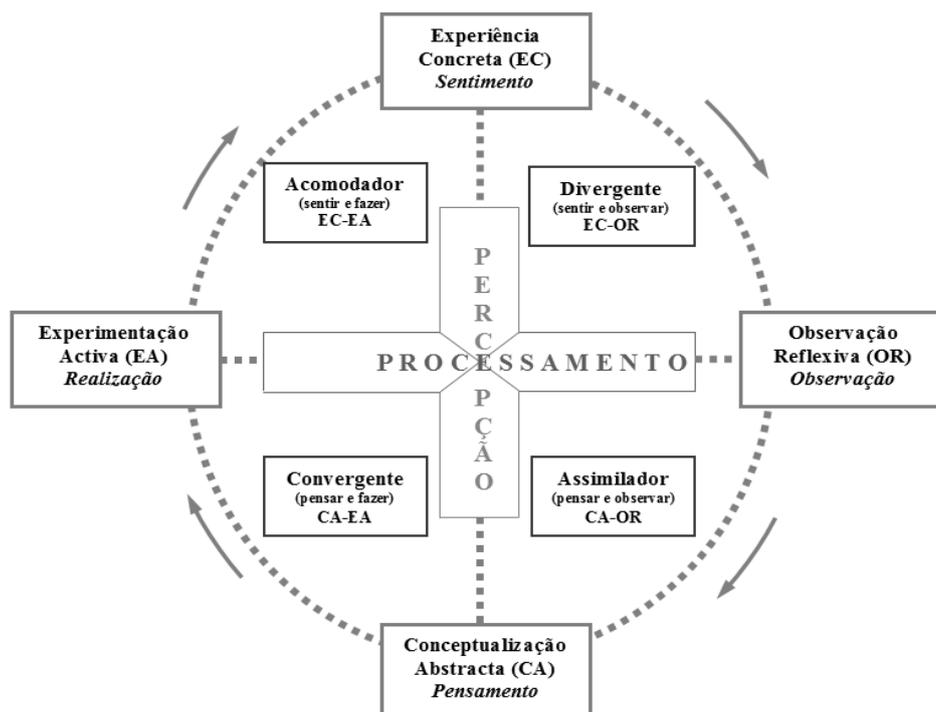


Figura 3 - Ciclo da aprendizagem experiencial de Kolb (Kolb, 1984).

Para tal, este modelo define um ciclo de aprendizagem iterativo, formado por quatro fases consecutivas: *Experiência Concreta (EC)*, *Observação Reflexiva (OR)*, *Conceptualização Abstracta (CA)* e *Experimentação Ativa (EA)*, conforme ilustra a Figura 3. De acordo com este modelo a aprendizagem pode ter início em qualquer fase, mas o ideal é que o indivíduo consiga percorrer todos os estágios do ciclo de modo a que a aprendizagem seja bem sucedida. As quatro fases do ciclo são as seguintes:

- *Experiência Concreta (EC)* - Na primeira fase do ciclo de aprendizagem ocorre o envolvimento com experiências concretas como ver, ouvir e tocar;
- *Observação Reflexiva (OR)* - Nesta fase inicia-se a observação e reflexão das experiências. O objetivo é a compreensão, por intermédio da observação e do significado das ideias e dos factos;
- *Conceptualização Abstracta (CA)* - Na fase CA ocorre a integração e transformação das observações e reflexões em teorias e conceitos. Interessa-se por teorias gerais e privilegia o pensar;
- *Experimentação Ativa (EA)* - Na fase EA as teorias são utilizadas para realizar tomadas de decisão e resolução de problemas.

Segundo o modelo de Kolb, no processo de aprendizagem estão envolvidas duas dimensões:

- **Percepção da informação** - Relacionada com a resposta emocional. Aprender pelo sentimento ou pelo pensamento;
- **Processamento da informação** - Relativa à abordagem a uma determinada tarefa. Aprender através da observação ou da realização.

Com base na combinação das duas dimensões referidas acima, Kolb desenvolveu o *Learning Style Inventory* (LSI) (Kolb, 1985) que permite classificar os indivíduos em quatro perfis de estilos de aprendizagem. A Tabela 1 apresenta de forma sintetizada os quatro perfis de estilos de aprendizagem e as suas principais tendências e aptidões dominantes (Gomes, 2010).

Tabela 1 - Estilos de Aprendizagem segundo Kolb e as suas Aptidões Dominantes.

Estilo	Características
<i>Divergente</i>	<p>Aptidões dominantes: EC-OR</p> <p>O seu ponto forte é a imaginação e produção de ideias. Sobressai em situações que exigem geração de ideias. É emotivo, interessa-se por pessoas (gosta de trabalhar em grupo). Tem interesses culturais amplos. Tende a especializar-se em artes. Característico dos indivíduos das áreas de humanidades.</p>
<i>Assimilador</i>	<p>Aptidões dominantes: CA-OR</p> <p>O seu ponto forte é a capacidade de criar modelos teóricos. Sobressai em raciocínio indutivo (assimilar observações desconstruídas e transformá-las em explicações integradas). Menos interessados por pessoas e mais em conceitos abstratos (ideias). Possui mais interesses teóricos do que nas suas aplicações práticas. Característico de pessoas que trabalham em departamentos de investigação e planeamento (Ciências, economia e física).</p>
<i>Convergente</i>	<p>Aptidões dominantes: CA-EA</p> <p>O seu ponto forte é a aplicação prática de ideias abstratas, aprende testando os seus conceitos. Sobressai em raciocínio hipotético dedutivo, através do qual se consegue concentrar em problemas específicos. Prefere lidar com “coisas” a lidar com pessoas. Tem interesses técnicos específicos. Característico de muitos engenheiros.</p>

Acomodado	<p>Aptidões dominantes: EC-EA</p> <p>O seu ponto forte é realizar coisas, executar planos e experiências. Sobressai em situações nas quais precise de se adaptar às circunstâncias imediatas e específicas.</p> <p>Gosta de estar com pessoas, embora seja, geralmente, impaciente e pressionador.</p> <p>Tem interesses por experiências novas e em assumir riscos.</p> <p>Característico de indivíduos de áreas de negócios/comércio.</p>
------------------	--

3.2.3 Modelo de Felder-Silverman

O modelo de Felder-Silverman (Felder e Spurlin, 2005) classifica o estilo de aprendizagem de um aluno numa das categorias de quatro dimensões de preferências de aprendizagem: **Sensorial/Intuitivo, Visual/Verbal, Ativo/Reflexivo, Sequencial/Global**.

Felder e Silverman desenvolveram o modelo de estilo de aprendizagem, por duas razões: a primeira foi para determinar as diferenças de estilo de aprendizagem mais importantes entre os estudantes de engenharia e a segunda razão foi para fornecer uma base aos professores de engenharia para desenvolver uma abordagem de ensino que fosse ao encontro das necessidades de aprendizagem de todos os alunos (Felder e Silverman, 1988).

De seguida apresentam-se as quatro dimensões de preferências de aprendizagem do Modelo de Felder-Silverman:

Ativo/Reflexivo - aluno ativo (aprende por experimentação, a trabalhar com os outros) ou aluno reflexivo (aprende a pensar nas coisas, gosta de trabalhar sozinho);

Sensorial/Intuitivo - aluno sensorial (concreto, prático, orientado para factos e processos) ou aluno intuitivo (conceptual, inovador, orientado para teorias e significados);

Visual/Verbal - aluno visual (dá preferência às representações visuais do material apresentado: imagens, diagramas, fluxogramas) ou aluno verbal (prefere explicações escritas e faladas);

Sequencial/Global - aluno sequencial (linear, ordenado, aprende através de pequenos passos incrementais) ou aluno global (holístico, pensadores sistemas, aprender em grandes saltos) (Felder, 1996).

De modo a determinar as dimensões preferenciais de um aluno foi criado o *Index of Learning Styles* (ILS) (Felder e Soloman, 2011) que para o efeito coloca 11 questões de escolha obrigatória para cada uma das quatro dimensões, originando um total de 44 questões (Felder e Spurlin, 2005). Cada pergunta tem uma resposta possível (a) ou (b) que corresponde a uma das

categorias relacionadas com a dimensão, por exemplo, a dimensão *Ativo* ou *Reflexivo*. As respostas (b) são subtraídas a partir das respostas (a) de modo a obter-se uma pontuação que é um número ímpar entre -11 e 11. A classificação de um indivíduo numa ou noutra categoria pode ser forte (9 a 11), moderada (5 a 7) ou fraca (1 a 3). Um indivíduo cuja categoria seja classificada como fraca apresenta uma preferência relativamente indiferente por qualquer uma das categorias dessa dimensão. Uma classificação moderada significa que o indivíduo possui alguma preferência por determinada categoria nessa dimensão. Os indivíduos com uma pontuação elevada têm uma forte preferência por uma determinada categoria dessa dimensão sentindo dificuldade quando os materiais de aprendizagem lhe são apresentados através de técnicas opostas (Gomes, 2010). A Figura 4 mostra um exemplo de um resultado gerado após a resposta de um aluno ao teste ILS.

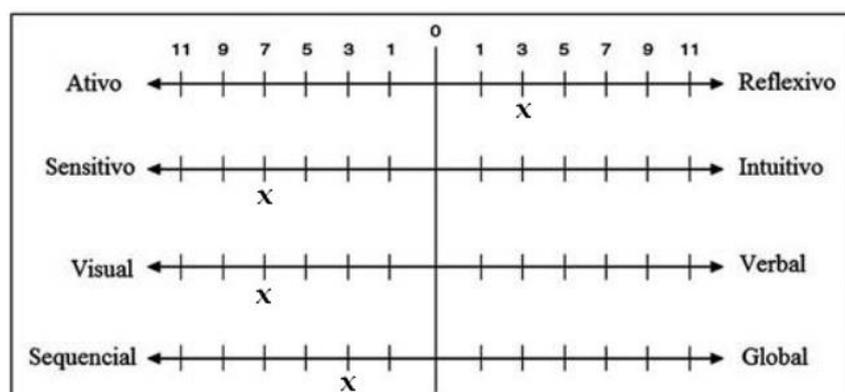


Figura 4 - Exemplo do resultado de um teste ILS. Adaptado de Felder e Silverman, (1988).

No exemplo da Figura 4 o aluno é fracamente reflexivo (Reflexivo =3), moderadamente sensorial (Sensitivo=7), moderadamente visual (Visual=7) e fracamente sequencial (Sequencial=3).

3.2.4 Guia de Estilos de Aprendizagem VARK

O Guia de Estilos de Aprendizagem VARK de Neil Fleming e Colleen Mills permite a um aluno determinar o seu perfil relativamente à sua preferência de aprendizagem (apud Gomes, 2010). Essa preferência é determinada através de um questionário com 16 perguntas que determina a forma que o aluno está mais predisposto para receber a informação. Os autores deste questionário acreditam que as pessoas recebem informações através dos sentidos e o cérebro seleciona algumas dessas informações e ignora o resto. As pessoas escolhem a informação à qual querem prestar atenção, de acordo com seus interesses. O questionário

VARK efetua a descrição de quatro tipos distintos de aprendizagem: **(V) visual**, **(A) auditiva**, **(R) leitura/escrita**, **(K) cinestésico**. De acordo com a teoria de estilos de aprendizagem VARK, alguns alunos processam informações de forma mais eficaz utilizando um estilo visual, enquanto outros preferem o estilo auditivo, ou da aprendizagem através da leitura/escrita ou então do estilo de aprendizagem cinestésico. Apesar da maioria dos alunos possuírem uma preferência marcada por um estilo particular de aprendizagem, estes normalmente são capazes de processar informações, mesmo se forem apresentadas no formato de um estilo não preferencial. Contudo, muitas pessoas reconhecem os benefícios associados aos vários estilos de aprendizagem. Por exemplo, um aluno que manifeste uma forte preferência na aprendizagem cinestésica também pode responder bem ao estilo de aprendizagem auditiva. De seguida são descritas as quatro preferências de aprendizagem:

(V) Visual: a aprendizagem visual é um estilo de aprendizagem em que as ideias, conceitos, dados e outras informações associadas a imagens, gráficos, símbolos e diagramas;

(A) Auditiva: a aprendizagem auditiva é um estilo de aprendizagem em que uma pessoa aprende através da escuta. Um aluno auditivo depende da audição e da fala como a principal forma de aprendizagem. Este aluno também utiliza as suas capacidades auditivas e de repetição de modo a compreender a informação que lhe é enviada (Leite et al., 2009);

(R) Leitura/Escrita: os alunos deste tipo preferem ler as instruções de um livro em vez de vê-las ou de ouvi-las. Estes preferem que as informações sejam apresentadas por escrito, como listas de ideias. Enfatizam a entrada e saída de informação baseada em texto;

(K) Cinestésico: estes alunos são caracterizados pelo facto de tendencialmente serem os mais lentos de todos os locutores. Tendem a ser lentos na tomada de decisões. Utilizam todos os seus sentidos para se envolver na aprendizagem.

3.2.5 Estudo comparativo dos modelos

Neste capítulo foram descritos vários modelos que determinam os estilos de aprendizagem de um aluno. Fazer a avaliação de diferentes modelos de estilos de aprendizagem e as suas implicações requer uma apreciação difícil e complexa uma vez que esta é uma área que está longe de consenso. Nesta secção faz-se uma avaliação aos modelos apresentados descrevendo as suas vantagens e desvantagens tendo em conta o objetivo pretendido que consistiu em desenvolver uma plataforma de aprendizagem, posteriormente testada por alunos de um Curso de Especialização Tecnológica a estudar a disciplina de Sistemas Digitais. De seguida são analisados os seguintes modelos: o modelo Myers-Briggs Type Indicator, o modelo de

aprendizagem de Kolb, o modelo de Felder-Silverman e o Guia de Estilos de Aprendizagem VARK.

3.2.5.1 Modelo Myers-Briggs Type Indicator

O Modelo Myers-Briggs Type Indicator (MBTI) classifica os alunos de acordo com suas preferências em quatro dimensões: *Sensorial/Intuitivo*, *Pensativo/Sentimental*, *Extrovertido/Introvertido* e *Julgador/Perceptivo* (Myers, 1980). O MBTI foi especificamente criado como uma ferramenta para categorizar de uma forma geral o tipo de personalidade de um indivíduo e a sua abordagem em relação aos outros. Esta característica fez com que este modelo tenha sido utilizado para determinar qual o melhor percurso acadêmico que um aluno deve seguir e também utilizado em empresas para determinar a função em que um indivíduo se sente mais confortável. Alguns críticos argumentam que este não foi o propósito da criação deste modelo, mas sim para ser uma ferramenta que permita a um indivíduo ter uma maior compreensão das suas preferências (Coffield et al., 2004). Um dos aspetos positivos é obter dezasseis tipos diferentes de personalidade a partir do cruzamento das quatro dimensões. Este facto é positivo porque quando se utiliza a informação sobre estilos de aprendizagem para proporcionar adaptabilidade, uma descrição detalhada dos estilos de aprendizagem pode melhorar o processo de adaptação (Mainemelis et al., 2002). No entanto, a validade das quatro dimensões que representam características opostas é fortemente questionada (Coffield et al., 2004). Além disso, vários investigadores consideram a confiabilidade do teste baixa. Estudos efetuados concluíram que entre 39% e 76% daqueles que fizeram o teste, tiveram resultados diferentes, após novo teste efetuado algumas semanas ou anos mais tarde (Matthews, 2004; Pittenger, 1993).

3.2.5.2 Modelo de Aprendizagem de Kolb

Este modelo classifica os alunos como tendo uma preferência por: *Experiência Concreta* e *Conceptualização Abstrata* que determina como é efetuada a perceção da informação e *Experimentação Ativa* ou *Observação Reflexiva* que determina como é processada a informação. Kolb acredita que a aprendizagem ocorre durante um ciclo e que os alunos devem utilizar todas as quatro fases do ciclo para que a aprendizagem se torne efetiva (Kolb (1984; 1985). Até hoje têm sido efetuados estudos para determinar a validade deste modelo com resultados contraditórios. Mainemelis, Boyatzis e Kolb resumem as evidências a favor e contra

do modelo de Kolb (Mainemelis et al., 2002). Wierstra e DeJong (Wierstra e DeJong, 2002) fizeram uma análise em que reduziram o modelo de Kolb a uma estrutura unidimensional com dois extremos, *Reflexão* versus *Fazer*, em que o modelo resultante mostrou ter precisão, o que a confirmar-se, significa que o conceito de ciclo de aprendizagem pode estar errado. Este modelo tem vindo a ser submetido a alterações ao longo dos anos o que tem aumentado a sua fiabilidade.

3.2.5.3 Modelo de Felder-Silverman

O modelo de Estilo de Aprendizagem Felder-Silverman distingue os indivíduos em quatro dimensões: *ativo/reflexivo*, *sensorial/intuitivo*, *visual/verbal* e *sequencial/global*. Felder e Silverman (1988) afirmam que os estilos de aprendizagem refletem as preferências e tendências de um indivíduo, e não são indicadores infalíveis de pontos fortes e fracos em ambas as preferências de uma determinada dimensão. De acordo com Graf et al. (2006), o modelo de Felder é o mais apropriado nos estilos de aprendizagem de alunos de engenharia e em ambientes de alta tecnologia. Críticos deste modelo afirmam que mesmo que este seja válido num determinado grupo de indivíduos no contexto em que foi criado, ao mudarem-se as características culturais a sua validade pode ser comprometida (Anastasi e Urbina, 2000). Os próprios Felder e Spurlin (2005) afirmam que embora o instrumento no seu idioma original possa ser considerado confiável, válido e adequado, em geral as traduções não passam por processos de validação e os resultados podem afetar a validade do modelo.

3.2.5.4 Guia de Estilos de Aprendizagem VARK

O guia de estilos de aprendizagem VARK efetua a descrição de quatro tipos distintos de aprendizagem: *(V) visual*, *(A) auditiva*, *(R) leitura/escrita*, *(K) cinestésica*. Segundo os seus autores (Fleming, 1992), não constitui um modelo de estilos de aprendizagem porque se concentra apenas numa dimensão da aprendizagem, ou seja, a forma como um indivíduo prefere receber a informação. Segundo um estudo realizado por Leite et al. (2009) o guia VARK obteve mais de 60% de respostas favoráveis de indivíduos que se identificavam com o estilo sugerido pelo questionário. A estratégia VARK é muitas vezes procurada devido à sua flexibilidade e facilidade de implementação (Martins, 2008). Outra grande vantagem do questionário VARK é que ele fornece uma estratégia que pode favorecer o estilo de aprendizagem de um aluno independente do ambiente de estudo. Ainda outro aspeto importante

defendido por Kumar (2010), é que a percepção do estilo de aprendizagem pode criar um melhor ambiente de aprendizagem ao permitir que os alunos utilizem estratégias adequadas.

3.2.5.5 Resumo dos Modelos Analisados

Na Tabela 2 enumeram-se as vantagens e desvantagens do Modelo Myers-Briggs Type Indicator (MBTI), Modelo de Aprendizagem de Kolb, Modelo de Felder-Silverman e Guia de Estilos de Aprendizagem VARK.

Tabela 2 - Vantagens e Desvantagens dos Modelos.

Modelo	Vantagens	Desvantagens
<i>Modelo Myers-Briggs Type Indicator (MBTI)</i>	Possui 4 dimensões que originam 16 tipos diferentes de perfis o que possibilita a construção completa da personalidade do indivíduo.	Não é orientado especificamente para a aprendizagem. Descrição dos perfis com alguma falta de objetividade.
<i>Modelo de Aprendizagem de Kolb</i>	Melhorias do modelo efetuadas ao longo dos anos aumentaram a sua fiabilidade. A maioria dos estudos realizados confirmou a validade deste modelo.	A noção do ciclo de aprendizagem pode estar errada. Tem recebido algumas críticas em relação à sua validade. Perfis resultantes do modelo pouco objetivos.
<i>Modelo de Felder-Silverman</i>	Elevado número de evidências relativamente à validade do modelo. Possui 16 tipos diferentes de perfis, o que possibilita a construção completa da personalidade do indivíduo. Utilizado com sucesso em alunos de engenharias e ambientes de alta tecnologia.	Artigos que validam o modelo foram escritos pelo criador do modelo. Questionário muito extenso. Fora do seu idioma original a sua validade pode estar comprometida.
<i>Guia de Estilos de Aprendizagem VARK</i>	Fornecer estratégias que favorecem o estilo de aprendizagem. Confiabilidade razoável.	Não é um modelo de estilos de aprendizagem.

3.2.6 Mapeamento com VARK

Como foi referido anteriormente uma das funcionalidades da plataforma ADAPT é definir o tipo de conteúdos a apresentar de acordo com o modelo de estilo de aprendizagem do aluno. Uma vez efetuada a classificação dos conteúdos segundo o modelo VARK, pretende-se estabelecer uma relação entre cada conteúdo e as dimensões do modelo de estilo de aprendizagem de cada aluno utilizador da plataforma.

Com o objetivo de determinar qual o melhor modelo de aprendizagem para efetuar este mapeamento, nas secções seguintes propõem-se possíveis mapeamentos entre os tipos de conteúdos do modelo VARK e cada uma das dimensões dos modelos de estilo de aprendizagem analisados anteriormente. É importante referir que os conteúdos associados no mapeamento são considerados os conteúdos dominantes, ou seja, são aqueles que serão exibidos em maior proporção e não unicamente aqueles que serão exibidos. Esta solução é benéfica por duas razões: uma, porque é importante que o aluno esporadicamente seja contrariado em relação à sua preferência de receção de informação; outra razão é que permite estudar o seu comportamento quando em contacto com conteúdos que não são os preferenciais, em que eventualmente até se pode descobrir que o aluno se adapta melhor a outros tipos de conteúdos que não os sugeridos pelo modelo.

3.2.6.1 Mapeamento Myers-Briggs Type Indicator com VARK

O modelo de Myers-Briggs analisa o estilo de aprendizagem de um indivíduo em quatro dimensões. A Tabela 3 ilustra os tipos de conteúdos VARK associados aos extremos de cada uma das dimensões do modelo de Myers-Briggs, tendo como base as características mais relevantes.

Tabela 3 - Mapeamento entre o Modelo Myers-Briggs Type Indicator e o Modelo VARK.

<i>Dimensão do modelo MBTI</i>	<i>Características relevantes</i>	<i>Conteúdos VARK (Visual, Auditiva, Leitura/ Escrita, Cinestésica).</i>
<i>Sensoriais(S)/ Intuitivos(N)</i>	<i>Sensoriais (S)</i>	
	Confiam mais em coisas concretas, informações sensoriais. Gostam de detalhes e factos. Para eles o significado está nos dados. Precisam de muitas informações.	Visual, Cinestésica.
	<i>Intuitivos (N)</i>	

	Preferem informações teóricas, que podem ser associadas com outras informações. Trabalham bem com informações incompletas e imperfeitas.	Leitura/Escreita.
<i>Pensativo(T)/ Sentimental(F)</i>	<i>Pensativo (T)</i>	
	Tomam decisões com base em regras. Gostam de prever o resultado lógico das alternativas de ação e tomam decisões com base na causa e efeito.	Leitura/Escreita.
	<i>Sentimental (F)</i>	
	Os indivíduos sentimentais gostam de tomar decisões com base em sentimentos e emoções. Consideram em primeiro lugar aquilo que é importante para eles independentemente da lógica e decidem com base em valores pessoais.	Visual, Cinestésica, Auditiva.
<i>Extrovertido(E)/ Introverso(I)</i>	<i>Extrovertido (E)</i>	
	Gostam de realizar várias atividades. Têm preferência por estudos rápidos e superficiais.	Visual, Cinestésica, Auditiva.
	<i>Introverso (I)</i>	
	São mais teóricos e gostam de refletir antes de agir. Possuem maior apetência para estudos profundos e demorados.	Leitura/Escreita, Auditiva.
<i>Julgador/ Perceptivo</i>	<i>Julgador (J)</i>	
	Possuem uma atitude crítica e de avaliação, vive de forma ordenada, planeada e controlada seguindo caminhos lógicos e estruturados. Apreciam a rotina e não gostam de surpresas.	Leitura/Escreita.
	<i>Perceptivo (P)</i>	
	Gostam de fazer coisas criativas, de forma não linear, seguindo caminhos aparentemente desorganizados e desconexos. São curiosos e apreciam a inovação e flexibilidade.	Visual, Cinestésica, Auditiva.

3.2.6.2 Mapeamento Kolb com VARK

O modelo de aprendizagem de Kolb é um modelo que define um ciclo de aprendizagem que contém quatro fases que origina quatro perfis: *Divergente*, *Assimilador*, *Convergente*, *Acomodado*. A Tabela 4 mostra o mapeamento dos perfis de aprendizagem do modelo Kolb com os tipos de conteúdos VARK.

Tabela 4 - Mapeamento entre o Modelo Kolb e o modelo VARK.

<i>Dimensão</i>	<i>Características relevantes</i>	<i>Conteúdos VARK (Visual, Auditiva, Leitura/Escreita, Cinestésica).</i>
<i>Divergente</i>	O seu ponto forte é a imaginação e produção de ideias. Sobressai em situações que exigem geração de ideias.	Visual, Auditiva.

Assimilador	O seu ponto forte é a capacidade de criar modelos teóricos. Sobressai em raciocínio indutivo (assimilar observações desconstruídas e transformá-las em explicações integradas). Tem mais interesses teóricos do que nas suas aplicações práticas.	Leitura/Escrita.
Convergente	O seu ponto forte é a aplicação prática de ideias abstratas, aprende testando os seus conceitos.	Visual, Leitura/Escrita.
Acomodado	O seu ponto forte é realizar coisas, executar planos e experiências. Tem interesses por experiências novas e em assumir riscos.	Visual, Cinestésica, Auditiva.

3.2.6.3 Mapeamento Felder-Silverman com VARK

O modelo de Felder-Silverman classifica as preferências de aprendizagem em quatro dimensões de estilos de aprendizagem: *Sensorial/Intuitivo*, *Visual/Verbal*, *Ativo/Reflexivo*, *Sequencial/Global*. A Tabela 5 apresenta o mapeamento dos perfis de aprendizagem do modelo Felder-Silverman com os tipos de conteúdos VARK.

Tabela 5 - Mapeamento entre o Modelo Felder-Silverman e o modelo VARK.

Dimensão do modelo de Felder-Silverman	Características relevantes	Conteúdos VARK (Visual, Auditiva, Leitura/ Escrita, Cinestésica).
Ativo/ Reflexivo	Ativo O aluno ativo aprende por experimentação, a trabalhar com os outros.	Visual, Cinestésica, Auditiva.
	Reflexivo O aluno reflexivo aprende a pensar nas coisas, gosta de trabalhar sozinho.	Leitura/Escrita.
Sensorial/ Intuitivo	Sensorial O aluno sensorial é concreto, prático, orientado para factos e processos.	Visual, Cinestésica.
	Intuitivo O aluno intuitivo é conceptual, inovador, orientado para teorias e significados.	Leitura/Escrita, Auditiva.
Visual/ Verbal	Visual O aluno visual dá preferência às representações visuais do material apresentado: imagens, diagramas, fluxogramas.	Visual, Cinestésica.
	Verbal	

	O aluno verbal prefere explicações escritas e faladas.	Leitura/Escrita, Auditiva.
Sequencial/ Global	Sequencial	
	O aluno sequencial é linear, ordenado, aprende através de pequenos passos incrementais.	Leitura/Escrita, Auditiva.
	Global	
	O aluno global é holístico, pensador, aprende em grandes saltos.	Visual, Cinestésica.

3.2.6.4 Utilização do questionário VARK

O questionário VARK permite determinar o perfil de um indivíduo relativamente à sua preferência de aprendizagem. Conforme referido, o questionário VARK efetua a descrição de quatro tipos distintos de aprendizagem: (**V**) *visual*, (**A**) *auditiva*, (**R**) *leitura/escrita*, (**K**) *cinestésica*. Uma das possibilidades de implementação seria a de utilizar o próprio questionário VARK e assim não ter de efetuar o mapeamento com qualquer outro modelo. Esta abordagem possui vantagens e desvantagens. A principal vantagem seria poder deixar de utilizar o questionário *Index of Learning Styles* numa fase inicial da utilização da plataforma por parte de um aluno. A desvantagem na utilização do questionário VARK é que este não é um modelo de estilo de aprendizagem pelo facto de avaliar apenas uma dimensão do perfil do aluno. Isto faz com que as informações obtidas relativas do perfil do aluno sejam reduzidas, fazendo com que a capacidade de adaptação de conteúdos esteja limitada apenas ao tipo de conteúdo a exibir, negligenciando outras áreas como a forma e a sequência de apresentação dos conteúdos. A estratégia VARK não está relacionada com questões de personalidade, motivação, preferências sociais, ambientes físicos ou introversão/extraversão. A escolha de limitar o VARK à preferência de aprendizagem foi feita porque é aí que Neil Fleming teve o maior sucesso, a ajudar no processo de aprendizagem dos alunos (VARK, 2017). Em suma, o questionário VARK tem mostrado um bom desempenho a determinar as preferências de aprendizagem e apenas isso. Para determinar preferências noutras dimensões é recomendado utilizar outros modelos.

3.2.7 Análise crítica

Nesta secção realiza-se uma análise crítica dos mapeamentos possíveis, de modo a determinar o modelo mais adequado para realizar o processo de adaptação de conteúdos. Como se pode

verificar, todos os modelos analisados anteriormente possuem dimensões com características que permitem efetuar uma associação com os tipos de conteúdos do modelo VARK. O modelo de Myers-Briggs possui quatro dimensões, cada uma delas com extremos que refletem características opostas. Para cada uma destas dimensões é possível efetuar o mapeamento com o modelo VARK. O modelo de Kolb possui duas dimensões que dão origem a quatro estilos de aprendizagem diferentes. Através do ciclo de Kolb é possível determinar quais as preferências de um determinado perfil, se possui maior preferência por conteúdos visuais ou por conteúdos escritos ou orais. O mapeamento com o modelo de Kolb é mais simples de concretizar do que com o modelo de Myers-Briggs pelo facto de este ter um menor número de dimensões. O modelo de Felder-Silverman possui quatro dimensões que originam dezasseis perfis diferentes. A vantagem deste modelo é o facto de uma das dimensões ser especificamente dedicada à forma como o aluno prefere receber a informação. Isto faz com que o mapeamento seja feito de uma forma mais objetiva e com mais precisão comparativamente aos restantes modelos. Desta forma, o modelo de Felder-Silverman foi o modelo selecionado na implementação da plataforma ADAPT para efetuar o mapeamento com o modelo VARK.

3.3 Taxonomia de Bloom

Uma taxonomia é um sistema de classificação ordenado de acordo com determinados critérios. A generalidade das taxonomias de objetivos educacionais são constituídas por três domínios: cognitivo, afetivo e psicomotor. O domínio cognitivo está relacionado com as capacidades de aprendizagem mental, o domínio afetivo está relacionado com a aprendizagem de sentimentos ou aspetos da área emocional e o domínio psicomotor está relacionado com capacidades físicas ou manuais. Outra utilização importante das taxonomias é a descrição do desempenho obtido nas avaliações de um aluno, mostrando em que ponto este se encontra no estágio de aprendizagem. A taxonomia de Bloom é uma classificação de diferentes níveis de objetivos e competências que os professores definem de modo a que os alunos alcancem um determinado nível cognitivo (Bloom, 1956). A taxonomia de Bloom foi revista posteriormente por Anderson e um grupo de investigadores de psicologia cognitiva (Anderson e Krathwohl, 2001). As duas versões da taxonomia de objetivos educacionais são frequentemente descritas na literatura como Taxonomia de Bloom e Taxonomia de Bloom Revista. A consequência dessa revisão foram as alterações efetuadas em termos de terminologia e estrutura. As alterações de terminologia fizeram com que os nomes do modelo de Bloom original fossem substituídos por verbos, de forma a corresponderem às formas pelas quais os objetivos de aprendizagem são

normalmente descritos. Na Taxonomia de Bloom Revista, as competências referentes ao domínio cognitivo são divididas em seis categorias, representadas na Figura 5.

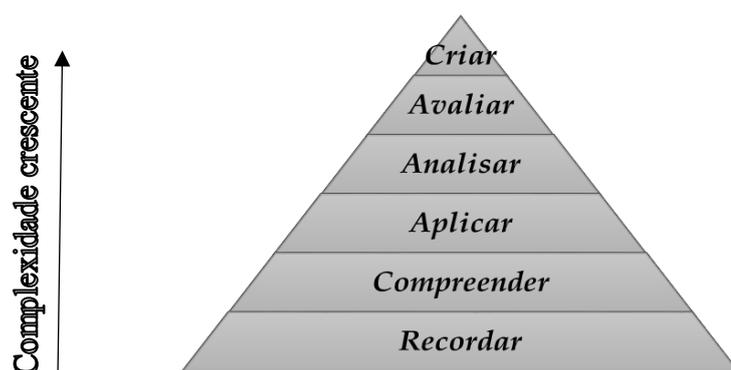


Figura 5 - Níveis hierárquicos da Taxonomia de Bloom Revista (Anderson e Krathwohl, 2001).

Os processos caracterizados pela taxonomia correspondem a resultados de aprendizagem em que cada categoria representa o que um indivíduo aprendeu. Estas categorias são organizadas relativamente aos processos mentais, ordenadas de acordo com o grau de complexidade. Na

Tabela 6 são listadas as categorias e os processos cognitivos que lhes estão associados.

Tabela 6 - Processos Cognitivos da Taxonomia de Bloom Revista.

<i>Categorias</i>	<i>Processos Cognitivos</i>
<i>Recordar</i>	Reconhecer.
<i>Compreender</i>	Interpretar, Exemplificar, Sumariar.
<i>Aplicar</i>	Executar, Implementar.
<i>Analisar</i>	Diferenciar, Organizar, Atribuir.
<i>Avaliar</i>	Verificar, Criticar.
<i>Criar</i>	Gerar, Planear, Produzir.

De seguida apresentam-se alguns exemplos de atividades que poderão ser desenvolvidas na disciplina de Sistemas Digitais correspondentes a cada uma das categorias da taxonomia de Bloom:

1) **Recordar:** consiste em reconhecer ou recordar informação, princípios específicos, métodos, processos, testes, estruturas ou conjuntos.

Um possível exemplo seria: “Represente todos os números possíveis com o sistema de numeração de base 2 com 4 bits?”

2) **Compreender:** esta categoria consiste em demonstrar o entendimento suficiente para organizar mentalmente a informação sobre um determinado assunto. A lista de palavras que

Bloom definiu para o tipo de atividades deste nível inclui “explicar” ou “traduzir”. Um exemplo poderia ser: “Realize no sistema de numeração de base 2 com 10 bits, a seguinte soma decimal: $(+65) + (-5)$ ”.

3) **Aplicar:** consiste em alcançar uma resposta, através da aplicação da informação previamente aprendida. O nível de aplicação consiste na utilização de abstrações e situações concretas, no qual se incluem, regras de procedimentos, métodos, princípios técnicos, ideias e teorias que devem ser recordadas e aplicadas. A lista de palavras que Bloom definiu para o tipo de atividades neste nível inclui “calcular”, “resolver” ou “escrever”. Um exemplo possível a utilizar em Sistemas Digitais seria: “Utilizando o mapa de Karnaugh minimize a seguinte função: $f(A, B, C, D) = E(6, 8, 9, 10, 11, 12, 13, 14)$ ”.

4) **Analisar:** a categoria Analisar consiste em realizar perguntas que exigem pensamento crítico e detalhado. A lista de palavras que Bloom definiu para o tipo de atividades neste nível inclui “categorizar”, “diferenciar”, “discriminar” ou “distinguir”. Um exemplo de uma tarefa apropriada seria: “Apresentar o diagrama de três circuitos integrados e pedir para identificar qual deles utiliza tecnologia TTL, qual utiliza a tecnologia CMOS e qual utiliza a tecnologia ECL”.

5) **Avaliar:** esta categoria inclui perguntas que requerem a execução de pensamento original e criativo. Tem como função juntar todas as partes para formar o todo. Em geral as perguntas deste nível consistem em descrições vagas de problemas, que os alunos têm de refinar e implementar. A lista de palavras que Bloom definiu para o tipo de atividades neste nível inclui “projetar”, “organizar” ou “planejar”. Um exemplo para esta categoria poderia consistir em apresentar ao aluno um determinado projeto, em que este teria que escolher qual o tipo de circuito integrado mais apropriado para a sua realização.

6) **Criar:** esta categoria inclui perguntas que possibilitem várias respostas ou soluções. A lista de palavras que Bloom definiu inclui “avaliar” ou “criar”. Um possível exemplo seria criar um projeto de SD que permitisse ao aluno a construção de circuitos integrados.

As alterações efetuadas na revisão do modelo de Bloom consideram uma gama maior de fatores que afetam o ensino e a aprendizagem, nomeadamente no nível do conhecimento. A dimensão do conhecimento divide-se em quatro categorias: *Factual*, *Conceptual*, *Procedimental* e *Metacognitiva*.

- **Conhecimento factual** - inclui elementos isolados de informação, como definições de vocabulário, conhecimento de terminologia e conhecimento de detalhes e elementos específicos;
- **Conhecimento conceptual** - consiste no conhecimento de classificações e categorias, princípios e generalizações, teorias, modelos e estrutura;
- **Conhecimento procedimental** - relacionado com o saber fazer. Inclui o conhecimento de um determinado assunto, algoritmos, heurísticas ou métodos empíricos, técnicas e métodos específicos sobre determinado assunto, bem como o conhecimento sobre os critérios para determinar quando utilizar esses procedimentos;
- **Conhecimento metacognitivo** - consiste em refletir sobre o que se sabe. Refere-se ao conhecimento dos processos cognitivos e das informações sobre como manipular esses processos de forma eficaz. Implica um conhecimento estratégico e sobre as tarefas cognitivas, incluindo o conhecimento contextual e condicional apropriado.

Esta divisão do conhecimento fornece uma matriz onde os objetivos de aprendizagem são mapeados. Cada nível de conhecimento pode corresponder a um nível do processo cognitivo (Figura 6), ou seja, o aluno pode recordar um conhecimento (A) **factual** ou (C) **procedimental**, compreender um conhecimento (B) **conceptual** ou (D) **metacognitivo** ou analisar um conhecimento (D) **metacognitivo** ou (A) **factual**.

	Fatual	Conceptual	Procedimental	Metacognitivo
Recordar				
Compreender				
Aplicar				
Analisar				
Avaliar				
Criar				

Figura 6 - Processos cognitivos e dimensão do conhecimento (adaptado de Fuller et al., 2007).

3.3 Resumo

Neste capítulo foram analisadas algumas das teorias de aprendizagem mais conhecidas (seção 3.1). O Comportamentalismo, baseia-se em mudanças observáveis no comportamento do aluno. Nesta teoria o ensino limita-se a cuidar da apresentação da informação e a organizar as contingências de reforço que facilitem a sua aquisição. O Cognitivismo, baseia-se no processo de pensamento por detrás do comportamento. Destacam-se os processos cognitivos internos que medeiam entre a codificação da informação e a resposta. Por último, o Humanismo que parte da premissa que construímos a nossa própria perspectiva do mundo, através de experiências individuais. Os alunos aprendem, desenvolvendo-se.

Em relação aos estilos de aprendizagem (seção 3.2), foram descritos vários métodos para determinar o estilo de aprendizagem de um aluno. Segundo Myers (1980) existem quatro dicotomias psicológicas em cada indivíduo: *extrovertido* (E) ou *introvertido* (I), *sensorial* (S) ou *intuitivo* (N), *pensativo* (T) ou *sentimental* (F), e *jugador* (J) ou *perceptivo* (P).

O modelo de estilos de aprendizagem proposto por Kolb é baseado na abordagem de processamento da informação. Os estilos de aprendizagem definidos neste modelo são os seguintes: *sentir e ver*; *ouvir e pensar*; *fazer e pensar*; e *fazer e sentir*.

Para Felder, os estilos de aprendizagem de um aluno estão relacionados com quatro dimensões de preferências de aprendizagem: *sensorial/intuitivo*, *visual/verbal*, *ativo/reflexivo*, *sequencial/global*.

A estratégia VARK, utiliza um questionário que fornece um perfil de aprendizagem e preferências do aluno que permite avaliar as preferências de aprendizagem, que estão relacionadas com a forma como os alunos querem aceder e selecionar a informação. A estratégia VARK foi selecionada neste trabalho devido à sua flexibilidade e facilidade de implementação.

O modelo de estilos de aprendizagem escolhido foi o modelo Felder-Silverman (1988) e o respetivo questionário *Index of Learning Styles* (Felder e Soloman, 2011) porque de acordo com Graf et al. (2006), o modelo de Felder é o mais apropriado nos estilos de aprendizagem de alunos de engenharia e em ambientes de alta tecnologia (seção 3.2.6.3). Para Felder, (1996), os estilos de aprendizagem, são a expressão dos estilos cognitivos e consistem nas

preferências ou características dominantes da forma como as pessoas recebem e processam informações. A plataforma ADAPT utiliza o questionário ILS de (Felder e Soloman, 2011) para determinar o perfil de aprendizagem do aluno e por esta razão, considera-se que a plataforma segue uma abordagem convergente com as teorias cognitivas, mais precisamente com o Construtivismo (secção 3.1.2).

A taxonomia selecionada para ser utilizada neste projeto é a taxonomia de Bloom revista (secção 3.3), pelo facto de ser uma taxonomia de objetivos educacionais que é aceite e muito utilizada no domínio das engenharias. O objetivo da utilização de taxonomias na plataforma ADAPT é o de classificar os OA em relação ao seu nível de dificuldade e complexidade de modo apresentá-los a cada aluno de acordo com o seu nível cognitivo. Por sua vez, o nível cognitivo de cada aluno é obtido através da realização de testes ao qual serão submetidos pontualmente.

4

Tecnologias e Normas Utilizadas

Este capítulo tem como objetivo apresentar as tecnologias utilizadas no desenvolvimento da plataforma ADAPT. A plataforma constitui um sistema educacional que se adapta ao estilo de aprendizagem e capacidades cognitivas do aluno. Esta adaptação é efetuada com base em tecnologias como a Lógica Difusa apresentada na [secção 4.1](#), o Raciocínio Baseado em Casos descreve-se na [secção 4.2](#), os Algoritmos Genéticos são expostos na [secção 4.3](#), na [secção 4.4](#) explicam-se as tarefas e as técnicas de *data mining* utilizadas, na [secção 4.5](#) descrevem-se as normas LOM e SCORM e por último na [secção 4.6](#) apresenta-se o resumo do capítulo.

4.1 Lógica Difusa

A teoria da lógica difusa é uma generalização da lógica clássica. Na lógica difusa, uma proposição pode variar no seu grau de verdade entre 0 e 1, o que permite que uma afirmação seja em simultâneo parcialmente verdadeira e parcialmente falsa. A Lógica difusa surgiu a partir da teoria dos conjuntos difusos que introduzem o conceito de grau de pertença de um elemento a um conjunto. Este conceito permite a definição de termos linguísticos, tais como, por exemplo, *rápida* ou *lenta*, *pequeno*, *médio* ou *grande*, que por meio de conjuntos de valores, discretos ou contínuos, dão origem à chamada computação com palavras. Conjuntos difusos e lógica difusa foram criados por [Zadeh \(1973\)](#) e [Mamdani, \(1973\)](#) aplicou esta técnica na resolução de problemas, criando para o efeito a conhecida inferência de Mamdani. Neste método, o processo de decisão é baseado em regras de inferência difusa, como por exemplo, “se \tilde{A} então \tilde{N} ”, em que o antecedente e o consequente são termos linguísticos representados por conjuntos difusos ([Mamdani e Assilian, 1975](#)).

Ao identificar alguns problemas com o processo de decisão utilizado no controlador de [Mamdani \(1973\)](#), [Takagi e Sugeno \(1983\)](#), propuseram um método de decisão simplificado, baseado na lógica difusa, onde somente o antecedente das regras é constituído por variáveis difusas. O consequente de cada regra é expresso através de uma função linear com os valores observados nas variáveis de entrada. Este tipo de controlador é referido na literatura como controlador de Takagi-Sugeno ([Takagi e Sugeno, 1983](#)).

Atualmente a lógica difusa tem vindo a ser utilizada com sucesso em vários campos, tais como engenharia de controlo de sistemas, processamento de imagem, engenharia de energia, automação industrial, robótica, eletrónica de consumo e otimização ([Singh et al., 2013](#)).

4.1.1 Função de Pertença

Um conjunto difuso é caracterizado por uma função de pertença, normalmente representada por $\mu(x)$. É através desta função que é determinado o quanto um elemento pertence a um determinado conjunto (Zimmermann, 1996). Assim um conjunto difuso \tilde{A} definido no domínio X é caracterizado por uma função de pertença $\mu_{\tilde{A}}$, a qual mapeia os elementos de X no intervalo $[0,1]$.

$$\mu_{\tilde{A}} : X \rightarrow [0,1] \quad (1)$$

Segundo a definição um conjunto difuso é expresso da seguinte forma:

$$\tilde{A} = \{ (x, \mu(x)) \mid x \in X \} \quad (2)$$

em que \tilde{A} é o conjunto difuso, $\mu_{\tilde{A}}(x)$ é a função de pertença e X é o domínio. De acordo com a aplicação pretendida, existem vários tipos de funções de pertença: Triangular, Trapezoidal, Gaussiana, Sigmoidal, Cauchy entre outras. A Figura 7 mostra o exemplo de uma função triangular. A seguinte função triangular é expressa pela equação (3):

$$\mu_{\text{tri}}(x; a, b, c) = \max(\min((x-a)/(b-a), (c-x)/(c-b)), 0), \text{ para } a < b < c. \quad (3)$$

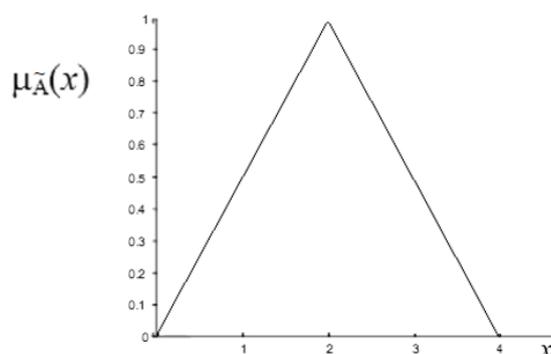


Figura 7 - Gráfico da função Triangular.

A Figura 7 apresenta o gráfico de uma função triangular cujos valores de a , b e c são respetivamente 0, 2, e 4.

4.1.2 Operações com Conjuntos Difusos

Nos conjuntos difusos definem-se operações fundamentais semelhantes às dos conjuntos clássicos, mas em termos de função de pertença. A Figura 8 contém dois conjuntos difusos \tilde{A} e \tilde{I} , definidos em U , com funções de pertença $\mu_{\tilde{A}}$ e $\mu_{\tilde{I}}$:

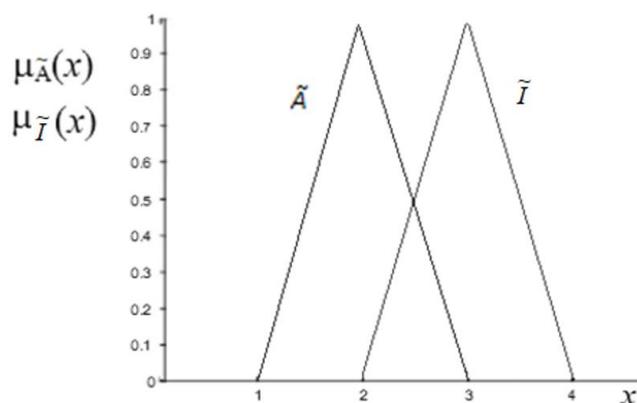


Figura 8 - Conjuntos difusos \tilde{A} e \tilde{I} .

Aos conjuntos difusos \tilde{A} e \tilde{I} podem ser aplicadas as operações de intersecção, reunião e complementação.

A função de pertença da intersecção de \tilde{A} com \tilde{I} é definida ponto a ponto para todos os elementos de $x \in U$ tais que:

$$\mu_{\tilde{A} \cap \tilde{I}}(x) = \min\{\mu_{\tilde{A}}(x), \mu_{\tilde{I}}(x)\} \quad (4)$$

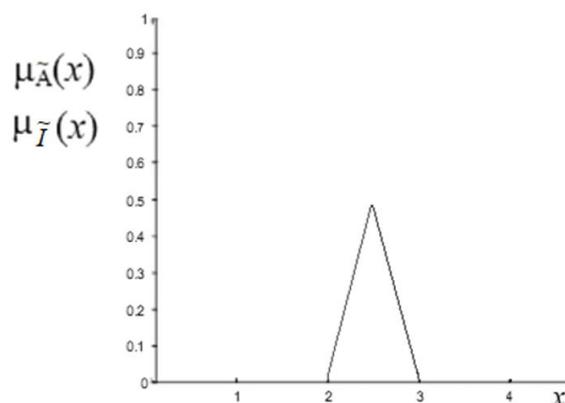


Figura 9 - Intersecção dos conjuntos difusos \tilde{A} e \tilde{I} .

A função de pertença da reunião de \tilde{A} com \tilde{I} é definida ponto a ponto para todos os elementos $x \in U$ tais que:

$$\mu_{\tilde{A} \cup \tilde{I}}(x) = \max\{\mu_{\tilde{A}}(x), \mu_{\tilde{I}}(x)\} \quad (5)$$

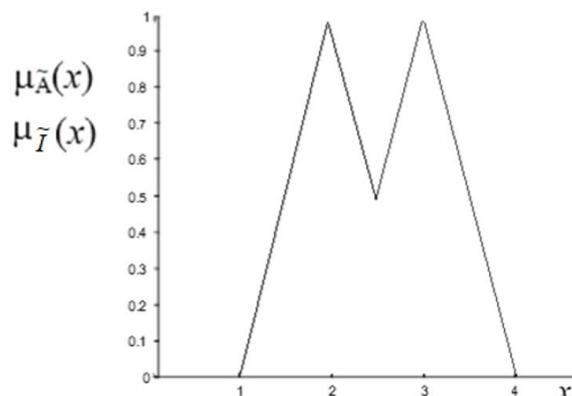


Figura 10 - Reunião dos conjuntos difusos \tilde{A} e \tilde{I} .

A função de pertença do complementar de \tilde{A} é definida ponto a ponto para todos os elementos $x \in U$ tais que:

$$\mu_{\tilde{A}}(x) = 1 - \mu_{\tilde{A}}(x) \quad (6)$$

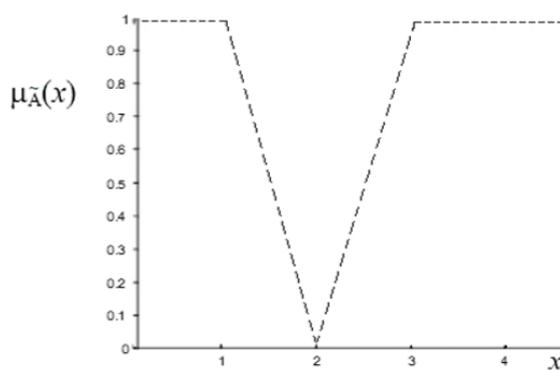


Figura 11 - Complementar do conjunto difuso \tilde{A} .

4.1.3 Variáveis Linguísticas

Uma variável linguística pode ser considerada uma entidade utilizada para representar um conceito de um dado problema. Esta representação é efetuada de forma linguística e conseqüentemente com imprecisão. Ao contrário de uma variável numérica, uma variável linguística admite apenas valores definidos na linguagem difusa. Um exemplo de uma variável linguística pode ser *temperatura*:

a variável difusa temperatura pode assim assumir valores tais como: *Muito Frio*, *Frio*, *Agradável*, *Quente* e *Muito Quente*. Estes valores são denominados de termos linguísticos. Estes termos, quando associados aos respetivos conjuntos difusos, originam funções de pertença tais como as representadas na Figura 12. Nesta figura as variáveis de pertença adotam funções trapezoidais.

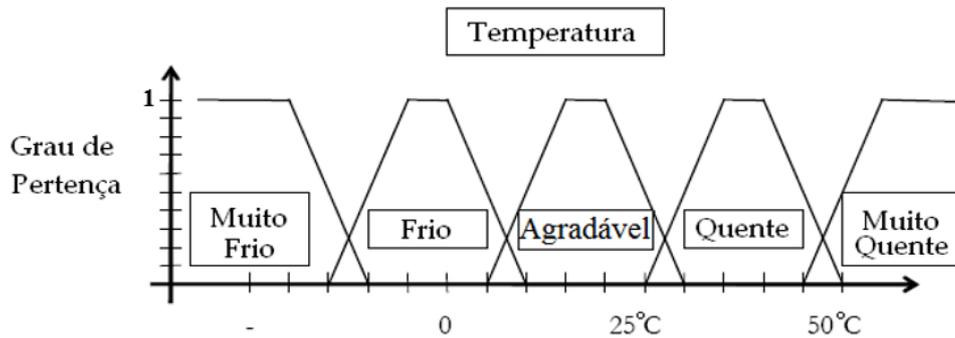


Figura 12 - Exemplo de possíveis termos linguísticos da variável linguística Temperatura e respectivas funções de pertinência.

4.1.4 Regras de Inferência

Na lógica difusa as regras de inferência são expressas como implicações lógicas: **Se** (antecedente) **Então** (consequente).

A criação destas regras pode ser dividida em duas etapas: a primeira consiste em avaliar o antecedente da regra, a segunda em aplicar o resultado ao consequente.

Com base na função de pertinência da Figura 12 poder-se-iam formular as seguintes regras:

1. **Se** *Temperatura é Muito Fria* **Então** aumentar muito a temperatura;
2. **Se** *Temperatura é Fria* **Então** aumentar ligeiramente a temperatura;
3. **Se** *Temperatura é Agradável* **Então** manter a temperatura;
4. **Se** *Temperatura é Quente* **Então** baixar ligeiramente a temperatura;
5. **Se** *Temperatura é Muito Quente* **Então** baixar muito a temperatura;

Para determinar o número de regras necessárias, procede-se à multiplicação do número de termos difusos das variáveis de entrada. Deste modo consegue cobrir-se todas as combinações possíveis resultantes das várias entradas. Por exemplo, num sistema com duas variáveis de entrada, cada uma com 5 termos difusos, existem 25 combinações ($5 \times 5 = 25$) de entrada e consequentemente, 25 regras de inferência. É possível utilizar menos regras, mas não é recomendável fazê-lo, dado que estas representam conhecimento e ao eliminar uma regra está a remover-se conhecimento do sistema, o que pode tornar-se importante se ele for modificado posteriormente.

4.1.5 Raciocínio Difuso

O raciocínio difuso é constituído por um ciclo que contém quatro etapas: fuzificação, inferência, agregação e desfuzificação.

A primeira etapa do raciocínio difuso é a fuzificação. Esta etapa consiste em transformar um valor numérico num termo em linguagem natural.

1. No processo de fuzificação de um determinado valor numérico, são utilizadas as funções de pertença para verificar o quanto esse valor pertence a um ou vários conjuntos difusos, cada um representando diferentes termos linguísticos;
2. De seguida, o processo de inferência consiste em aplicar as entradas fuzificadas nos antecedentes e a partir daí obter o valor de μ para o conseqüente de cada regra. Nesta operação podem figurar operadores (E) e (OU).
3. A etapa de agregação consiste num processo em que podem ter de ser combinados os valores de μ de diferentes regras cujo conseqüente seja o mesmo;
4. A última etapa é a desfuzificação. Nesta etapa um dado conjunto difuso é transformado num valor numérico.

Para exemplificar cada uma das etapas, pode ser considerado um processador de um computador pessoal e o respetivo dissipador de calor. Neste domínio identificam-se três variáveis linguísticas: duas variáveis de entrada - temperatura e carga de dados - e uma variável de saída que representa o número de rotações por minuto do dissipador (RPM).

As etapas do raciocínio difuso para este exemplo são apresentadas nas secções seguintes.

4.1.5.1 Fuzificação

Nesta etapa obtém-se o grau de pertença de cada entrada a cada um dos conjuntos difusos. Para o exemplo em questão, representando por x o valor (numérico) da temperatura e por y o da carga de dados, e utilizando os conjuntos difusos representativos de termos linguísticos e previamente definidos conforme se mostra na Figura 13, obtém-se os seguintes graus de pertença para cada uma das variáveis de entrada:

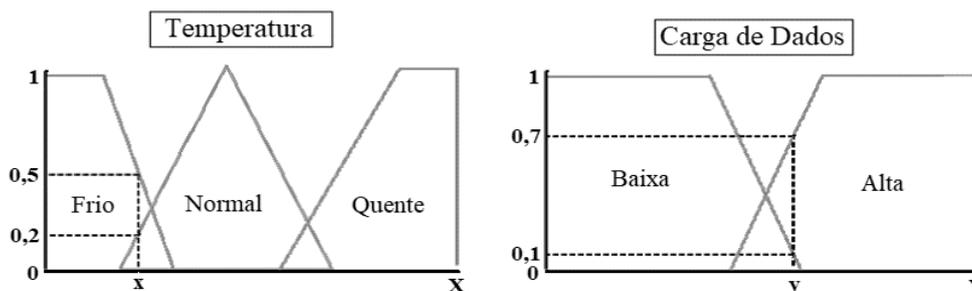


Figura 13 - Fuzzificação das variáveis linguísticas de entrada x e y e respectivas funções de pertinência.

Para a variável temperatura, $\mu_{\text{frio}}(x) = 0,5$ e $\mu_{\text{normal}}(x) = 0,2$. Para a variável carga de dados o $\mu_{\text{baixa}}(y) = 0,1$ e $\mu_{\text{alta}}(y) = 0,7$.

4.1.5.2 Inferência

O processo de inferência consiste em aplicar as entradas “fuzificadas” da etapa anterior nos antecedentes das regras, e a partir daí obter o valor do consequente da regra. Para um antecedente composto, os operadores (E) e (OU) são utilizados da seguinte forma para se obter um único resultado por regra:

- (E): é utilizada a operação de intersecção que considera o menor grau de pertinência (entre dois ou mais valores de μ de vários termos linguísticos que figurem no antecedente da regra);
- (OU): é utilizada a operação de união que considera o maior grau de pertinência.

Depois disto e considerando a inferência de Mamdani, o método de obtenção do valor de μ do consequente de cada regra, consiste em “cortar” o conjunto difuso que define esse consequente, pelo nível do valor de μ do antecedente da regra. Por exemplo, considerem-se as seguintes regras:

1: **SE** (x tem *Temperatura Quente* (0) **OU** y tem *Carga de Dados Baixa* (0.1)) **ENTÃO** (z tem *RPM baixa* (0.1))

2: **SE** (x tem *Temperatura Normal* (0.2) **E** y tem *Carga de Dados Alta* (0.7)) **ENTÃO** (z tem *RPM média* (0.2))

3: **SE** (x tem *Temperatura Baixa* (0.5)) **ENTÃO** (z tem *RPM elevada* (0.5))

Na regra 1, e devido ao operador (OU), o grau de pertinência resultante para z é 0.1, por ser o maior entre $\mu(x)=0$ e $\mu(y)=0.1$. Com a operação (E) na regra 2, o grau de pertinência de z é 0.2, o

menor de entre $\mu(x)=0.7$ e $\mu(y)=0.2$. Na regra 3, como existe apenas uma variável linguística de entrada, o seu valor de $\mu=0.5$ é passado diretamente para a variável linguística de saída, o conseqüente z .

4.1.5.3 Agregação

Nesta etapa são agregadas todas as funções de pertinência dos conseqüentes de cada regra num único conjunto difuso e, caso haja regras terminando com o mesmo termo linguístico, é calculado o máximo dos vários valores de μ dos seus conseqüentes. No presente exemplo, o resultado da aplicação das regras difusas 1, 2 e 3 dá origem aos termos linguísticos da variável linguística RPM e respetivas funções de pertinência, apresentadas na Figura 14.

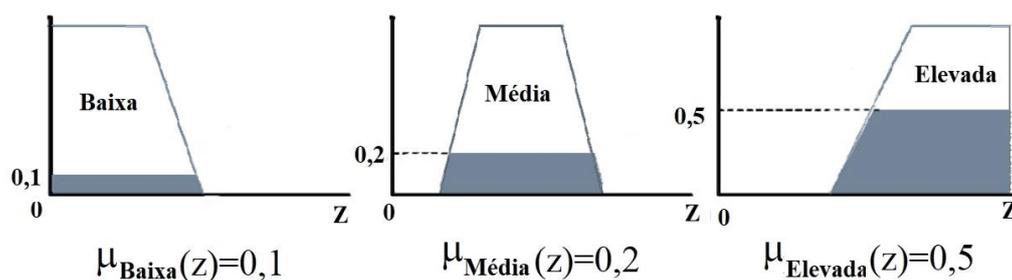


Figura 14 - Termos linguísticos da variável linguística de saída z e respetivas funções de pertinência, produzidos pela aplicação das regras fuzzy 1, 2 e 3.

O conjunto difuso resultante do processo de agregação das regras difusas 1, 2 e 3 é apresentado na Figura 15.

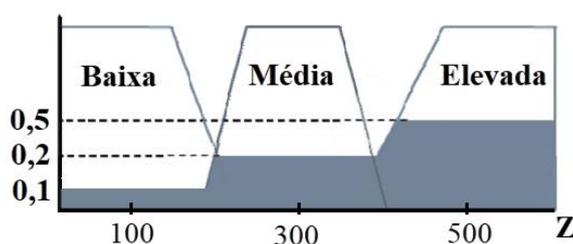


Figura 15 - Conjunto difuso resultante do processo de agregação.

4.1.5.4 Desfuzificação

A última etapa no raciocínio difuso é a “desfuzificação”. Esta etapa é o oposto da “fuzificação” e em vez de transformar um dado quantitativo num termo difuso, é transformado um conjunto difuso num valor. Um dos métodos de desfuzificação mais comuns é conhecido como *Center of Area* (COA) (equação 7).

$$COA = \frac{\int_{u1}^{u2} u \cdot \mu(u) du}{\int_{u1}^{u2} \mu(u) du} \quad (7)$$

Na prática, por simplificação, rapidez e porque os resultados obtidos são geralmente bastante semelhantes, utiliza-se uma aproximação que consiste em multiplicar os pontos médios das diferentes funções de pertinência pelos respectivos valores de μ , e dividir pela soma dos valores de μ . Considerando o conjunto difuso da Figura 15, o resultado numérico obtido desta forma é dado pela equação:

$$COA = \frac{(0,1) \cdot 100 + (0,2) \cdot 300 + (0,5) \cdot 500}{0,1 + 0,2 + 0,5} = 332,5$$

Deste modo, para o exemplo considerado o valor obtido é de 332,5 RPM.

4.2 Raciocínio Baseado em Casos

O Raciocínio Baseado em Casos (RBC) é um paradigma que se baseia na representação de ocorrências passadas. Cada ocorrência (caso) é composta por uma descrição e pela respectiva solução. A resolução de um problema consiste em encontrar um caso anterior semelhante ao atual e apresentar a sua solução diretamente ou adaptada ao novo contexto.

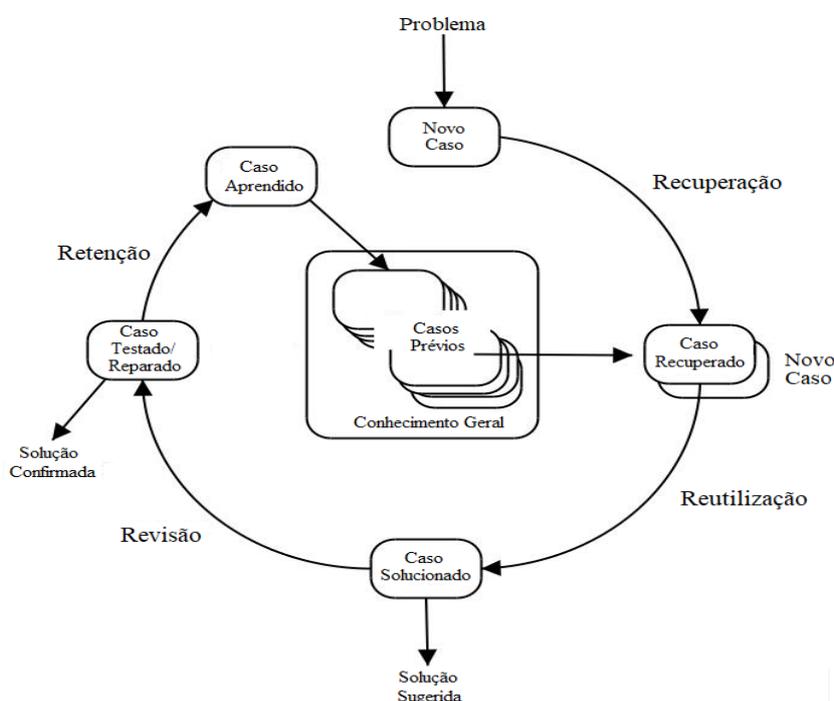


Figura 16 - Ciclo de Aamodt e Plaza (Aamodt e Plaza, 1994).

O funcionamento de um sistema RBC pode ser representado pelo ciclo de quatro fases de (Aamodt e Plaza, 1994) ilustrado na Figura 16 e descrito de seguida:

1. **Recuperação (*retrieve*):** consiste em procurar os casos mais semelhantes ao atual;
2. **Reutilização (*reuse*):** efetua a reutilização da solução que o caso mais semelhante ao atual contém e propõe-na, com vista a solucionar o problema atual. A solução pode ser a mesma ou ter de ser adaptada;
3. **Revisão (*revise*):** verifica se a solução proposta é válida. Se for inválida, é necessário proceder à sua correção;
4. **Retenção (*retain*):** consiste em guardar o conhecimento contido no caso atual se este possuir algo de novo, de diferente.

4.2.1 Fase de Recuperação

Num sistema RBC um problema (novo caso) é resolvido assumindo que problemas semelhantes requerem soluções semelhantes (Leake et. al, 1996). A procura de uma solução para o problema atual consiste em selecionar um conjunto de casos possivelmente relevantes para a solução do problema atual e selecionar o melhor ou melhores entre eles. Neste âmbito, o conceito de Recuperação foi adotado por (Aamodt e Plaza, 1994) para designar a fase de recuperação de um caso armazenado na biblioteca de casos, com um grande grau de semelhança com o novo problema apresentado ao sistema.

Esta etapa pode compreender duas fases: numa primeira fase são selecionados casos com contornos que sejam semelhantes ao do caso atual através de um sistema de indexação. Estes índices permitem uma rápida identificação dos casos cujos atributos sejam relevantes para a resolução do problema atual; na segunda fase é habitualmente utilizada a técnica do vizinho mais próximo (*nearest neighbour*) para determinar a semelhança entre o caso atual e os casos selecionados na etapa anterior.

A semelhança entre casos é calculada com base na distância entre valores de atributos correspondentes em ambos os casos. Para este efeito pode recorrer-se a várias definições de distância, tal como a linear ou a euclidiana, se os atributos forem numéricos.

A distância entre atributos nominais pode ser tabelada, ou estes podem ser previamente codificados, ou simplesmente na base do valor igual ou diferente. Todos os valores são em geral normalizados de alguma forma, de modo a evitar eventual preponderância daqueles que possuem maiores domínios. As distâncias assim obtidas são posteriormente adicionadas, podendo ser ponderadas para cada atributo.

$$D_L(q, s) = \frac{\sum_{i=1}^n d(q_i, s_i) \times w_i}{\sum_{i=1}^n w_i} \quad (8)$$

onde:

n é o número de atributos em cada caso

d é a distância linear entre atributos homólogos

q é o caso atual

s é o caso da biblioteca

w_i é peso relativo ao atributo i

$i \in [1, n]$

A semelhança global entre casos pode em geral ser calculada da seguinte forma:

onde:

$$S = 1 - D$$

D = distância global

S = semelhança global (entre casos)

4.2.2 Fase de Reutilização

O termo Reutilização foi utilizado por (Aamodt e Plaza, 1994) para designar a fase de utilização e eventual adaptação da solução do caso mais semelhante recuperado.

A reutilização consiste em disponibilizar uma cópia da solução já conhecida, eventualmente depois de adaptada por meio de regras, cálculo ou outro qualquer sistema. Schank (1982) considera que existem dois tipos de adaptação:

Transformacional: onde a solução de um caso passado não é aplicada diretamente como uma solução no novo caso, mas existe conhecimento sob a forma de operadores;

Derivacional: este método reutiliza um método, ou regras utilizadas no passado para adaptar uma solução. O caso selecionado contém informações sobre o método utilizado para resolver o problema incluindo uma justificação dos operadores utilizados, objetivos pretendidos, alternativas geradas, caminhos de pesquisa falhados, etc.

4.2.3 Fase de Revisão

O conceito de Revisão foi utilizado por [Aamodt e Plaza, \(1994\)](#) para denominar a fase na qual a solução proposta pela fase de reutilização ou adaptação é avaliada por um professor externo. Consiste em duas tarefas: a primeira avalia a solução gerada na fase anterior (Reutilização). Esta avaliação confirma ou não a solução proposta pelo sistema. Se o caso for bem-sucedido, o sistema aprende com o sucesso e o caso pode ser guardado. A segunda tarefa consiste na reparação da solução utilizando conhecimentos específicos acerca do domínio.

Avaliação: pode ser efetuada de forma manual ou automática. No caso de ser feita manualmente, a solução aceite pode ter sido obtida através do funcionamento num ambiente real ou introduzida por um professor externo que confirma ou não a solução proposta pelo sistema. A avaliação pode ainda ser feita de forma automática através de um programa de simulação que é capaz de gerar a solução correta. Este método é utilizado por exemplo no CHEF, em que uma solução, neste caso uma receita culinária é aplicada a um modelo interno que fornece um *feedback* que permite a sua eventual reparação.

Reparação: a reparação de um caso envolve a deteção dos erros da solução atual e recuperar ou gerar explicações sobre estes. Esta tarefa utiliza as explicações referentes às falhas para modificar a solução de tal forma que as falhas não voltem a ocorrer. No domínio do diagnóstico uma solução pode ser modificada pelo utilizador que pode também comunicar um novo diagnóstico ou escolher outro já existente mas não associado ao contexto atual.

4.2.4 Retenção

A noção de Retenção foi utilizada por ([Aamodt e Plaza, 1994](#)) para denominar a etapa em que o novo problema solucionado pode ser armazenado na base de casos.

Num sistema RBC a base de casos pode ser atualizada independentemente de como o problema foi resolvido.

Se o problema foi resolvido através do uso de um caso anterior, um novo caso pode ser criado ou então o caso antigo pode ser generalizado para resolver o problema atual.

Se o problema foi resolvido por outros métodos, como por exemplo, fazendo perguntas ao utilizador, então um novo caso terá que ser construído.

Em ambas as situações, é necessário tomar uma decisão acerca de como implementar o mecanismo de aprendizagem.

Um caso deve ser guardado na base de conhecimento em várias situações. Por exemplo, na situação do perfil do caso ser diferente do caso existente. Outra situação em que um novo caso deve ser guardado é se a solução gerada na etapa Reutilização não tiver sido diretamente utilizada, ou por ter sofrido modificações manuais ou automáticas na fase de Revisão ou por ter falhado tendo sido indicada uma solução completamente nova. Um caso deve ser também inserido para servir como exemplo positivo em que se considere que a um tipo de caso corresponde a solução X ou então como um exemplo negativo de modo a registrar que uma determinada solução não é válida.

Como exemplo desta situação pode considerar-se o CLAVIER que regista planos de produção que anteriormente falharam, para poder, se necessário, invalidar certas soluções.

4.3 Algoritmos Genéticos

A Computação Evolucionária (CE) é um campo da Inteligência Artificial que envolve problemas de otimização combinatória. A técnica de CE utiliza o progresso iterativo, como forma de melhoramento de uma população (Reis e Machado, 2007).

Os Algoritmos Genéticos (AG) (Goldberg, 1989) constituem um subcampo da CE e são algoritmos heurísticos adaptativos de pesquisa com base nas ideias evolucionárias da genética e da seleção natural. O conceito básico de um AG baseia-se nos princípios da sobrevivência do ser mais apto e foi proposto inicialmente por Charles Darwin. Em 1859, Darwin publicou “A Origem das Espécies”, (Darwin, 1859) onde propôs que os seres humanos, e na verdade todas as espécies, não nasceram como elas são atualmente, mas evoluíram a partir dos seus ancestrais. Ao longo do tempo, as espécies alteraram-se para se adaptar ao meio ambiente e com isso conseguem sobreviver.

Os AG foram criados por John Holland (Holland, 1992) nos anos sessenta na Universidade de Michigan. O AG é um método baseado numa população de “cromossomas” que evolui através de um método inspirado na “seleção natural” em conjunto com operadores genéticos de cruzamento e de mutação.

Com o passar do tempo, ao longo de várias iterações, o número de indivíduos com desempenho acima da média (mais aptos) vai aumentando e consequentemente conjuntos de indivíduos altamente adaptados são combinados a partir de outros indivíduos aptos de modo a encontrar soluções cada vez melhores.

Na resolução de problemas reais, cada cromossoma, indivíduo ou solução, representa uma

potencial solução do problema. A resolução do problema de acordo com a solução codificada por cada cromossoma, leva a desempenhos diferentes. A medida deste desempenho é conseguida através de uma função designada por função de *fitness*. Em algumas situações esta avaliação pode ser executada por um agente humano, dando assim origem ao termo Computação Evolucionária Interativa (CEI).

Os Algoritmos Genéticos têm a recombinação como principal operador de pesquisa e aplicam como operador secundário a mutação com baixas probabilidades. A Tabela 7 contém os termos utilizados no domínio dos algoritmos genéticos.

Tabela 7 - Termos utilizados nos Algoritmos Genéticos (Luke, 2012).

<i>Termo</i>	<i>Definição</i>
<i>Indivíduo</i>	Uma solução candidata do problema
<i>Progenitor e descendente</i>	Um descendente é um indivíduo resultante do cruzamento de duas soluções candidatas (progenitores)
<i>População</i>	Conjunto de indivíduos
<i>Aptidão (fitness)</i>	Qualidade de um indivíduo
<i>Seleção</i>	Escolha de indivíduos com base na sua aptidão
<i>Cruzamento</i>	Escolha e troca de secções entre dois progenitores de modo a produzir dois descendentes
<i>Mutação</i>	Mudança aleatória da descendência criada por cruzamento
<i>Reprodução</i>	Produção de um ou mais descendentes de uma população de progenitores através de um processo iterativo de seleção, cruzamento e mutação
<i>Geração</i>	População produzida em cada iteração
<i>Genótipo ou genoma</i>	Estrutura de dados de um indivíduo
<i>Cromossoma</i>	Um genótipo na forma de um vetor (solução codificada)
<i>Gene</i>	Uma determinada posição num cromossoma
<i>Alelo</i>	Um valor particular de um gene
<i>Locus</i>	Posicionamento de um gene no cromossoma

Durante o funcionamento de um AG as soluções possíveis são consideradas como indivíduos de uma população que irá evoluir a cada nova iteração originando uma nova geração. Inicialmente é definida uma população, normalmente constituída por indivíduos gerados aleatoriamente. De seguida é avaliada toda a população de indivíduos através de uma função que avalia a qualidade do indivíduo denominada de função de aptidão ou *fitness*.

O próximo passo consiste na utilização do operador "seleção" para escolher os melhores indivíduos, ou seja aqueles com mais valor, determinado através da função de aptidão, permitindo desta forma a criação de uma nova geração constituída por um conjunto de novas

soluções. Esta nova geração é obtida através da aplicação de operadores como por exemplo, cruzamento e mutação, que alteram as características dos indivíduos.

A população evolui através de iterações sucessivas até encontrar uma solução que seja aceitável, até que o número máximo de iterações seja atingido ou até que o algoritmo não consiga melhorar a solução já encontrada. A Figura 17 ilustra o exemplo de um Algoritmo Genético.

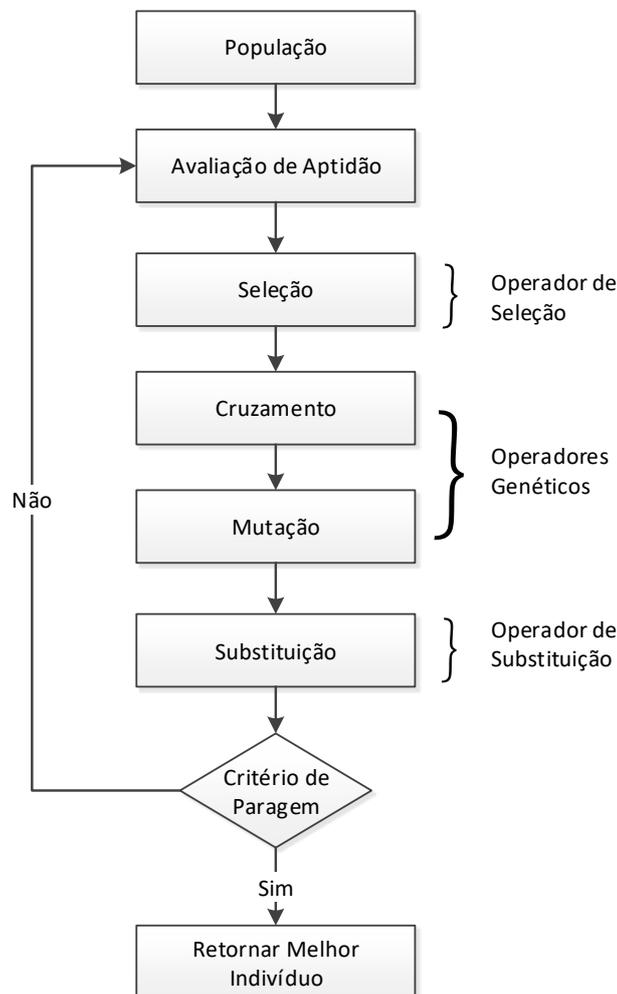


Figura 17 - Algoritmo Genético.

Os principais conceitos inerentes à execução do algoritmo apresentado na Figura 17 são descritos de seguida em maior detalhe.

- **População:** é caracterizada pelo conjunto de indivíduos que são utilizados como soluções possíveis que permitem resolver o problema e serão utilizados para criar novos conjuntos de indivíduos em cada iteração. Normalmente é criada de forma aleatória, mas quando possível, o conhecimento do domínio pode ser utilizado para definir a população inicial. O número de elementos da população pode ter influência no desempenho e na eficiência de

um AG. Uma população pequena corre o risco de perder a diversidade necessária para convergir para uma boa solução, uma vez que fornece uma pequena cobertura do espaço de pesquisa do problema. Por outro lado, se a população tiver uma dimensão elevada, o algoritmo pode perder parte da sua eficiência pela demora em avaliar a função de aptidão de todo o conjunto de indivíduos em cada iteração.

- **Avaliação da Aptidão (*Fitness*):** é efetuada através de uma função que calcula o valor de aptidão de cada indivíduo da população. Esta função efetua a medição da qualidade de uma solução e desta forma avaliar o quão próximo um indivíduo está da solução pretendida. É importante que esta função possua a capacidade de diferenciar as boas soluções das soluções menos promissoras. Se a avaliação possuir pouca precisão, existe a possibilidade de excluir soluções de boa qualidade durante a execução do algoritmo.
- **Seleção:** consiste em selecionar, em cada geração, os indivíduos sobre os quais são aplicados os operadores genéticos. Existem diversas formas de seleção, sendo as mais populares o método de seleção por roleta e o método de seleção por torneio. No método de seleção por roleta, cada indivíduo da população é representado numa roleta proporcionalmente ao seu índice de aptidão. Deste modo, aos indivíduos com uma elevada aptidão, é-lhes atribuída uma porção maior da roleta. A Figura 18 apresenta uma roleta com 5 indivíduos onde se verifica que o indivíduo S2 apresenta maior aptidão, dado ocupar um espaço maior. O contrário acontece com o indivíduo S3. Deste modo, a probabilidade do indivíduo S2 pertencer à população da geração seguinte é superior à do indivíduo S3.

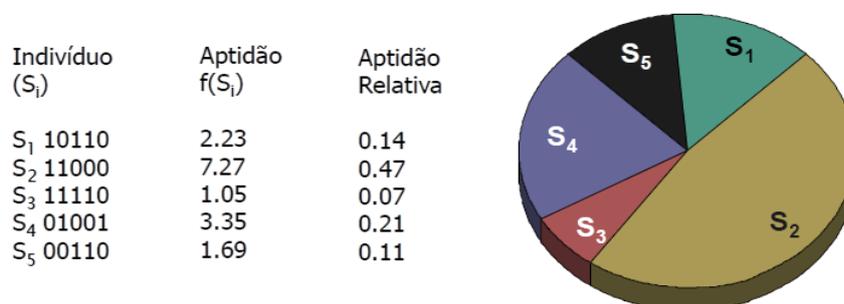


Figura 18 - Método da roleta baseado em aptidão relativa.

O exemplo de um algoritmo seleção por roleta é apresentado na Figura 19:

Início

T = soma dos valores de aptidão de todos os indivíduos da população

Repetir N vezes para selecionar n indivíduos

r = valor aleatório entre 0 e T

```

    Percorrer sequencialmente os indivíduos da população, acumulando
    em  $S$  o valor de aptidão dos indivíduos já percorridos
    Se  $S \geq r$  então
        Selecionar o indivíduo atual
    Fim Se
  Fim Repetir
Fim

```

Figura 19 - Algoritmo do método de seleção por roleta (Mitchell, 1997).

Outro método existente é a seleção por Torneio onde são escolhidos aleatoriamente K indivíduos da população sendo selecionado o que tiver melhor aptidão. Para escolher N indivíduos, o processo é repetido N vezes. O parâmetro K representa a dimensão do torneio e normalmente possui valores entre 2 e 5. Quanto maior o valor de K maior será a pressão evolutiva pois o indivíduo selecionado terá que ser melhor do que um maior conjunto de indivíduos. Este método é o mais utilizado, pois oferece a vantagem de não exigir que a comparação seja feita entre todos os indivíduos da população (Banzhaf, 1998). Um exemplo da implementação deste algoritmo é ilustrado na Figura 20.

```

Início
   $k = 2$ 
  Repetir  $N$  vezes
    Selecionar  $K$  indivíduos da população aleatoriamente
    Selecionar o indivíduo com maior aptidão
  Fim Repetir
Fim

```

Figura 20 - Algoritmo do método de seleção por Torneio.

- **Operadores Genéticos:** têm como objetivo transformar a população através de gerações sucessivas, estendendo a procura de soluções até encontrar um resultado satisfatório. Os operadores genéticos são necessários para que a população se diversifique e mantenha características de adaptação adquiridas pelas gerações anteriores. Dos operadores mais utilizados, inclui-se o operador de cruzamento e o operador de seleção

O operador de cruzamento é responsável pela recombinação de características dos progenitores durante o processo de reprodução, permitindo que as próximas gerações herdem essas características. Este operador é considerado o operador genético predominante e por isso é aplicado com altas taxas de probabilidade (taxa de *crossover*).

Os tipos de cruzamento num ponto e em dois pontos, apresentados na Figura 21 são dos mais utilizados.

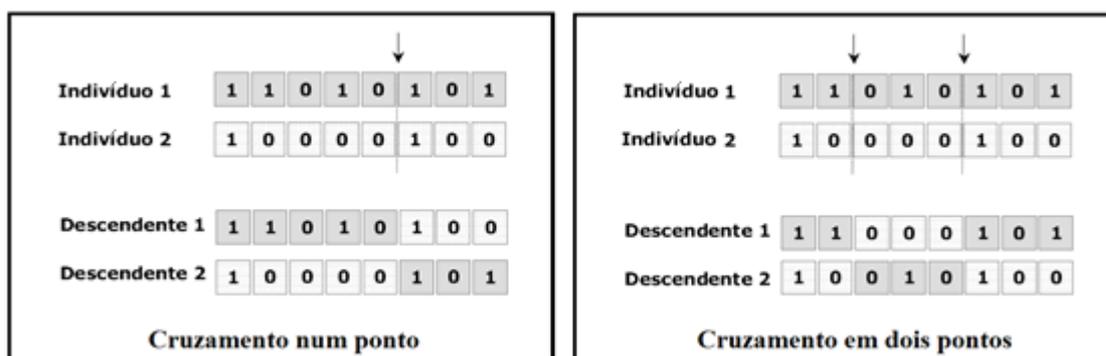


Figura 21 - Exemplos de operadores genéticos: Cruzamento num ponto e em dois pontos.

Através dos operadores de cruzamento são criados novos indivíduos combinando características de dois indivíduos progenitores. Neste processo parte das características de um indivíduo são trocadas por uma parte equivalente do outro. O resultado desta operação consiste em criar indivíduos descendentes que potencialmente combinam as melhores características da população, dado que os indivíduos progenitores foram selecionados com base no seu desempenho.

O operador de mutação é utilizado para introduzir diversidade genética na população, modificando aleatoriamente uma ou mais características, fornecendo os meios para a introdução de novos elementos na população. Este operador modifica aleatoriamente uma característica do indivíduo sobre o qual é aplicado (Figura 22).

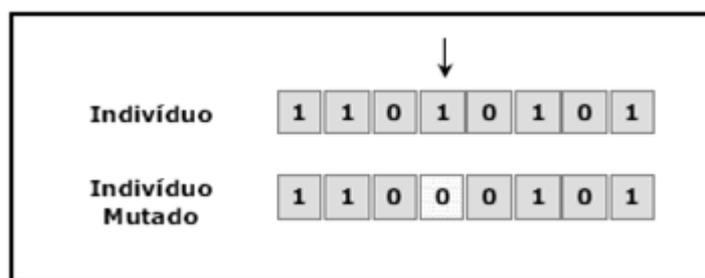


Figura 22 - Exemplo do operador genético: Mutação.

Desta forma, a mutação assegura que a probabilidade de se chegar a qualquer ponto do espaço de pesquisa nunca seja zero, além de poder contornar mínimos locais, uma vez que este mecanismo permite alterar ligeiramente a direção da pesquisa. O operador de mutação é aplicado aos indivíduos com uma probabilidade dada pela taxa de mutação. Normalmente é utilizada uma taxa de mutação pequena, pelo fato de ser um operador genético secundário.

- **Substituição:** esta operação consiste em efetuar a substituição da população ou parte dela, na passagem de uma geração para a geração seguinte, sendo os indivíduos da população descartados para abrir espaço para os descendentes. Este processo pode ser efetuado através da substituição total da população ou então através da substituição de apenas algumas soluções, normalmente as que se considerem ter pior qualidade.

4.4 *Data Mining*

Devido aos avanços contínuos na área das tecnologias da informação a quantidade de dados que têm vindo a ser gerados e armazenados tem vindo a crescer de forma exponencial. Nestes dados existe conhecimento armazenado, que pode ser extraído, permitindo identificar padrões e tendências.

Neste contexto, o *data mining* aparece como uma solução para o problema da obtenção de informação a partir de grandes volumes de dados, colocando à disposição dos analistas várias técnicas que lhes permitem extrair dos dados padrões de comportamento relevantes para o negócio ou área em questão (Kantardzic, 2003).

O *data mining* pode ser considerado como a aplicação de métodos e técnicas em grandes Bases de Dados, para encontrar tendências ou padrões com o intuito de descobrir conhecimento (Santos e Azevedo, 2005).

As técnicas de *data mining* quando estendidas a outras áreas originam formas alternativas de obtenção de conhecimento como é o caso de *text mining* ou *link mining*.

O *text mining*, também conhecido como *text data mining* (Hearst, 1997) refere-se ao processo de extração de padrões e conhecimento a partir de documentos de texto não estruturados. É um campo multidisciplinar, que abrange várias áreas tais como recuperação de informação, análise de texto, extração de informação, agrupamento, categorização e visualização, entre outros.

Técnicas de *data mining* aplicadas a estruturas, como é o caso dos grafos, originaram técnicas denominadas por *link mining*. Os grafos possuem vértices que representam objetos e ligações (*links*) entre esses vértices que representam relações entre esses objetos.

A interpretação mais comum do conceito de *link* é o *hiperlink* que consiste numa forma de interligar dois documentos na *World Wide Web* ativando um elemento incorporado no documento de origem e que permite aceder a outro documento.

Os nós de um grafo podem ser do mesmo tipo, denominados de homogéneos, ou de tipos diferentes, denominados de heterogéneos. A *World Wide Web* pode ser considerada uma rede homogénea dado que todos os nós são URL, enquanto uma rede de *links* para citações

bibliográficas forma uma rede heterogénea dado que os nós podem ser papéis, livros ou artigos de revistas, entre outros (Getoor, 2005). As técnicas de *link mining* possuem várias utilizações como por exemplo análise de dados e otimização de motores de pesquisa.

Uma realidade emergente é a utilização de técnicas de *data mining* na educação, onde o principal objetivo é o desenvolvimento de métodos que permitam explorar dados obtidos a partir de aplicações educacionais, e assim compreender os alunos e a forma como estes aprendem. O *data mining* vocacionado para o ensino, tem como objetivo oferecer aos alunos recomendações durante a sua interação com uma aplicação e deste modo melhorar o seu processo de aprendizagem. As principais utilizações desta técnica são: adaptação do curso segundo o progresso do aluno, ajudar os alunos oferecendo-lhes sugestões, recomendar caminhos personalizados a seguir, entre outros.

As técnicas de *data mining* podem também ser utilizadas para monitorizar e avaliar o processo de aprendizagem dos alunos que utilizam um STI. Num ambiente de ensino tradicional, a observação do aluno é uma das técnicas informais mais utilizadas na deteção de falhas no processo de aprendizagem. Consequentemente, a interação entre professor e aluno constitui a principal fonte de informações deste método. Esta realidade constitui um grande obstáculo ao processo de aprendizagem quando se utiliza um STI, uma vez que na maioria do tempo o contacto com o aluno é realizado por intermédio do computador, limitando-se muitas das vezes à troca de mensagens escritas. Apesar deste obstáculo, a tecnologia tornou possível determinar, à distância, algumas características do aluno e analisá-las de uma maneira análoga ao comportamento de um aluno a frequentar um curso presencial. Neste contexto, a aplicação de *data mining* poderá ser útil na implementação de STI que permitam um maior acompanhamento dos alunos, (Silva et al., 2001).

O *data mining* é uma área multidisciplinar onde convergem diferentes paradigmas de computação podendo ser dividido em várias tarefas que utilizam técnicas para atingir os seus objetivos. Na [secção 4.4.1](#) são apresentadas as tarefas de *data mining* e na [secção 4.4.2](#) são apresentadas as técnicas que foram utilizadas.

4.4.1 Tarefas de *Data Mining*

A utilização de técnicas de *data mining* começa pela definição de quais os resultados que se pretendem obter. Uma vez definidos os objetivos pode escolher-se qual ou quais os

algoritmos a utilizar para a aquisição do conhecimento que se procura. Nesta secção são descritas as tarefas de Segmentação (*Clustering*), Classificação e Sumarização.

4.4.1.1 Segmentação (*Clustering*)

As tarefas de segmentação também conhecidas como *clustering*, são processos que consistem na divisão de uma população heterogénea em vários subgrupos ou *clusters* mais homogéneos (Klosgen e Zytkow, 1996). Um *cluster* é um conjunto de exemplos com características semelhantes entre si e diferentes dos restantes conjuntos.

As tarefas de *clustering* procuram semelhanças e diferenças num conjunto de dados e agrupam os dados semelhantes em segmentos ou *clusters*, de acordo com algum critério ou métrica. Os segmentos obtidos nesta técnica de aprendizagem correspondem a padrões escondidos numa grande quantidade de dados (Berkhin, 2002).

Nas tarefas de segmentação não é necessário definir os conjuntos nem os atributos que devem ser utilizados para segmentar o conjunto de dados. No processo de *clustering* o algoritmo parte de dados não catalogados, ou seja, não utiliza dados de treino previamente classificados (Xu e Wunsch, 2005). Por esta razão, as técnicas de *clustering* constituem um método não supervisionado.

A segmentação é útil em situações como: tomadas de decisão, situações de *machine learning* e análise e exploração de padrões em conjunto de dados com conteúdo desconhecido (Jain, et al., 1999).

4.4.1.2 Classificação

As tarefas de classificação são consideradas métodos de aprendizagem supervisionada onde é construído um modelo (classificador) com recurso a um conjunto de dados de treino (*training set*) que possui exemplos previamente classificados e que permitem classificar novos exemplos que façam parte de um outro conjunto de dados.

A aprendizagem de um classificador ocorre na fase de treino. Os dados de treino são o conjunto de dados que servem de exemplo sendo utilizados no processo de aprendizagem, em que é necessário proceder ao ajuste de vários parâmetros (Ripley, 1996).

Um classificador pode ser um conjunto de regras, uma árvore de decisão ou uma rede neuronal. Ao aplicar o classificador obtido em novos exemplos, está-se a classificar e a prever qual a classe a que corresponde um novo exemplo.

Durante o processo de classificação podem ocorrer falhas que têm como consequência a não atribuição da classe correta a todos os exemplos. Este problema, faz com que seja importante estudar o erro do classificador que determina a probabilidade com que um dado exemplo é mal classificado.

Para determinar a quantidade de erros e assim avaliar a confiabilidade nos modelos gerados são utilizados vários indicadores:

- Taxa de erro = $n.^{\circ}$ de erros / total;
- Validação Cruzada: Divide os dados (treino/teste) em n partições e calcula o erro médio;
- Matriz de Confusão: Separa os diversos tipos de erro: Falso Positivo (o classificador prevê que é de uma classe e não é) e Falso Negativo (o classificador não deteta que o exemplo é de uma determinada classe).

Um método comum de avaliação consiste em dividir o conjunto de dados em dois conjuntos: um conjunto de dados de treino (*training set*) para treinar o classificador e um conjunto de dados de teste (*test set*), utilizado para estimar a taxa de erro. O conjunto de dados de teste é independente do conjunto de dados de treino, mas segue a mesma distribuição de probabilidade. Se um modelo for simultaneamente ajustado ao conjunto de dados de treino e ao conjunto de dados de teste, significa que o sobre ajuste (*overfit*) foi mínimo. Um melhor ajuste do conjunto de dados de treino em relação ao conjunto de dados de teste geralmente significa um *overfit* elevado. Quando um classificador induzido sobre ajusta o conjunto de treino, significa que o modelo fica mais adaptado às instâncias utilizadas na sua indução do que aquelas que vão ser classificadas futuramente. Esta taxa de erro é conhecida como erro aparente também conhecido como erro de generalização. Deste modo, um classificador deve ser avaliado tendo em conta o seu desempenho (capacidade de generalização) naqueles exemplos que não foram utilizados na sua construção.

A Figura 23 ilustra um conjunto de dados de treino e um conjunto de dados de teste da mesma população representados através de pontos azuis. Dois modelos preditivos são ajustados ao conjunto de dados de treino. Ambos os modelos ajustados são ilustrados nos conjuntos de treino e teste. No conjunto de treino, o ajuste representado pela curva laranja possui um Erro Quadrático Médio (EQM) = 4 enquanto o ajuste representado pela curva verde possui um EQM = 9. No conjunto de dados de teste, o ajuste representado pela curva laranja possui um EQM = 15 enquanto o ajuste representado pela curva verde possui um EQM = 13. O modelo preditivo representado pela curva laranja possui um *overfit* considerável nos dados de treino, uma vez

que o seu EQM aumenta aproximadamente quatro vezes ao comparar-se o conjunto de teste com o conjunto de treino. O modelo preditivo representado pela curva verde possui um *overfit* consideravelmente menor nos dados de treino, dado o seu EQM possuir um aumento duas vezes menor.

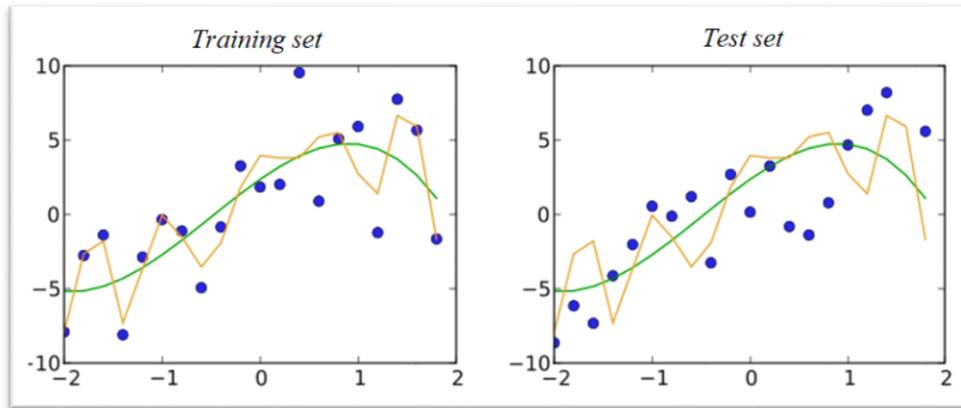


Figura 23 - Exemplo de conjunto de dados de treino (*training set*) e conjunto de dados de teste (*test set*) (Training, test, and validation sets, 2018).

Existem vários tipos de algoritmos de classificação, sendo alguns dos mais utilizados, as Árvores de Decisão, *Naive Bayes*, Regras, Redes Neurais Artificiais (RNA) e Máquinas de Suporte Vetorial (*Support Vector Machines - SVM*).

Podem ser considerados como exemplos de tarefas de classificação: a classificação de um pedido de crédito como sendo de baixo, médio e alto risco ou tarefas de diagnóstico.

4.4.1.3 Sumarização

Segundo (Fayyad et al., 1996), as tarefas de sumarização envolvem métodos para encontrar uma descrição compacta para um subconjunto de dados. A Sumarização é constituída por duas etapas: caracterização de dados e discriminação dos dados.

- A Caracterização de dados, consiste em efetuar uma sumarização das propriedades gerais dos objetos existentes numa determinada classe, e desta forma produzir regras de caracterização. Os dados relevantes para a criação de uma classe são normalmente disponibilizados através de uma consulta a uma base de dados e processados por um módulo de sumarização que efetua a extração dos dados em diferentes níveis de abstração. Como possível exemplo, pode considerar-se a identificação de clientes que regularmente compram mais de 20 livros por ano numa livraria.

- A Discriminação de dados produz regras de discriminação e pode ser definida como uma comparação de propriedades gerais de objetos entre duas classes. Por exemplo, pode comparar-se as características gerais de consumidores que compraram mais de 20 livros no ano passado com aqueles cujas compras não ultrapassaram as 5 unidades. As técnicas utilizadas no processo de discriminação são semelhantes às técnicas de caracterização com a diferença de que os resultados obtidos na discriminação incluem medidas comparativas.

Segundo (Han e Kamper, 2000), as técnicas de *data mining* podem também ser aplicadas a tarefas como análise de exceções (deteção de *outliers*), ou seja, dados que não podem ser agrupados numa classe predefinida, e também a análises de evolução, que dizem respeito ao estudo de padrões sequenciais.

A análise de exceções lida com dados que não podem ser agrupados numa classe predefinida e efetua uma análise de dados que podem ser descartados em certas situações, permitindo aumentar a eficiência, como podem também revelar informações importantes sobre um dado domínio. Esta técnica é utilizada em eventos que ocorrem com pouca frequência como por exemplo, a deteção de fraudes onde é possível detetar a utilização indevida de cartões de crédito ao descobrir clientes que efetuaram compras com um valor muito elevado, fora de seu padrão habitual de gastos.

A análise de evolução dedica-se ao estudo de dados que se alteram ao longo do tempo e efetua a representação de tendências utilizando processos de caracterização, comparação, classificação ou agrupamento de dados relacionados entre si. Como exemplo, pode considerar-se a evolução do estoque em empresas que necessitem decidir regularmente sobre a sua ampliação em função da regularidade das vendas, e assim melhorar a distribuição dos seus produtos.

4.4.2 Técnicas de *Data Mining*

Uma vez definidas as tarefas que se devem realizar no processo de *data mining*, é necessário escolher quais as técnicas que devem ser utilizadas, que sejam mais propícias à obtenção dos melhores resultados.

Árvores de Decisão, Regras de Associação, Redes Neurais Artificiais, e *K-means* são exemplos de algumas técnicas de *data mining* e apresentam-se nesta secção.

4.4.2.1 Árvores de Decisão

Uma árvore de decisão é um fluxograma semelhante à estrutura de uma árvore, onde cada nó representa um teste aplicado a um atributo, cada ramo representa o resultado desse teste e cada folha representa uma classe. As árvores de decisão são das técnicas de *data mining* mais utilizadas. Para a sua enorme popularidade contribui a sua simplicidade de implementação, e principalmente a facilidade de compreensão do resultado final (Quinlan, 1986). As árvores de decisão dividem-se em dois tipos, dependendo do tipo de *output* esperado: Árvores de Classificação e Árvores de Regressão.

Nas árvores de classificação o objetivo da previsão é determinar a classe à qual a observação pertence; nas árvores de regressão o *output* é um valor numérico. O modelo de árvores de decisão é construído, a partir de um *dataset* de treino, o que faz deste um método de aprendizagem supervisionada. Na Figura 24 é ilustrado um exemplo de uma árvore de decisão. Neste exemplo é modelada a decisão de ligar ou não ligar um sistema de rega mediante dois atributos: temperatura e humidade. As classes possíveis são constituídas pelo conjunto {Ligar, Não Ligar} e as variáveis ou atributos são caracterizadas pelo conjunto {Temperatura, Humidade}. O processo de classificação, ou neste caso de decisão, começa pela raiz, ou seja, pelo primeiro nó da árvore.

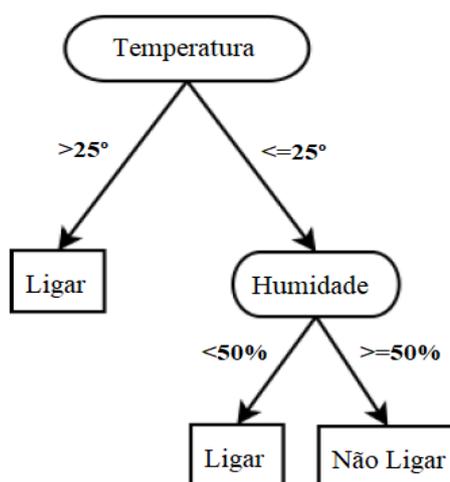


Figura 24 - Exemplo de uma árvore de decisão.

No primeiro nó é analisado o valor da temperatura, sendo possível ligar dois *outputs*: temperatura $>25^{\circ}\text{C}$ ou temperatura $\leq 25^{\circ}\text{C}$. No caso da temperatura ser $>25^{\circ}\text{C}$ o caso em análise é imediatamente classificado com ligar; caso a temperatura seja $\leq 25^{\circ}\text{C}$ o processo de classificação avança para o ramo seguinte da árvore onde é analisado o valor da variável

humidade. Neste caso é testada a condição de humidade $\geq 50\%$ ou $< 50\%$, onde é feita a classificação ligar ou não ligar.

As árvores de decisão apresentam algumas vantagens em relação a outros métodos de classificação (Lewis, 2000). Apresentam uma elevada simplicidade na sua compreensão e na análise e interpretação dos seus resultados. Um resultado observado num modelo, é facilmente explicado e comprovado por operações lógicas, ao contrário de outras técnicas, como as redes neuronais, nas quais é difícil compreender os resultados obtidos.

As árvores de decisão aplicam-se tanto a dados numéricos como a dados simbólicos, ao contrário de outras técnicas que apenas conseguem lidar com alguns tipos de dados como por exemplo, as redes neuronais que apenas podem usar variáveis numéricas.

Como qualquer outro classificador, as árvores de decisão apresentam também algumas desvantagens: os algoritmos utilizados nas árvores de decisão, atuam ao nível do nó a ser processado, ou seja, tomam a decisão ótima para o nó em questão, não havendo garantia que a árvore resultante seja a ótima (Murthy, 1998); outra desvantagem é o facto de nos modelos com dados que incluam variáveis com diferentes níveis de detalhe, existir a tendência de colocar um maior ênfase nas variáveis com maior nível de detalhe (Deng et al., 2011).

4.4.2.2 Regras de Associação

O conceito de regras de associação foi criado por Agrawal (1993) com o intuito de descobrir padrões de comportamento nas transações de um supermercado. As regras de associação permitem criar relações entre itens de um conjunto de dados tal como, por exemplo:

$$\{\text{cerveja, batatas}\} \Rightarrow \{\text{fraldas}\}$$

A regra indica que um cliente que compre cerveja e batatas, tem tendência a comprar também fraldas. O valor de uma regra pode ser obtido por métricas como o suporte, a confiança ou o *lift* que quantificam a qualidade e utilidade da regra criada.

O suporte $\text{sup}(X)$ de um conjunto X é definido como a proporção de transações da base de dados que contém este conjunto.

A confiança de uma regra é definida pela equação:

$$\text{Conf}(X \Rightarrow Y) = \frac{\text{sup}(XUY)}{\text{sup}(X)} \quad (9)$$

O *lift* é uma medida do desempenho de um modelo utilizado na classificação de casos como tendo uma melhor resposta em relação à população total, medida em relação a um outro modelo. Um modelo é considerado bom se a resposta for melhor do que a média da população total. O *lift* é definido pela equação:

$$\text{Lift}(X \Rightarrow Y) = \frac{\text{sup}(XUY)}{\text{sup}(Y) \times \text{sup}(X)} \quad (10)$$

Por exemplo, se uma regra possuir um suporte de 80% e uma confiança de 60%, significa que 80% da totalidade dos clientes compraram cerveja, batatas e fraldas simultaneamente; os 60% da confiança significam que estes casos são 60% daqueles em que os clientes apenas compraram cerveja e batatas, mas não fraldas.

A nível de representação de dados para extração de regras de associação, utiliza-se um identificador da transação seguido dos respetivos itens. Deste modo, as transações registadas são armazenadas em formato binário (item presente ou ausente) em que cada uma é identificada por uma chave. A Tabela 8 apresenta um exemplo em que são utilizadas regras de associação para descrever o registo da compra de produtos num supermercado. Os atributos são apresentados em colunas (Cerveja, Batatas e Fraldas) e podem aferir o valor “1” ou “0” consoante estes figurem ou não na transação.

Tabela 8 - Exemplo de Regras de Associação.

TID	Cerveja	Batatas	Fraldas
1	1	1	0
2	0	1	1
3	0	0	0
4	1	1	1
5	0	1	0

No caso da regra {Cerveja, Batatas} => {Fraldas} possui uma confiança:

$$\text{Conf}(X \Rightarrow Y) = \frac{\text{sup}(XUY)}{\text{sup}(X)} = \frac{\frac{1}{5}}{\frac{2}{5}} = \frac{0,2}{0,4} = 0,5$$

o que significa que para 50% das transações que contêm cerveja e batatas, a regra está correta.

O *lift* para a regra {Cerveja, Batatas} => {Fraldas} é dado por:

$$Lift(X \Rightarrow Y) = \frac{\sup(XUY)}{\sup(Y) \times \sup(X)} = \frac{\frac{1}{5}}{\frac{2}{5} \times \frac{2}{5}} = \frac{0,2}{0,4 \times 0,4} = 1,25$$

Se uma regra possuir um $lift = 1$, significa que a probabilidade de ocorrência do antecedente e do consequente são independentes entre si. Quando duas ocorrências são independentes entre si, não pode ser estabelecida nenhuma regra envolvendo estas duas ocorrências. No caso de $lift > 1$, como é o caso, pode determinar-se o grau em que as duas ocorrências são dependentes uma da outra tornando-as úteis para prever o consequente em conjuntos de dados futuros.

4.4.2.3 Redes Neurais Artificiais

O perceptron foi proposto por Rosenblatt (1958) para efetuar o reconhecimento de letras maiúsculas do alfabeto e consiste numa estrutura que procura simular a forma, o comportamento e as funções de um neurónio biológico (Figura 25). As dendrites foram substituídas por entradas, cujas ligações com o corpo celular são realizadas através de pesos que simulam as sinapses. Os estímulos captados pelas entradas são processados pela *função de soma* e o limiar de disparo do neurónio biológico foi substituído pela *função de ativação*.

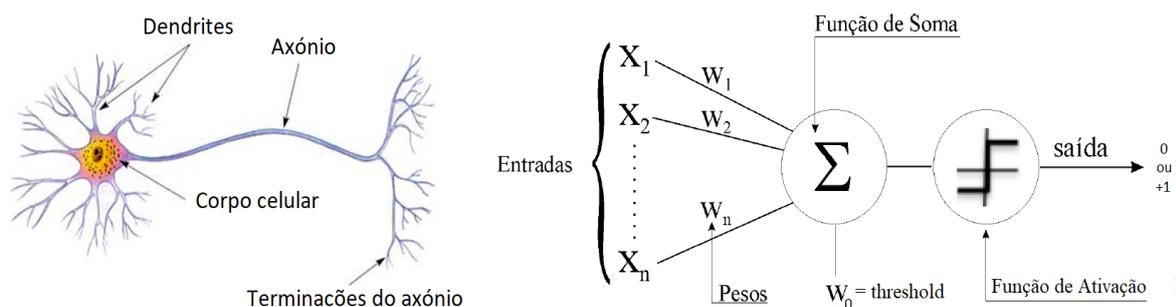


Figura 25 - Neurónio natural e perceptron (adaptado de Tafner et al., 1996).

Assim como o neurónio biológico, o perceptron possui um ou mais sinais de entrada e apenas um sinal de saída. Os pesos são atributos representados pela letra w (*weight*) e representam o grau de importância de uma determinada entrada. O valor do peso é alterado em função da intensidade do sinal de entrada. Matematicamente, os pesos são vistos como um vetor de valores $[w_1, w_2, \dots, w_n]$. O sinal de excitação do perceptron é resultante do somatório do produto dos sinais de entrada, representados por um vetor $[x_1, x_2, \dots, x_n]$, pelo vetor de pesos do perceptron (equação 11).

$$S = \sum_{k=0}^n w_i \times x_i \quad (11)$$

De seguida é verificado se o valor resultante da soma entre o produto dos sinais de entrada pelos respetivos pesos atingiu ou não um valor predeterminado, denominado de limiar (*threshold*). Se o valor atingiu o limiar, o mesmo é passado através da saída. Caso contrário, o sinal não será transferido. O *threshold* pode ser representado através de várias funções ilustradas na Figura 26.

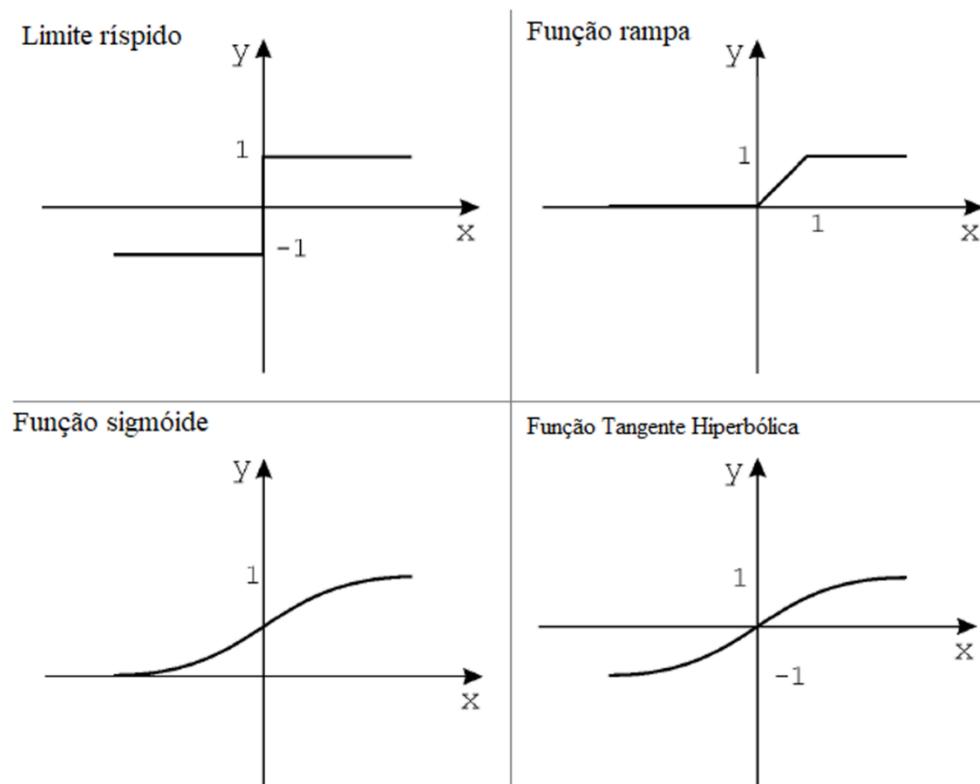


Figura 26 - Funções de ativação (Kovács, 1996).

Um perceptrão é caracterizado por uma unidade linear e ao calcular a combinação linear das entradas, fica limitado à criação de uma reta ao longo de um hiper plano, fazendo com que apenas consiga classificar padrões em apenas duas classes como por exemplo funções: AND, OR ou NOT. A solução para ultrapassar este problema consistiu em expandir a camada de saída do perceptrão para incluir mais do que um neurónio e desta forma poder classificar-se mais de duas classes. Deste modo, a partir do modelo de um perceptrão pode construir-se uma rede neuronal artificial (RNA) em que as entradas, simulam uma área de captação de estímulos, podendo ser conectadas a outros neurónios, originando uma série de saídas, onde cada neurónio representa uma saída. Em comparação com o sistema biológico, estas conexões representam o contacto das dendrites com outros neurónios, onde são realizadas as sinapses.

Segundo (Haykin, 1999) uma rede neuronal pode ser definida como:

“... um processador paralelamente distribuído constituído por unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para uso. Assemelha-se ao cérebro em dois aspetos:

1. O conhecimento é adquirido pela rede através de um processo de aprendizagem;
2. Forças de conexão entre neurónios, denominados de pesos sinápticos, são utilizados para armazenar o conhecimento adquirido”.

A arquitetura de uma RNA é constituída por uma série de nós. Existem nós de entrada que recebem sinais de entrada (*input layer*) e nós de saída (*output layer*) que fornecem os sinais de saída. Podem existir um número ilimitado de camadas intermédias (*hidden layers*).

Uma RNA pode ter uma ou várias camadas. As redes que possuem uma única camada são indicadas para a solução de problemas linearmente separáveis. As redes multicamadas possuem mais de uma camada entre as camadas de entrada e saída. Um exemplo de uma rede com várias camadas é a *Multi-Layer Perceptron* (MLP) apresentada na Figura 27.

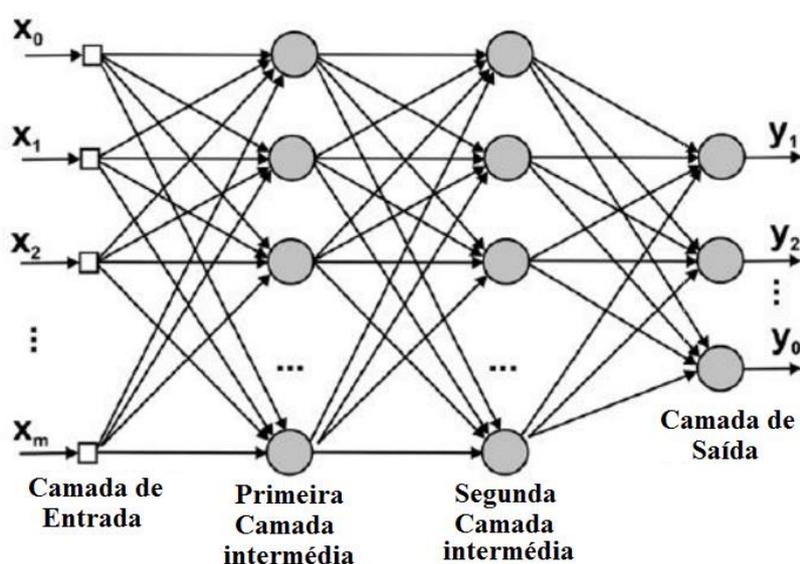


Figura 27 - Rede neuronal MLP com 2 camadas intermédias, m entradas e o saídas (Scielo, 2017).

Os nós que compõem uma RNA podem possuir conexões do tipo *feedback* (cíclica) ou *feedforward* (acíclicas) (Figura 28).

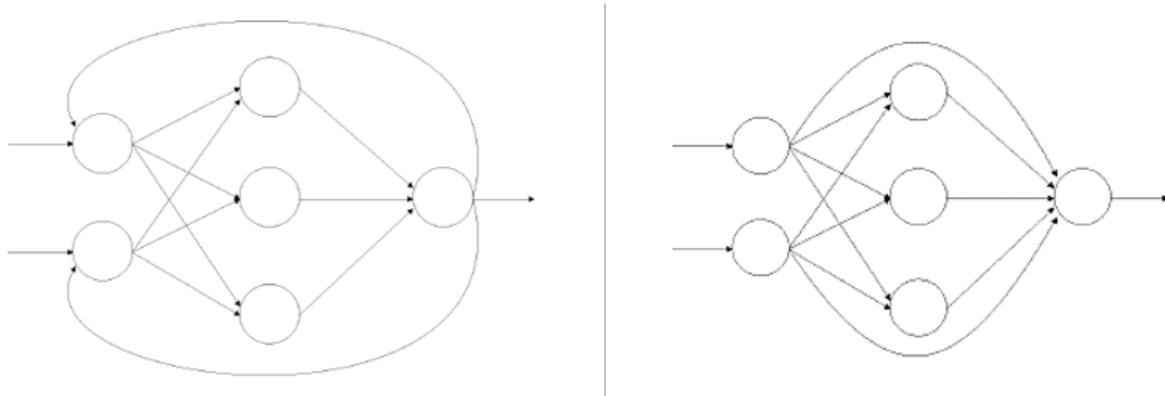


Figura 28 - Exemplo de uma RNA *feedback* (cíclica) e RNA *feedforward* (acíclica).

Nas RNA com conexões *feedback* a saída de um neurónio na camada i da rede é utilizada como entrada dos nós em camadas de índice menor ou igual a i . Se todas as ligações entre os neurónios forem cíclicas, a rede é chamada auto associativa. Estas redes são úteis para a recuperação ou regeneração de um padrão de entrada (Carvalho, 1998).

Nas RNA com conexões *feedforward* a saída de um neurónio na camada i da rede não pode ser usada como entrada de nós em camadas de índice menor ou igual a i (Carvalho, 1998). Uma aplicação típica das RNA *feedforward* consiste em desenvolver modelos não-lineares que também são usados para o reconhecimento e classificação de padrões.

Uma das características importantes das RNA é a capacidade de aprendizagem e deste modo melhorar o seu desempenho. Este processo de aprendizagem é conseguido através de métodos de treino caracterizados por um processo iterativo que consiste em ajustar os pesos das suas unidades até a classificação desejada ser obtida.

Existem vários algoritmos de aprendizagem específicos para determinados tipos de redes neuronais. Neste contexto existem os seguintes algoritmos de aprendizagem (Castro e Zuben, 2003):

- **Aprendizagem Supervisionada** - Durante a aprendizagem supervisionada, a RNA é treinada com auxílio de um agente externo que indica à rede a resposta desejada para um determinado conjunto de sinais de entrada.
- **Aprendizagem Não Supervisionada** - Nesta aprendizagem também denominada de auto-organização não é necessário a existência de um agente externo a indicar a resposta desejada durante o processo de treino.
- **Reforço** - Quando um agente externo avalia a resposta dada pela rede.

O ritmo de aprendizagem de uma RNA depende de vários fatores. Uma baixa taxa de aprendizagem resulta num período de tempo relativamente grande no processo de aprendizagem da rede, até que se possa alcançar um resultado considerado adequado.

Com uma taxa de aprendizagem elevada, a rede pode não ser capaz de fazer uma discriminação fina em relação aos sistemas que aprendem de forma mais lenta. Para além do tempo de aprendizagem existem vários fatores que são considerados ao efetuar-se o treino da rede. Os fatores relacionados com o processo de aprendizagem de uma RNA incluem: a complexidade da rede, o número de camadas, o paradigma de seleção, a arquitetura adotada, o algoritmo de aprendizagem, as regras utilizadas e a precisão desejada, entre outros. Todos estes fatores contribuem e alteram o tempo de treino da rede. A alteração destes fatores pode aumentar o tempo de treino ou resultar numa precisão pouco satisfatória.

A principal vantagem na utilização das RNA consiste no facto de terem maior imunidade ao ruído (filtragem automática de *outliers*) o que as adequa a tarefas de reconhecimento de imagem e de som. Por esta razão as RNA são recomendadas em aplicações cujos exemplos possam conter muito ruído por serem complexos como por exemplo: câmaras fotográficas, microfones, etc.

Também têm sido utilizadas com bastante sucesso na interpretação de cenas visuais como o reconhecimento de caracteres escritos à mão, reconhecimento de rostos de pessoas, reconhecimento de voz e aprendizagem de estratégias por robots.

4.4.2.4 K-means

O algoritmo K-means, criado em 1967 por MacQueen, é um algoritmo de *clustering* que agrupa um conjunto de exemplos num determinado número de K grupos.

Normalmente o valor de K é estimado por um método simples e bastante utilizado, apresentado na equação (12):

$$K = \sqrt{\frac{N}{2}} \quad (12)$$

Deste modo, k toma o valor da raiz quadrada de N (o número de exemplos do *dataset*) a dividir por 2. O *K-means* começa por criar k centróides que inicialmente são posicionados aleatoriamente. Ao longo das iterações, o algoritmo recalcula a posição dos centróides minimizando a distância (geralmente é utilizada a distância Euclidiana), entre os exemplos e o

centróide mais próximo. Os exemplos são inseridos no centroide mais próximo, ou seja, com maior similaridade. O centro dos *clusters* é recalculado a cada ciclo, tendo em conta o centro de massa dos elementos. O reposicionamento do *cluster* é utilizado pela seguinte função:

$$v_i = \frac{1}{C_i} \sum_{k=0}^n x_i \quad (13)$$

Onde:

‘ v_i ’ é o posicionamento do centróide i

‘ x_i ’ representa o ponto i do *dataset*

‘ C_i ’ representa o número de pontos do *cluster* i

O processo termina quando os centróides deixarem de se deslocar, deixar de haver trocas de objetos entre *clusters* ou terminar o número de iterações.

As principais vantagens deste algoritmo é facto de ser, rápido, robusto e fácil de entender.

4.5 Normas LOM e SCORM

Com a crescente utilização de objetos de aprendizagem no apoio às atividades de ensino, surgiram vários padrões com o objetivo de definir uma especificação para os objetos de aprendizagem utilizados pelos sistemas de gestão da aprendizagem (SGA). Um SGA é uma aplicação que permite a gestão de utilizadores e de atividades de aprendizagem (Pecheanu et al., 2011), bem como a disponibilização de serviços de suporte à aprendizagem *online* (Simões et al., 2013).

Os padrões com maior destaque são: SCORM (*Sharable Content Object Reference Model*), que define modelos de referência que especificam padrões de empacotamento e apresentação através da *web* num ambiente de ensino distribuído de objetos de aprendizagem; e o LOM (*Learning Object Metadata*) que surgiu a partir da necessidade de classificar e descrever mais detalhadamente objetos de aprendizagem (Pessoa e Benitti, 2008). O modelo de dados LOM é um padrão aberto que especifica a sintaxe e a semântica dos metadados associados a objetos de aprendizagem, que podem ser definidos como os atributos necessários para descrever completa e adequadamente um objeto de aprendizagem (IEEE-LTSC, 2018). O LOM é geralmente codificado em XML (eXtensible Markup Language), sendo utilizado para descrever objetos de aprendizagem ou quaisquer outros recursos digitais que sejam utilizados no apoio a processos de aprendizagem.

O esquema de dados conceituais do LOM possui uma estrutura hierárquica em forma de árvore composta por nove categorias:

1. **Geral (*General*):** informação que descreve o objeto de aprendizagem como um todo.
2. **Ciclo de vida (*Lifecycle*):** histórico e estado atual do objeto de aprendizagem e daqueles que contribuíram para a sua criação.
3. **Meta metadados (*Meta-metadata*):** informações sobre os metadados que descrevem o objeto de aprendizagem.
4. **Técnico (*Technical*):** requisitos técnicos e características do objeto de aprendizagem.
5. **Educacional (*Educational*):** características educacionais e pedagógicas do objeto de aprendizagem.
6. **Direitos (*Rights*):** direitos de propriedade intelectual e condições de uso do objeto de aprendizagem.
7. **Relação (*Relation*):** relação entre o objeto de aprendizagem e outros objetos relacionados.
8. **Anotação (*Annotation*):** comentários sobre o uso educacional dos objetos de aprendizagem, incluindo quando e por quem é que foram criados.
9. **Classificação (*Classification*):** esquemas de classificação utilizados para descrever as diferentes características do objeto de aprendizagem.

Cada uma das categorias descritas anteriormente contém subelementos que podem ser elementos simples que contêm dados, ou podem ser elementos agregados, que contêm outros subelementos. A Figura 29 ilustra a estrutura em forma de árvore do modelo de dados LOM constituída pelos seus elementos e respetivos subelementos.

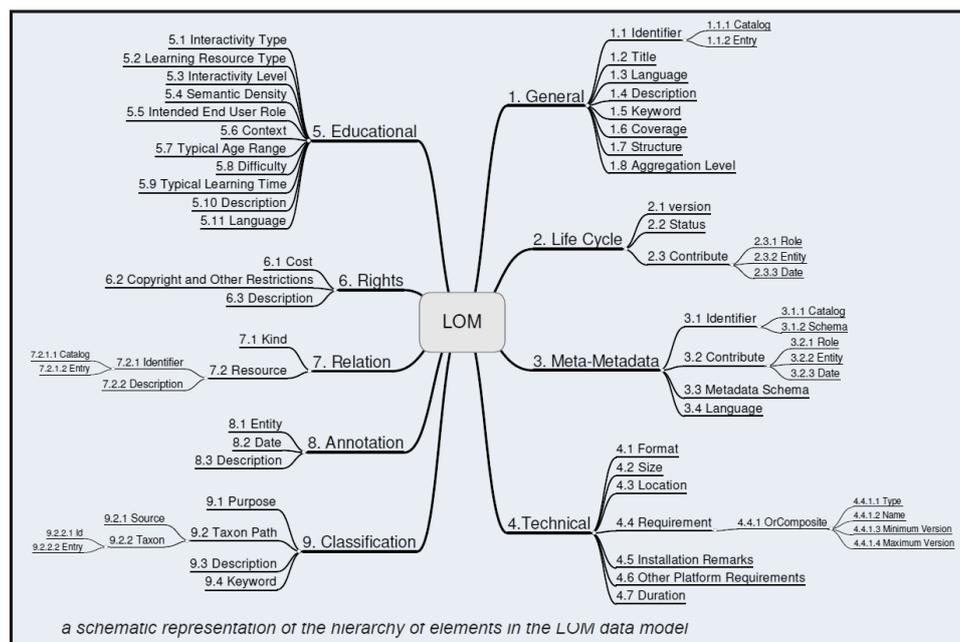


Figura 29 - Hierarquia dos elementos que compõem o modelo de dados LOM (IMS Global, 2018).

Quando se implementa um sistema com recurso à norma LOM não é necessário oferecer suporte a todos os elementos do modelo de dados, nem o modelo de dados deve limitar as informações que podem ser armazenadas. Os elementos já existentes no modelo de dados LOM podem ser descartados e elementos de outros modelos de metadados podem ser adicionados.

O Modelo SCORM é uma coleção de padrões e especificações que permitem a criação de objetos de aprendizagem reutilizáveis. Estes objetos denominados de *sharable content objects* (SCO) podem ser reutilizados em diferentes sistemas e contextos. Ao permitir que os SCO sejam independentes da plataforma de *e-learning* ou do repositório utilizado possibilita que o mesmo conteúdo possa ser incorporado em várias disciplinas ou módulos e deste modo poder vir a ter diferentes utilizações. Deste modo, se um SGA estiver em conformidade com a norma SCORM, este poderá reproduzir qualquer conteúdo que seja compatível com essa norma. O SCORM é composto por três subespecificações (SCORM Explained, 2018):

- **Secção “Content Packaging”:** especifica como o conteúdo deve ser empacotado e descrito. A especificação do *Content Packaging* utiliza um ficheiro de manifesto (*manifest file*). O manifesto é um ficheiro XML que contém a descrição do conteúdo. Cada parte do manifesto pode ser descrita em detalhes associados aos metadados. Os metadados do SCORM são armazenados no formato LOM e podem ser aplicados a qualquer secção do manifesto, podendo por exemplo, ser aplicados ao curso como um todo, a elementos

individuais ou até mesmo a recursos e arquivos de modo a melhorar a sua capacidade de reutilização. O conteúdo pode ser entregue, por exemplo, num CD ou pode ser colocado num arquivo ZIP. Quando o conteúdo é colocado num arquivo ZIP, ele é denominado *package interchange file* ou PIF. Os PIF são o formato de armazenamento mais comum do modelo SCORM.

- **Secção “Tempo de execução (*Run-Time*)”**: especifica como o conteúdo deve ser transmitido e como é efetuada a comunicação com o SGA. A especificação do tempo de execução informa ao SGA se este deve iniciar o conteúdo na mesma ou numa nova janela do navegador de *Internet*. O SGA só pode lançar um SCO de cada vez. Alguns SGA permitem que os autores dos conteúdos controlem como os SCO são iniciados, quais os elementos de navegação disponíveis e até a dimensão da janela do navegador de *Internet* que apresenta o SCO.

- **Secção “Sequenciamento (*Sequencing*)”**: especifica como o aluno pode navegar entre as partes do curso. É definido por um conjunto de regras de sequenciamento representadas em formato XML no ficheiro de manifesto do curso. A utilização do Sequenciamento é opcional. No caso de nenhuma regra de sequenciamento ser especificada, as configurações padrão permitem fornecer uma experiência adequada ao aluno.

4.6 Resumo

A lógica difusa permite captar informações vagas, em geral descritas numa linguagem natural e convertê-las para um formato numérico quando necessário. No contexto da plataforma ADAPT é utilizada para efetuar um mapeamento que relaciona o perfil do aluno caracterizado através do modelo de Felder-Silverman com OA classificados segundo o modelo VARK ([secção 4.1](#)).

O paradigma RBC permite resolver problemas relativos a casos novos com base em soluções utilizadas para solucionar problemas em casos anteriores. Na plataforma ADAPT, o paradigma RBC é utilizado para determinar a sequência de apresentação dos OA de um determinado curso com base em casos criados através da utilização da plataforma por alunos que concluíram o curso anteriormente ([secção 4.2](#)).

Os Algoritmos Genéticos são uma classe particular de algoritmos evolutivos que através de

técnicas de pesquisa e otimização procuram encontrar soluções ótimas, ou aproximadamente ótimas. A plataforma ADAPT utiliza AG quando a solução devolvida pelo sistema RBC para o problema atual não é considerada a mais adequada sendo necessário a realização de uma adaptação do caso ([secção 4.3](#)).

O *data mining* pode ser considerado como a aplicação de métodos e técnicas em grandes bases de dados, para encontrar tendências ou padrões com o intuito de descobrir conhecimento ([Santos e Azevedo, 2005](#)). No contexto da plataforma ADAPT as técnicas de *data mining* são utilizadas na sugestão de conteúdos alternativos e na identificação de mudanças de estilo de aprendizagem ([secção 4.4](#)). Para este efeito foi desenvolvido um módulo de *data mining* e pesquisa local implementado pelo Bolseiro Pedro Filipe Caldeira Neves através da bolsa com referência PTDC/CPE-CED/115175/2009 FEDER - Eixo I de Programa Operacional Fatores de Competitividade (POFC) / QREN (COMPETE: FCOMP-01-0124-FEDER-014418). Os detalhes de implementação do módulo podem ser consultados em ([Neves, 2014](#)). O módulo de *data mining* e pesquisa local foi integrado na plataforma ADAPT de modo a funcionar em conjunto com o módulo STI. Depois de efetuada a integração foram realizados testes funcionais de modo a validar funcionalidades especificadas e testes de integração.

Por fim, na [secção 4.5](#) foram descritas as normas: LOM que classifica e descreve objetos de aprendizagem e SCORM que define padrões de empacotamento e apresentação de objetos de aprendizagem.

5 Modelação e Design

Neste capítulo apresentam-se os diagramas UML (*Unified Modeling Language*) utilizados para efetuar a modelação e o levantamento de alguns dos requisitos do sistema. Deste modo, na [secção 5.1](#) ilustra-se o Diagrama de Casos de Uso (DCU), na [secção 5.2](#) apresenta-se o Diagrama de Atividade (DA), na [secção 5.3](#) descreve-se o Diagrama de Classes, na [secção 5.4](#) apresenta-se o Diagrama de Sequência (DS), na [secção 5.5](#) expõe-se o Modelo Físico criado no processo de modelação e por último na [secção 5.6](#) é efetuado o resumo do capítulo.

5.1 Diagrama de Casos de Uso

Um Diagrama de Casos de Uso (DCU) é uma ferramenta utilizada no levantamento de requisitos funcionais de uma aplicação.

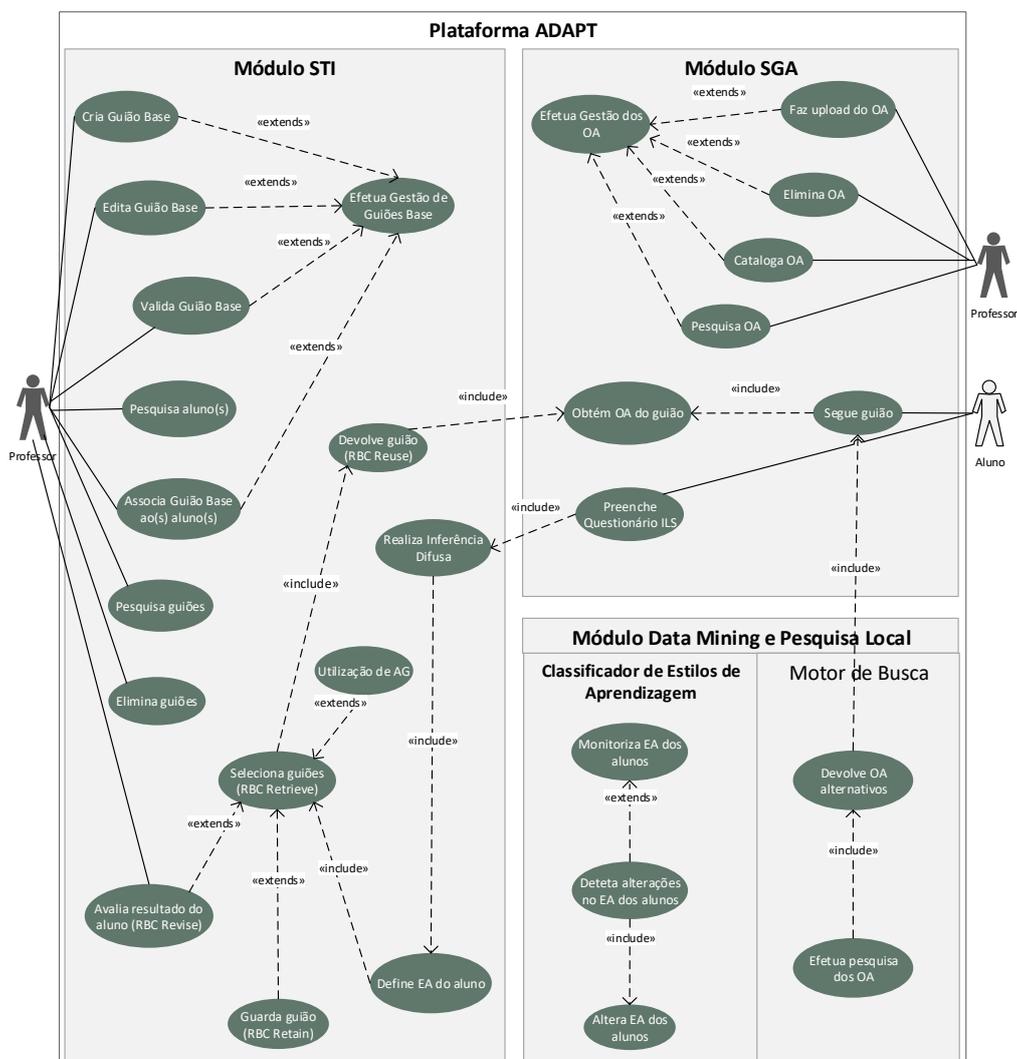


Figura 30 - Diagrama de casos de uso da plataforma ADAPT.

Representa o conjunto de interações entre um ator e o sistema. Um ator é um humano ou entidade que interage com o sistema e realiza uma ação. Na Figura 30 apresenta-se um DCU

geral destinado a proporcionar uma visão global das interações entre os atores (professor e aluno) e os módulos da plataforma ADAPT. Inicialmente o professor acede ao módulo SGA para efetuar o *upload* dos OA que contêm os conteúdos educativos que pretende apresentar aos seus alunos. O SGA permite realizar várias tarefas de gestão como pesquisar e classificar os OA existentes no seu repositório. De seguida, o professor dirige-se ao módulo STI para criar o Guião Base, construído com recurso aos OA armazenados no repositório do SGA. O Guião Base é uma estrutura em forma de grafo que contém as várias sequências de visualização possíveis de um dado curso a partir do qual vai ser extraído o percurso (guião) a ser seguido pelo aluno selecionado com base na proximidade desse guião às suas preferências de aprendizagem.

Quando um aluno se autentica na plataforma ocorre uma de duas situações: é a primeira vez que o aluno utiliza a plataforma, ou então o aluno já se tinha autenticado previamente e já se encontra a seguir um guião.

Na primeira situação é-lhe apresentado o questionário ILS de Felder-Soloman. Depois de submeter o questionário preenchido, o módulo de lógica difusa é invocado recebendo como parâmetros os resultados do questionário. Este módulo mapeia os resultados do ILS em preferências VARK e guarda-as na base de dados. De seguida entra em funcionamento o paradigma RBC que, a partir da biblioteca de casos onde se encontram guiões anteriores já utilizados por outros alunos ou guiões novos previamente definidos por um professor, retorna um guião que em princípio vai ser utilizado para apresentação dos conteúdos ao aluno. O passo seguinte consiste em verificar se este é o guião mais adequado tendo em conta o perfil do aluno previamente determinado pelo sistema difuso: de facto, pode acontecer que o não seja, dado que na biblioteca de casos (guiões) existem apenas sequências previamente utilizadas ou criadas manualmente. Contudo, havendo em cada nó vários OA com diferentes classificações VARK, é eventualmente possível criar um guião novo que se encontre mais adaptado ao perfil determinado pelo ILS. Para esse efeito são utilizados algoritmos genéticos, na tentativa de otimizar a sequência de conteúdos ao perfil ILS do novo aluno. De seguida é invocado um motor de busca local que efetua uma pesquisa com vista a identificar outros OA (conteúdos complementares que não se encontram associados aos nós do grafo) relacionados com os conteúdos do guião que o aluno irá seguir. Dá-se então início à apresentação do primeiro conteúdo e simultaneamente dos links para o ou os OA seguintes bem como para os relacionados que foram retornados pelo motor de busca local. O aluno pode então avançar ao

longo do guião e, quando terminado, é guardado na biblioteca de casos do sistema RBC passando assim a constituir um novo exemplo (de sucesso, ou de falha).

Na segunda situação - em que o aluno já se encontra a seguir um guião - a plataforma acede-lhe e posiciona-se no último OA visualizado na sessão anterior. De seguida é invocado o motor de busca local para pesquisar conteúdos alternativos relacionados com o OA que o aluno se encontra a visualizar naquele momento. São apresentados o OA seguinte e os links para os OA relacionados. Segue-se então o mesmo processo descrito anteriormente, até ao final do curso.

Enquanto o aluno progride ao longo do guião, o classificador de estilos de aprendizagem do módulo *data mining* e pesquisa local é executado em paralelo e periodicamente verifica se existem alterações no perfil de aprendizagem de todos os alunos que estejam ativos na base de dados da plataforma. Caso detete alterações no perfil de algum aluno, são alteradas as suas preferências de aprendizagem VARK e também os OA do guião atual que ainda não foram acedidos pelo aluno.

De seguida é efetuada uma descrição dos casos de uso apresentados na Figura 30. Na Tabela 9 descrevem-se os casos de uso do módulo STI, na Tabela 10 apresentam-se os casos de uso do módulo SGA e na Tabela 11 enumeram-se os casos de uso do módulo de *data mining* e pesquisa local.

Tabela 9 - Descrição dos Casos de Uso do módulo STI.

Casos de Uso (Módulo STI)	Efetua Gestão de Guiões Base	Processo que engloba as tarefas de gestão de guiões.
	Cria Guião Base	O professor tem a possibilidade de criar um Guião Base com as várias sequências possíveis de apresentação de um curso.
	Edita Guião Base	O professor tem a possibilidade de editar um guião, podendo acrescentar ou retirar conteúdos. Também pode alterar a sequência de conteúdos a serem apresentados.
	Valida Guião Base	O professor pode validar/invalidar um guião.
	Pesquisa aluno(s)	O professor realiza pesquisas de alunos.
	Associa Guião Base ao(s) aluno(s)	Processo que consiste em atribuir um Guião Base a um conjunto de alunos.
	Pesquisa guiões	O professor pode efetuar pesquisas de guiões.
	Elimina guiões	O professor tem a possibilidade de eliminar guiões.
	Seleciona guiões (<i>Retrieve</i>)	Realiza a fase <i>Retrieve</i> do paradigma RBC em que é retornado um conjunto de guiões (casos).

	Utilização de AG (<i>Reuse</i>)	Fase <i>Reuse</i> do paradigma RBC que utiliza um AG para efetuar a otimização de um guião quando este não possui um grau de similaridade satisfatória ao perfil do aluno.
	Devolve guião	Processo que consiste na obtenção do guião a apresentar ao aluno.
	Avalia resultado do aluno (<i>Revise</i>)	Processo em que o professor avalia o guião seguido pelo aluno.
	Guarda guião (<i>Retain</i>)	Fase <i>Retain</i> do paradigma RBC que consiste em armazenar o guião na biblioteca de casos.
	Realiza Inferência Difusa	Processo em que o Sistema Difuso efetua o processo de inferência sobre o resultado do questionário ILS preenchido pelo aluno (módulo SGA).
	Define EA do aluno	Obtenção do estilo de aprendizagem VARK do aluno através do Sistema Difuso.

Tabela 10 - Descrição dos Casos de Uso do módulo SGA.

Casos de Uso (Módulo SGA)	Efetua Gestão dos OA	Processo que engloba as tarefas de gestão de guiões.
	Faz <i>upload</i> do OA	Processo que consiste em efetuar o carregamento de um OA para o repositório do módulo SGA.
	Elimina OA	Processo que consiste em eliminar fisicamente um OA.
	Cataloga OA	Processo que consiste em catalogar um OA com o paradigma VARK, taxonomia de Bloom e as normas SCORM ou LOM.
	Pesquisa OA	Efetua a pesquisa de OA no repositório do SGA.
	Preenche Questionário ILS	Preenchimento do questionário ILS por parte do aluno.
	Obtém OA do guião	Obtém o OA sugerido pelo STI e apresenta-o ao aluno.
	Segue guião	Aluno efetua a navegação do guião que lhe foi atribuído.

Tabela 11 - Descrição dos Casos de Uso do módulo *data mining* e pesquisa local.

Casos de Uso (Módulos de <i>data mining</i> e pesquisa local)	Monitoriza EA dos alunos	Monitorização do estilo de aprendizagem dos alunos com base nos OA consultados e tempo de permanência despendido.
	Deteta alterações nos EA dos alunos	Processo que deteta alterações no estilo de aprendizagem dos alunos.
	Altera EA dos alunos	Efetua uma atualização do estilo de aprendizagem dos alunos.
	Devolve OA alternativos	Os OA alternativos são disponibilizados.
	Efetua pesquisa dos OA	Pesquisa OA alternativos relacionados com o OA que o aluno se encontra a visualizar em cada momento.

5.2 Diagrama de Atividades

Um Diagrama de Atividade (DA) é utilizado para modelar o aspeto comportamental de processos. Este diagrama mostra o fluxo de controlo de uma atividade para outra e assim realiza a modelação de aspetos dinâmicos do sistema. Na maioria dos casos envolve a modelação de etapas sequenciais num processo computacional. De seguida é apresentado o DA da plataforma ADAPT (Figura 31) onde são descritas as atividades do professor, do aluno, do processo de adaptação do Guião Base ao aluno e do módulo de *data mining* e pesquisa local.

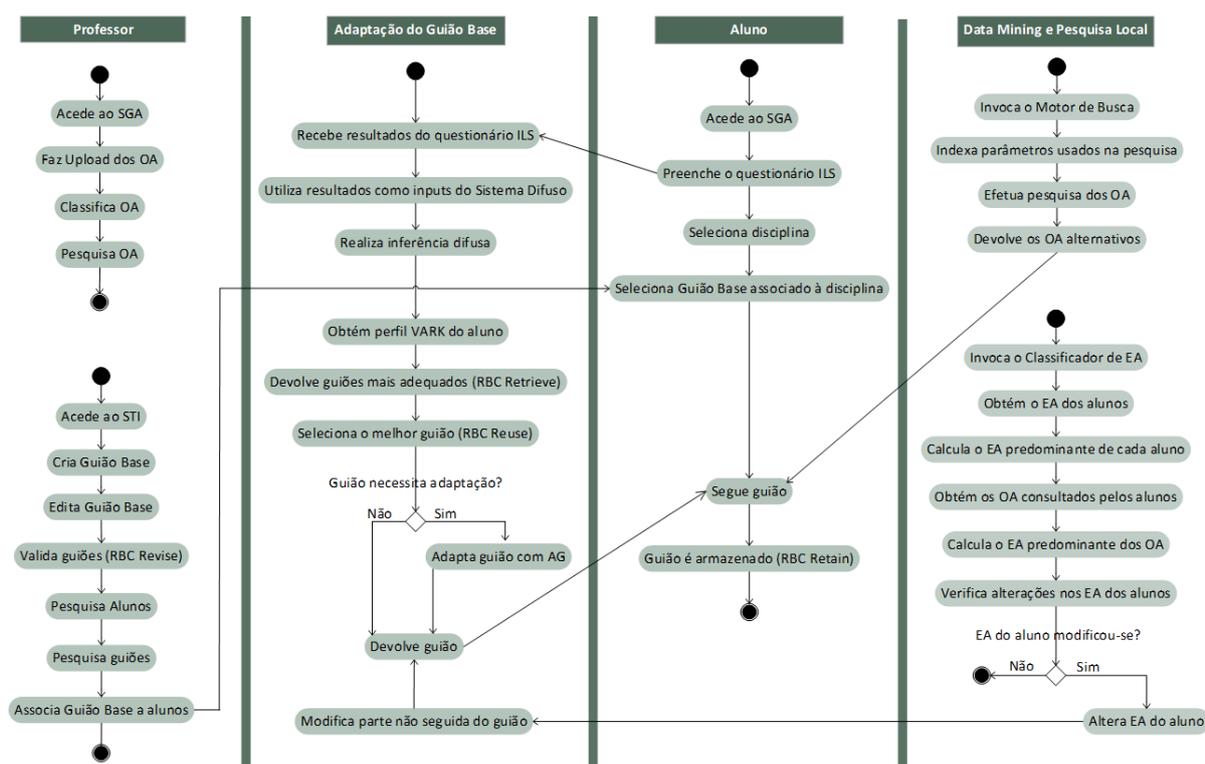


Figura 31 - Diagrama de Atividades da plataforma ADAPT.

As atividades do professor representadas na primeira coluna da Figura 31 incluem tarefas de gestão por ele pode realizar. Estas, incluem a gestão dos OA existentes no SGA, como o *upload*, classificação, pesquisa e eliminação, assim como as tarefas de gestão de Guiões Base como a criação, edição e associação a alunos. Na segunda coluna estão ilustradas as atividades de adaptação do Guião Base a partir do qual vai ser extraído o guião a apresentar ao aluno. Estas atividades incluem a receção dos resultados do questionário ILS e obtenção do perfil VARK utilizado posteriormente pelo paradigma RBC na seleção do guião a ser apresentado. Este guião pode necessitar de ser adaptado com recurso a um algoritmo genético antes de ser apresentado ao aluno. Na terceira coluna são descritas as atividades decorrentes da utilização da plataforma

por parte de um aluno desde o preenchimento do questionário ILS até à navegação do guião selecionado. Por fim, na quarta coluna apresentam-se as atividades do módulo de *data mining* e pesquisa local: o motor de busca sugere conteúdos alternativos e o classificador de estilos de aprendizagem monitoriza e deteta alterações no perfil de aprendizagem do aluno e em caso afirmativo modifica a parte ainda não seguida do guião. Os processos representados na Figura 31 são descritos na Tabela 12.

Tabela 12 - Descrição dos processos do Diagrama de Atividades da plataforma ADAPT.

Professor	Acede ao SGA	O professor autentica-se no SGA com as suas credenciais.
	Faz <i>Upload</i> do OA	Carrega o OA para o repositório do SGA.
	Classifica OA	Processo que consiste em classificar um OA com VARK, taxonomia Bloom, normas SCORM ou LOM.
	Pesquisa OA	Efetua uma pesquisa para encontrar um ou mais OA pretendidos.
	Elimina OA	Elimina um OA do repositório do módulo SGA.
	Acede ao STI	O professor acede ao módulo STI.
	Cria Guião Base	Criação do Guião Base com o curso que vai ser seguido pelos alunos.
	Edita Guião Base	Efetua alterações no Guião Base.
	Valida guiões (RBC <i>Revise</i>)	Valida guiões que foram seguidos pelos alunos.
	Pesquisa Alunos	Efetua pesquisa de alunos por nome, n.º de aluno ou disciplina.
	Pesquisa Guiões	Realização de pesquisas de guiões Base ou adaptados pelo nome do guião ou por disciplina.
	Associa Guião Base aos alunos	Associa os alunos a um determinado Guião Base.
Adaptação do Guião Base	Recebe os resultados do questionário ILS	Processo que consiste em receber os resultados do questionário ILS preenchido pelo aluno.
	Utiliza resultados como <i>inputs</i> do Sistema Difuso	Os resultados obtidos resultantes do preenchimento do questionário ILS são passados como <i>inputs</i> ao sistema difuso.
	Realiza inferência difusa	Realização do processo de inferência difusa.
	Obtém perfil VARK do aluno	Processo que consiste na obtenção do perfil VARK do aluno.
	Devolve guiões mais adequados (RBC <i>Retrieve</i>)	Fase <i>Retrieve</i> do paradigma RBC que devolve os casos (guiões) com maior similaridade com o perfil do aluno.
	Seleciona o melhor guião (RBC <i>Reuse</i>)	Seleciona o guião com a menor distância global ao perfil do aluno.
	Adapta Guião com AG	Efetua a adaptação do guião com recurso a um AG no caso da fase <i>Reuse</i> não devolver uma solução considerada satisfatória.

	Devolve Guião	Guião devolvido pela fase <i>Reuse</i> do paradigma RBC.
	Modifica parte não seguida do guião	O motor de busca, pertencente ao módulo <i>data mining</i> e pesquisa local, efetua a alteração da parte do guião ainda não seguida pelo aluno. O motor de busca é acionado cada vez que o aluno efetue uma ação de navegação no guião sendo apresentado o primeiro elemento de um array contendo uma lista de OA ordenada pelos critérios da função de avaliação utilizada pelo motor de busca.
Aluno	Acede ao SGA	O aluno autentica-se no SGA com as suas credenciais.
	Preenche questionário ILS	Preenche o questionário ILS de Felder-Soloman.
	Seleciona disciplina	Seleciona a disciplina pretendida.
	Seleciona Guião Base associado à disciplina	Seleciona o Guião Base que pretende utilizar.
	Segue guião	Segue o guião adaptado ao perfil de aprendizagem do aluno.
	Guião é armazenado (RBC <i>Retain</i>)	Processo que consiste em armazenar o guião (caso) na biblioteca de casos.
<i>Data mining</i> e pesquisa local (Motor de Busca)	Invoca o Motor de Busca	Processo que consiste na invocação do motor de busca do módulo <i>data mining</i> e pesquisa local.
	Indexa parâmetros usados na pesquisa	Efetua a indexação de atributos relevantes que possibilitam o processo de pesquisa.
	Efetua pesquisa dos OA	Pesquisa OA alternativos com base no OA que o aluno se encontra a estudar no momento.
	Devolve os OA alternativos	Os OA alternativos são disponibilizados ao aluno no caso de este os pretender consultar.
<i>Data mining</i> e pesquisa local (Classificador de Estilos de Aprendizagem)	Invoca o Classificador de EA	Invocação do classificador de estilos de aprendizagem do módulo <i>data mining</i> e pesquisa local.
	Obtém o EA dos alunos	Obtenção as preferências VARK de cada aluno.
	Calcula o EA predominante de cada aluno	Com base nos parâmetros VARK de cada aluno calcula o seu estilo de aprendizagem predominante.
	Obtém os OA consultados pelos alunos	Obtém as consultas que os alunos da plataforma têm vindo a fazer ao longo de várias semanas.
	Calcula o EA predominante dos OA	Com base nos parâmetros VARK de cada OA calcula o seu estilo de aprendizagem predominante.
	Verifica alterações nos EA dos alunos	Comparando o EA do aluno com as contagens de OA diferentes que têm vindo a consultar, o sistema calcula se existe ou não mudança no perfil de aprendizagem do aluno.
	Altera EA do aluno	Regista a alteração do EA do aluno na base de dados.

5.3 Diagrama de Classes

A partir dos diagramas apresentados nas [seções 5.1](#) e [5.2](#) foram extraídas as principais classes necessárias ao correto funcionamento da plataforma e que originaram o modelo conceptual apresentado na Figura 32.

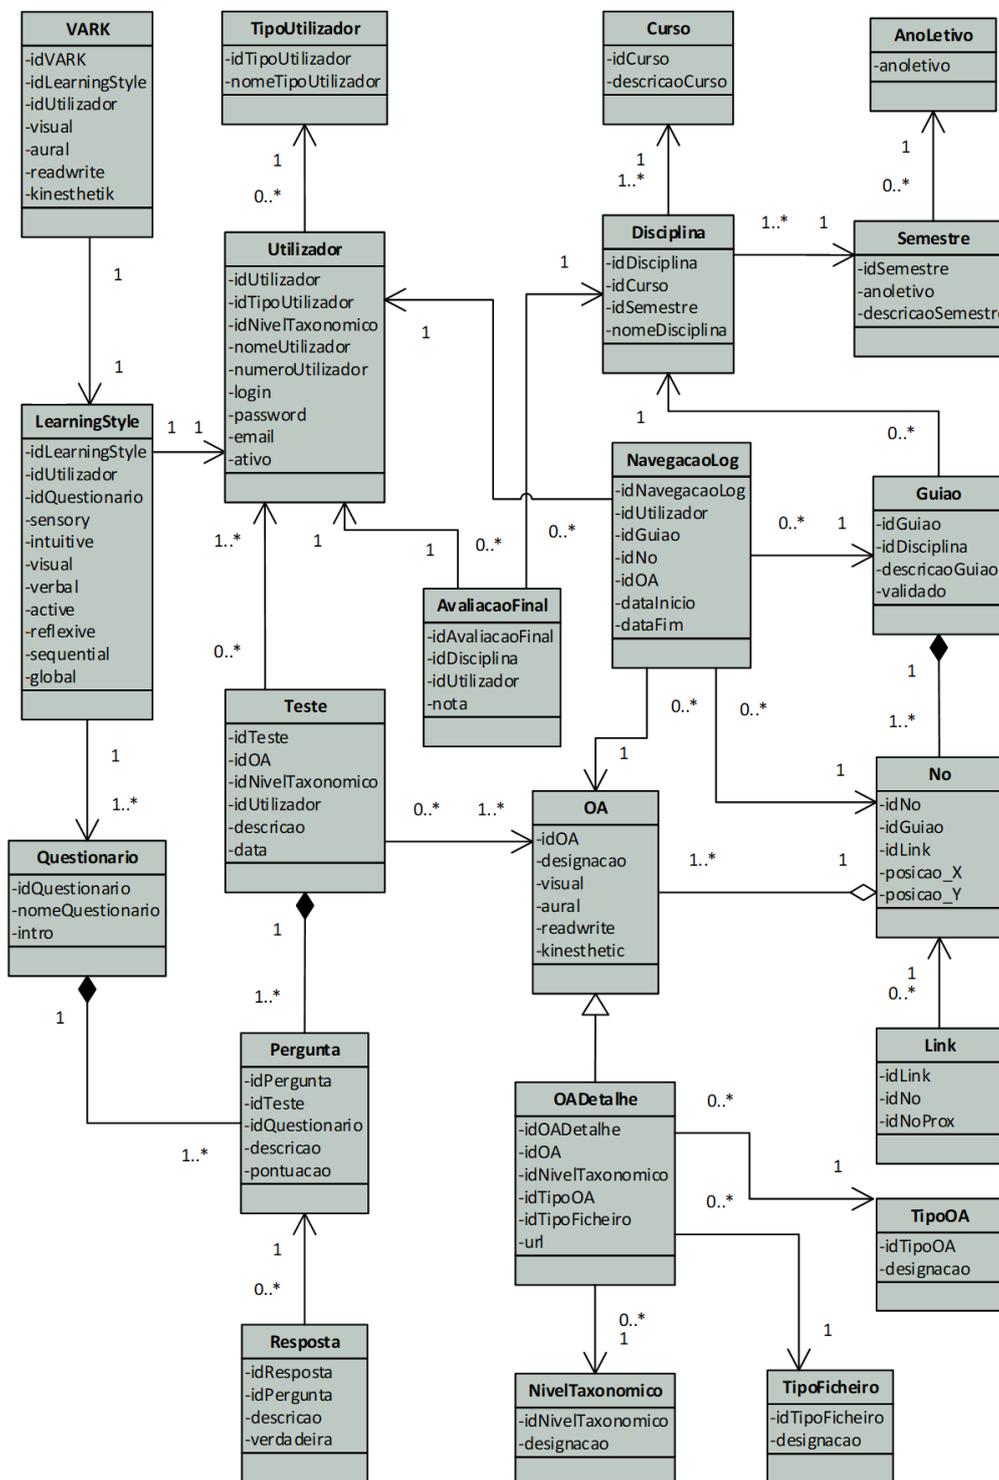


Figura 32 - Diagrama de Classes da plataforma ADAPT.

5.4 Diagrama de Sequência

Os diagramas de sequência (DS) são utilizados em UML para representar a sequência de processos, mais especificamente as mensagens passadas entre objetos, num programa de computador. A Figura 33 apresenta o DS com a troca de mensagens de alguns dos objetos existentes na plataforma ADAPT quando esta é utilizada por um professor.

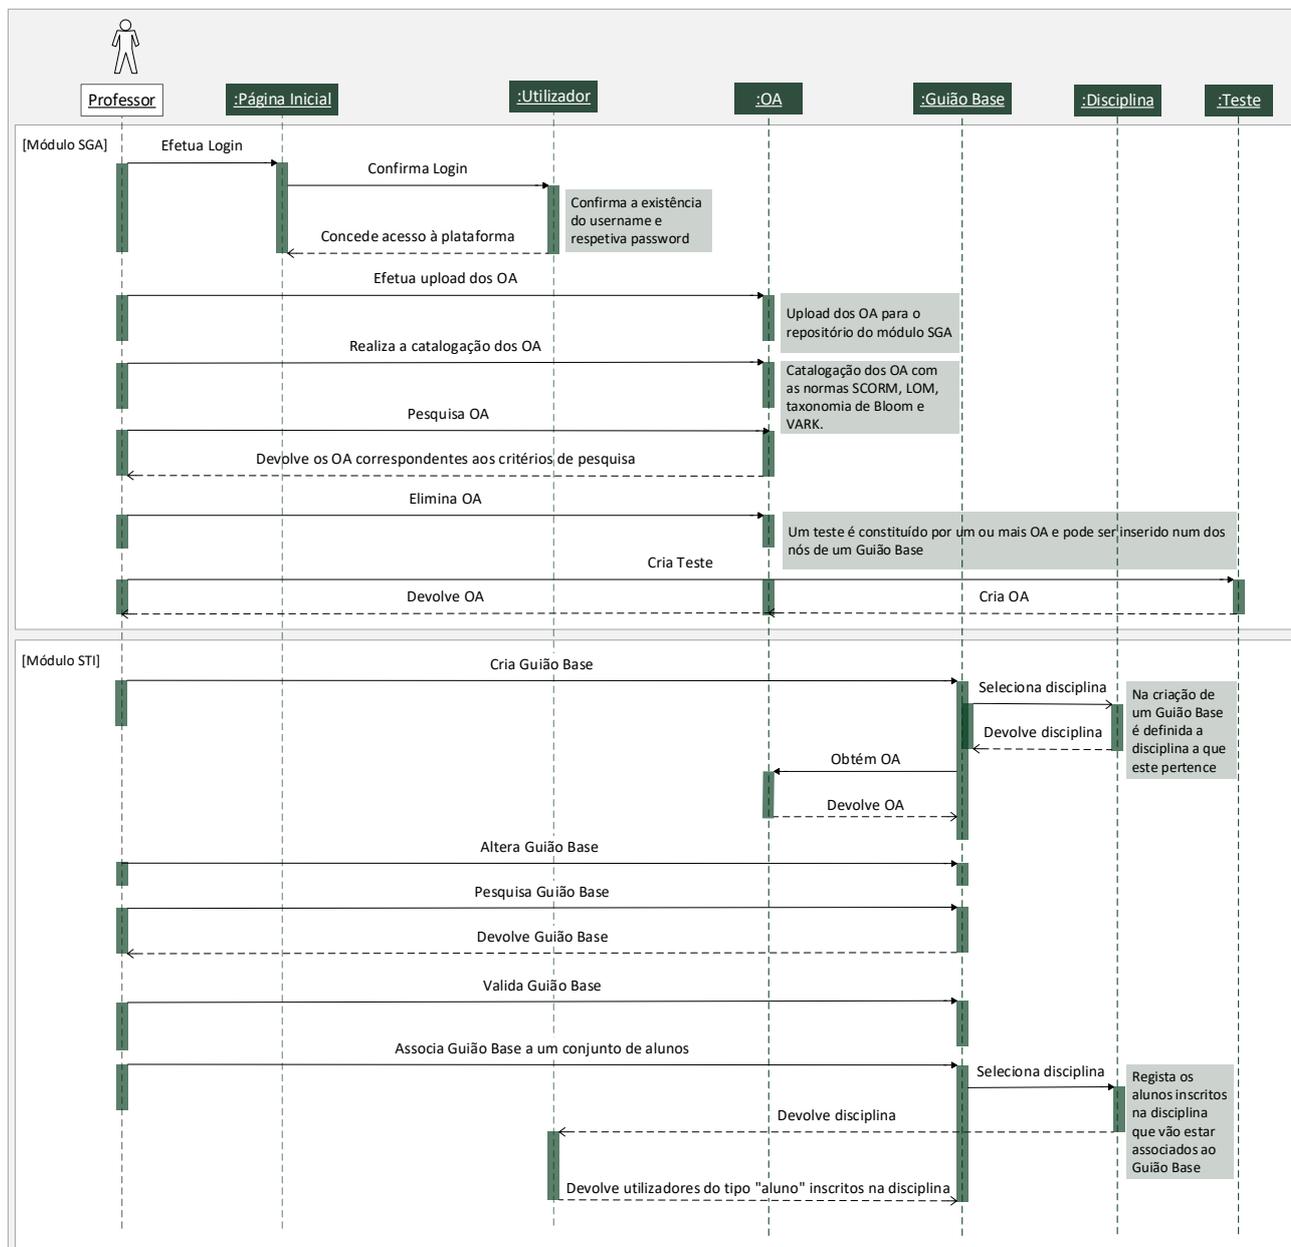


Figura 33 - Diagrama de sequência da utilização da plataforma ADAPT por um professor.

Quando um professor acede ao módulo SGA este utiliza as suas credenciais na página inicial de modo a proceder à sua autenticação na plataforma. Neste processo são comparados o *login*

e *password* inseridos com os existentes no objeto “Utilizador”. No caso do processo ser realizado com sucesso são disponibilizadas as opções de gestão dos OA existentes nomeadamente *upload*, pesquisa, catalogação e eliminação dos OA.

Um professor tem a possibilidade de realizar testes com o objetivo de determinar o nível de conhecimento dos alunos. Cada um destes testes é caracterizado por um ou vários OA que podem posteriormente ser colocados num Guião Base e desta forma disponibilizados aos alunos. No módulo STI são disponibilizadas ao professor opções de criação e gestão dos Guiões Base tendo para o efeito acesso às informações dos OA armazenados no SGA.

A Figura 34 apresenta um DS com a troca de mensagens de alguns dos objetos da plataforma ADAPT quando esta é utilizada por um aluno.

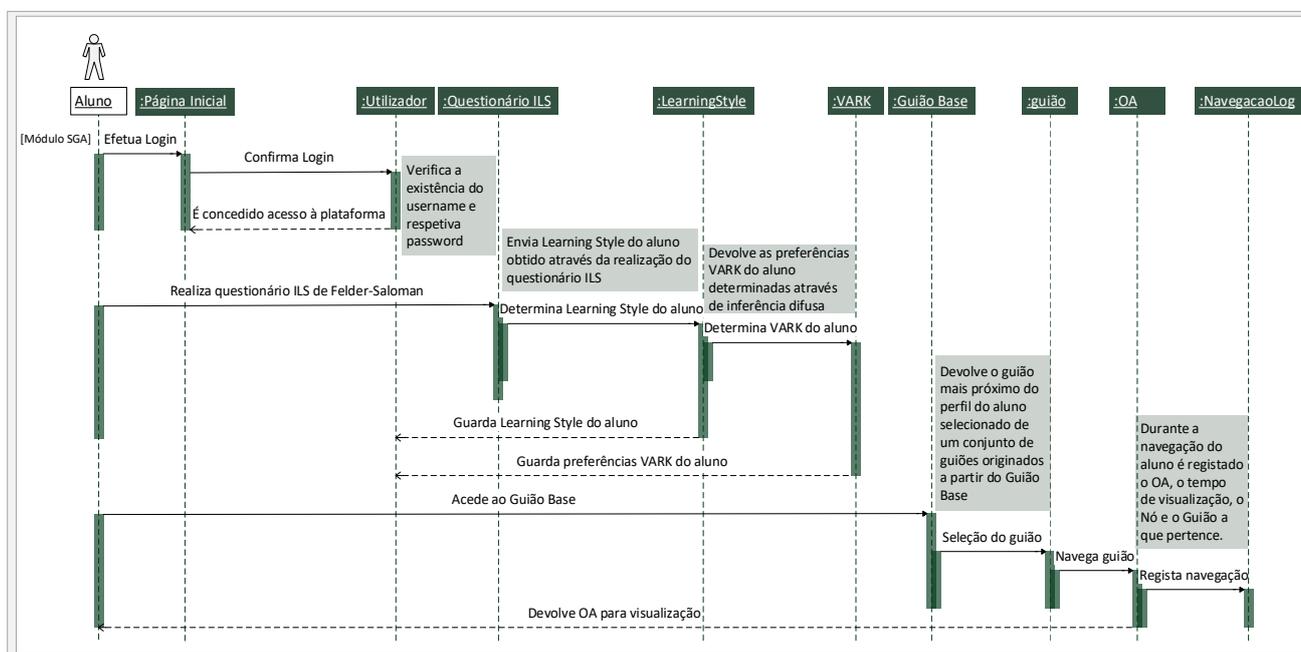


Figura 34 - Diagrama de sequência da utilização da plataforma ADAPT por um aluno.

O processo de autenticação de um aluno é semelhante ao de um professor. No caso da autenticação ser bem sucedida e ser a primeira vez que o aluno acede à plataforma é apresentado ao aluno o questionário ILS (objeto QuestionárioILS) sendo guardadas as suas respostas, o resultado obtido (objeto *LearningStyle*) e as preferências de aprendizagem VARK (objeto VARK). Depois de preencher o questionário ILS é disponibilizado ao aluno o acesso às disciplinas a que está inscrito e respetivos Guiões Base. Ao aluno é apenas permitido selecionar os Guiões Base utilizados pela plataforma para determinar a sequência a apresentar ao aluno

(objeto guião) constituída pelos conteúdos educacionais (objeto OA). Os OA acedidos durante a navegação do aluno são registados no objeto NavegacaoLog, onde também é guardado o tempo de permanência despendido em cada um dos OA. O objeto NavegacaoLog armazena os exemplos da base de casos utilizados pelo sistema RBC.

5.5 Modelo Físico

Nesta secção apresentam-se as tabelas de base de dados que foram criadas para apoiar os processos existentes na plataforma ADAPT. O modelo físico foi obtido no processo de análise descrito nas secções anteriores. De seguida são descritas as tabelas mais relevantes da base de dados e por fim é apresentado o modelo físico completo. As tabelas ilustradas são representadas através das cores verde e azul. A criação das tabelas ilustradas com a cor verde foram da responsabilidade do autor do presente documento, enquanto a criação das tabelas de cor azul foram da responsabilidade do bolseiro Luís Dias no âmbito do “Projeto e desenvolvimento de um LMS”. Na Figura 35 apresentam-se as tabelas relacionadas com o Guião Base e os guiões adaptados seguidos pelos alunos.

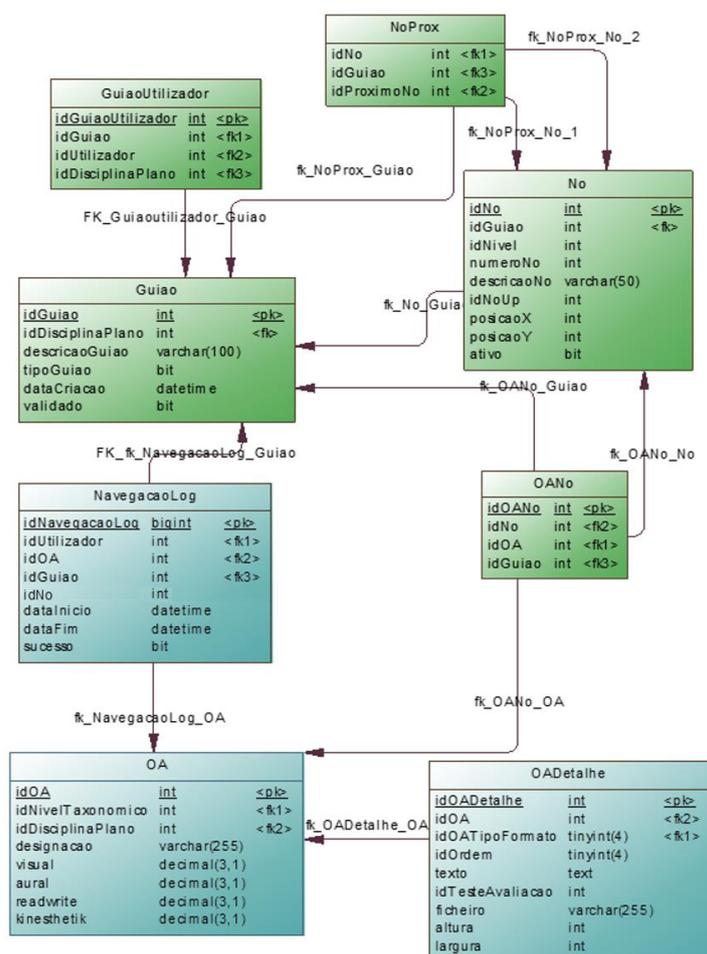
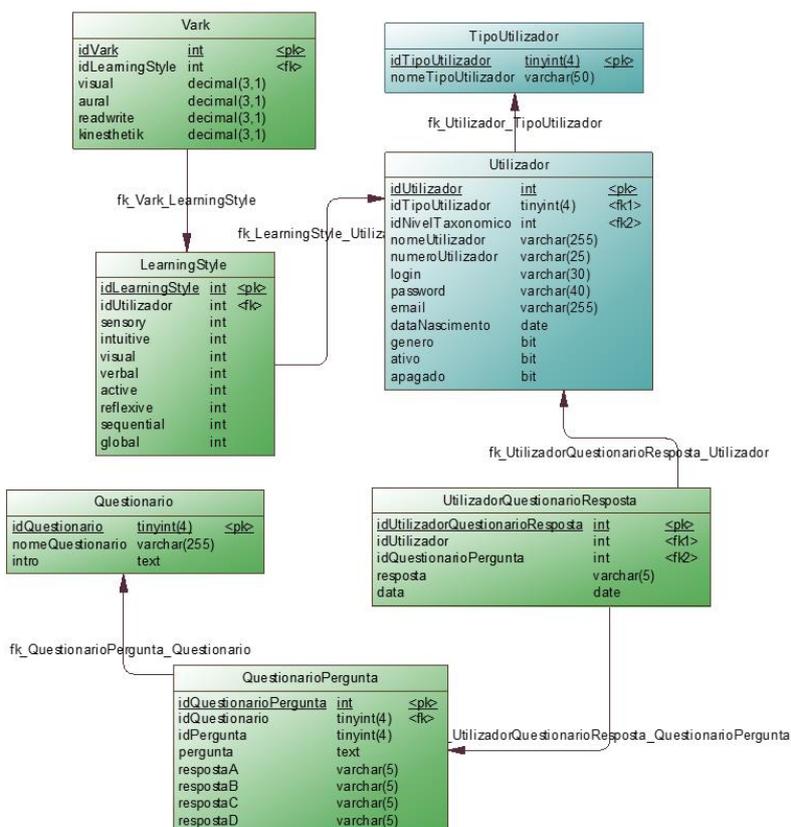


Figura 35 - Tabelas da BD responsáveis pela representação dos Guiões Base e guiões adaptados.

Um Guião Base é caracterizado por um grafo sendo armazenado na tabela “Guião” que possui uma relação 1:N com a tabela “No” que representa um vértice do grafo. A tabela “NoProx” representa uma aresta com ligação para outro nó do Guião Base. Um nó pode conter vários objetos de aprendizagem representados pela tabela “OA” e “OADetalhe”. A tabela “NavegacaoLog” regista os OA acedidos pelos alunos ao seguir o guião adaptado que lhes foi proposto.

A Figura 36 apresenta as tabelas da BD relacionadas com o estilo de aprendizagem do aluno. Inicialmente o aluno, representado pela tabela “Utilizador” na BD, preenche o questionário ILS que o avalia nas quatro dimensões do modelo Felder-Silverman (FS). As tabelas utilizadas na representação do questionário são: tabela “Questionario”, tabela “QuestionarioPergunta” que armazena as perguntas do questionário e a tabela “UtilizadorQuestionarioResposta” que armazena as respostas dadas pelo aluno ao responder ao questionário. Cada uma das dicotomias do modelo Felder-Silverman é armazenada na tabela “LearningStyle”. As preferências de aprendizagem VARK do aluno são armazenadas na tabela “Vark”.

**Figura 36 - Tabelas da BD responsáveis pela representação do questionário ILS e o seu resultado.**

5.6 Resumo

Neste capítulo foram apresentados os diagramas UML, Diagramas de Casos de Uso, Diagramas de Sequência, Diagramas de Atividade e também os modelos Conceptual e Físico que serviram de base para a implementação da arquitetura da plataforma ADAPT, descrita no [Capítulo 6](#).

Deste modo, apresentou-se na [secção 5.1](#) um DCU com o conjunto de interações entre um professor ou um aluno e os módulos que integram a plataforma ADAPT: módulo STI, módulo SGA e módulo de *data mining* e pesquisa local.

Na [secção 5.2](#) ilustrou-se um DA onde são modelados alguns dos processos dinâmicos da plataforma ADAPT nomeadamente as atividades realizadas no processo de geração de um guião adaptado a partir do Guião Base tendo como intervenientes o professor e aluno.

Na [secção 5.3](#) apresentou-se o diagrama de classes onde se efetua a descrição da estrutura da plataforma ADAPT através das suas classes, atributos e relações entre objetos.

Na [secção 5.4](#) descreveu-se um Diagrama de Sequência com a troca de informações entre os vários objetos da plataforma ADAPT no processo de gestão de Guiões Base e gestão dos OA que os compõem assim como a sua adaptação ao perfil do aluno quando este interage com a plataforma.

Por último, na [secção 5.5](#) apresentou-se o modelo da base de dados onde se descreve algumas das tabelas mais importantes e no final ilustrou-se o modelo físico completo.

6 Implementação

Neste capítulo apresentam-se as soluções nas quais se baseou o desenvolvimento da plataforma ADAPT. Tais soluções incluem a escolha da linguagem de programação que mais se adequava aos objetivos pretendidos, a tecnologia de base de dados, as informações necessárias para descrever os objetos de aprendizagem e os *standards* que foram tidos em conta para o efeito. É apresentada também a forma como são criados os guiões dos cursos, as técnicas de inteligência artificial utilizadas na adaptação desses guiões e por último as conclusões retiradas deste capítulo.

6.1 Linguagem de Programação e Tecnologias de Base de Dados

A linguagem de programação *Java* foi a linguagem selecionada para o desenvolvimento da plataforma. Esta é uma linguagem de programação, de alto nível e orientada a objetos. A razão desta escolha deveu-se a três fatores: em primeiro lugar pelo facto de ser uma tecnologia em que o custo é praticamente zero - os editores e ambientes de produção são gratuitos como é o caso do *NetBeans*, *Eclipse*, *Jcreator*, etc., assim como também são gratuitos os Servidores de Aplicação como é o caso do *TomCat*, *Jboss*, *Jetty* entre outros.

Em segundo lugar a portabilidade: por ser uma linguagem interpretada, o *Java* pode ser executado em qualquer plataforma ou equipamento que possua um interpretador *Java*, sem ser necessário proceder a alteração de código e as aplicações podem ser facilmente migradas entre servidores. Esta realidade é possível devido à utilização da *Java Virtual Machine (JVM)* que carrega e executa os programas escritos em *Java*, convertendo o *bytecode* em código executável de máquina.

Em terceiro lugar a facilidade de utilização, documentação existente sobre a linguagem e a sua quota de utilização relativamente elevada: *Java* é a linguagem de programação mais utilizada a nível mundial ([TIOBE Index, 2018](#)).

A nível de base de dados, optou-se também por utilizar ferramentas gratuitas, nomeadamente o *MySQL*. Para interagir com a base de dados foram necessárias duas ferramentas: a primeira foi o pacote de *software XAMPP* que já inclui um servidor de base de dados e a segunda foi o *MySQLWorkbench*, para efetuar a gestão da base de dados bem como para a construção e validação de *queries* utilizadas na plataforma.

O IDE escolhido foi o *NetBeans* pela sua facilidade de utilização e pela disponibilização das ferramentas necessárias.

6.2 Arquitetura do Sistema

Nesta secção descreve-se a arquitetura da plataforma ADAPT, ilustrada na Figura 38. Conceptualmente a plataforma é constituída por três módulos: o módulo SGA, o módulo STI e o módulo *data mining* e pesquisa local.

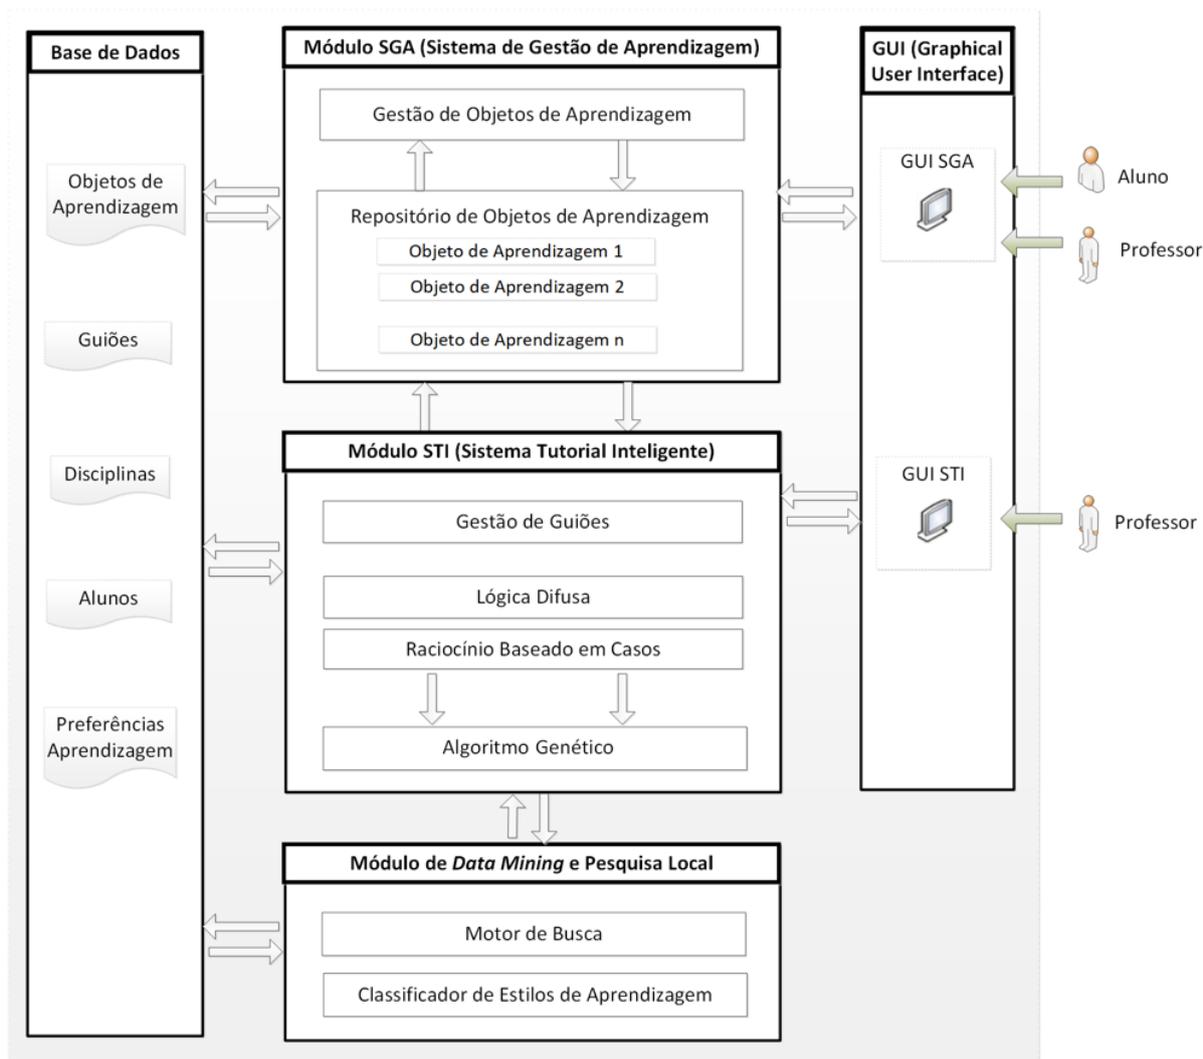


Figura 38 - Arquitetura da plataforma ADAPT.

- O módulo SGA - Sistema de Gestão de Aprendizagem - serve de repositório aos OA que, depois de carregados na plataforma, podem ser catalogados em diferentes categorias por um professor com permissões necessárias. É através do módulo SGA que os alunos acedem aos guiões dos respetivos cursos. Na [secção 6.3](#) do presente capítulo efetua-se uma descrição do módulo SGA e dos OA nele contidos;
- O módulo STI - Sistema Tutorial Inteligente - permite efetuar a criação e gestão de Guiões Base. Este módulo permite aceder aos OA existentes no módulo SGA e com

estes construir os Guiões Base utilizados nas várias disciplinas. Estes guiões são criados pelos professores que possuam permissões de acesso e posteriormente serão adaptados, criando um guião personalizado, para cada um dos alunos de acordo com o seu perfil. A [secção 6.4](#) descreve de forma mais pormenorizada todo este processo assim como as *interfaces* criadas para o efeito. Depois de criados os guiões, são utilizadas técnicas de IA para determinar a melhor forma de os apresentar aos alunos. A lógica difusa é utilizada no mapeamento dos OA com o perfil de aprendizagem dos alunos ([secção 6.5](#)); o Raciocínio Baseado em Casos é utilizado para selecionar guiões utilizados no passado por outros alunos com perfil semelhante ([secção 6.6](#)). Quando o RBC não devolve uma solução considerada satisfatória são utilizados Algoritmos Genéticos ([secção 6.7](#)).

- O módulo *data mining* e pesquisa local contém um motor de busca que efetua a pesquisa de conteúdos alternativos e o classificador de estilos de aprendizagem que deteta alterações no perfil de aprendizagem dos alunos ([secção 6.8](#)).

Todos os módulos são apoiados por uma base de dados que contém informações acerca dos guiões, dos alunos e das preferências VARK, entre outras, e por várias *interfaces* gráficas que permitem a interação entre eles.

6.3 SGA e Objetos de Aprendizagem

Os SGA vieram disponibilizar um alargado número de recursos, incluindo áreas de partilha de conteúdos, fóruns de discussão, salas de *chat*, avaliações, exercícios, testes e questionários (Ioannou e Hannafin, 2008). Como exemplo de um SGA pode considerar-se o Moodle (Moodle, 2017).

No contexto da plataforma ADAPT e de modo a efetuar o processo de adaptação do curso a cada aluno, tornou-se necessário a criação de um vasto leque de OA e de um SGA que permitisse efetuar a sua gestão e apresentação.

A criação dos OA utilizados na plataforma ADAPT foi da responsabilidade do bolsheiro Filipe Azevedo no projeto “Desenvolvimento de Conteúdos para a Plataforma ADAPT”, DEIS-ISEC (Azevedo, 2013). Este projeto consistiu no desenvolvimento de conteúdos educativos relacionados com a disciplina de Sistemas Digitais. Para o efeito foram criados OA em número e em variedade suficiente de modo a poderem ser classificados através do VARK e da taxonomia de Bloom. Os OA são classificados com um valor no intervalo [1,100] para cada

uma das preferências de VARK e no intervalo [1, 6] para a taxonomia de Bloom. Estes OA foram criados com recurso a imagens, textos, áudio e animações. A Figura 39 ilustra um OA que consiste numa animação e que explica o tópico Mapas de Karnaugh da disciplina de Sistemas Digitais.

4. Mapas de Karnaugh

Mapas de Karnaugh
(Grupos de Adjacência Primários)
→ Forma Mínima Soma Produtos

		1	1
		1	1
1	1		

Os grupos nº1 e nº3 são **primários**.

Figura 39 - Exemplo de um OA (Azevedo, 2013).

De modo a permitir a gestão e apresentação dos OA aos alunos procedeu-se à implementação de um SGA. Este SGA foi desenvolvido no projeto “Desenvolvimento de um LMS” (Learning Management System) básico, concebido para suportar as solicitações dos restantes componentes do projeto ADAPT, em particular de um ITS (*Intelligent Tutoring System*) - GECAD/ISEP, bolsheiro Luís Dias.

O SGA desenvolvido neste projeto permite carregar os OA em vários formatos (pdf, jpeg, doc, docx, jar, swf, mp3, mp4) e classificá-los pelas normas SCORM, LOM, preferências VARK e taxonomia de Bloom. Também é o SGA que disponibiliza aos alunos de um determinado curso a visualização dos OA que o constituem, e que são seleccionados pelo módulo STI. A Figura 40 ilustra uma captura de ecrã do SGA onde está a ser apresentado um OA com o formato .swf (animação *flash*) a um aluno que frequenta o 1º semestre do 1º ano, disciplina de Sistema Digitais.

The screenshot displays the ADAPT platform interface. At the top left is the 'ADAPT' logo. The top right corner contains the text 'Avaliar a plataforma' and 'Sair'. On the left side, there is a sidebar with 'Disciplinas' (LEI - 1º ano - 1º semestre) and 'Sistemas Digitais', followed by 'Outras sugestões:' listing several lesson files. The main content area is titled '1.2 - Sistemas Digitais (swf)' and shows a slide titled '1. Introdução' with the heading 'Sistemas Digitais'. The slide features a circuit diagram with a battery, a light bulb, a switch, and an ammeter labeled 'A'. Below the diagram, the text reads 'Os sinais digitais alternam entre dois níveis de voltagem,'. At the bottom of the slide, there are navigation controls: a question mark icon, a search icon, and four numbered buttons (1, 2, 3, 4). Green arrow icons are positioned on the left and right sides of the slide area. The footer contains logos for 'isep Instituto Superior de Engenharia do Porto', 'gecad Grupo de Investigação em Engenharia de Computadores e Aplicações', 'i3ec Instituto Superior de Engenharia de Lisboa', 'utad Universidade de Trás-os-Montes e Alto Douro', and 'FCT Fundação para a Ciência e a Tecnologia'.

Figura 40 - Apresentação de um OA no Sistema de Gestão de Aprendizagem.

Pelo exposto, foi necessário implementar uma forma de comunicação entre o módulo SGA e o módulo STI de modo a que este possa determinar qual o próximo OA a ser visualizado quando o aluno pretende avançar ou recuar no curso. Deste modo quando o SGA pretende apresentar um OA ao aluno tem que invocar um método do STI no qual tem que especificar quatro parâmetros:

- **Id do aluno autenticado na plataforma** - permite saber qual o aluno que está a utilizar a plataforma naquele momento.
- **Id da disciplina** - permite determinar a disciplina a que o guião pertence.
- **Id do guião** - permite obter os OA do guião em questão.
- **Flag de direção do guião** - informa o STI se o aluno pretende avançar ou recuar no guião.

Por sua vez o método do STI invocado pelo SGA retorna um *array* com uma lista de OA identificados pelo seu ID. O primeiro OA do *array* corresponde ao OA a ser apresentado ao aluno. Os restantes OA são os sugeridos pela pesquisa local do módulo *data mining* e pesquisa local e são apresentados na área lateral da *interface* do SGA “Outras sugestões” conforme a Figura 40.

6.4 Criação e gestão de Guiões

Internamente um Guião Base é representado por um grafo. Os nós do grafo contêm os OA da disciplina de um determinado curso. As ligações entre os nós representam os *links* que permitem às páginas desse nó aceder às páginas do nó apontado. Os OA de cada nó contêm a apresentação de um tema através de diversos formatos. Estes OA estão catalogados de acordo com a classificação proposta pelo paradigma VARK e pela taxonomia de Bloom. Inicialmente o professor cria um Guião Base para uma determinada disciplina do curso contendo todo o material de estudo. Posteriormente é analisado o perfil do aluno, e com base nas suas preferências de aprendizagem é determinado o percurso mais adequado, selecionado a partir dos vários percursos possíveis do Guião Base.

Isto significa que pode ser criado um guião individual, adaptado a cada aluno de acordo com as suas preferências de aprendizagem.

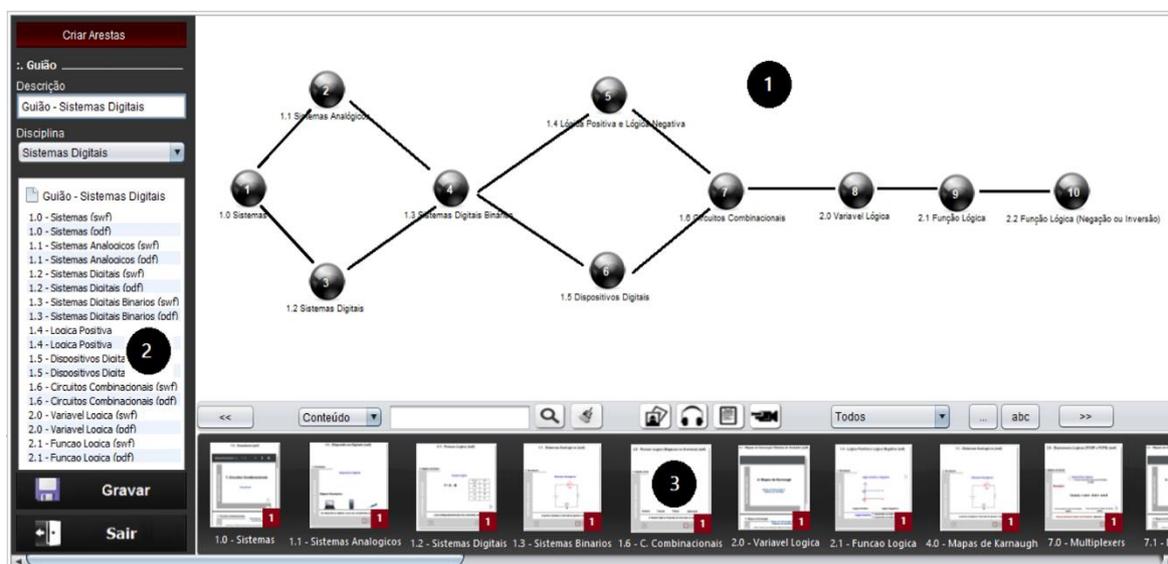


Figura 41 - Interface de Criação/Edição de Guiões.

A fim de permitir a criação, edição e manutenção de guiões, foram implementadas várias interfaces gráficas (GUI). A Figura 41 ilustra a interface gráfica pertencente ao módulo STI que foi desenvolvida de modo a permitir a criação e edição de guiões. A interface está dividida em três áreas principais: (1) é a área onde o professor pode criar a estrutura de um grafo (Guião Base) adicionando os nós necessários onde serão colocados os OA. A criação de *links* entre páginas é possível ao clicar em dois nós consecutivos, criando assim a sequência de navegação. Na área (3) da Figura 41 encontra-se a área de pesquisa de OA. Os OA podem ser pesquisados por nome, por nível taxonómico (taxonomia de Bloom) ou pela classificação dominante do

modelo VARK. Na barra lateral esquerda (2) da Figura 41 apresentam-se os nós do guião e os OA neles contidos. O processo de atribuição de um OA a um nó é efetuado clicando no OA (3) e arrastando-o para o nó de destino (1).

De modo a que todo o processo de gestão de guiões pudesse ser realizado foi necessária a criação de um conjunto de *interfaces* gráficas também elas pertencentes ao módulo STI. A *interface* Pesquisa de Guiões (Figura 42) foi criada para permitir a pesquisa de guiões existentes na base de dados. Esta pesquisa pode ser efetuada pela descrição do guião, pela disciplina à qual o guião pertence, pelo seu estado e pelo tipo de guião. Esta *interface* permite também efetuar a validação e a eliminação de um determinado guião. Possibilita também o acesso direto à *interface* Edição de Guiões através do botão *Novo*.

Descrição Guião	Disciplina	Tipo Guião	Validado
Guião - Sistemas Digitais	Sistemas Digitais	Base	Sim
Guião - Algoritmos e Programação	Algoritmos e Programação	Base	Sim
Guião - Técnicas Avançadas de Programação	Técnicas Avançadas de Programação	Base	Sim
Guião - Análise Matemática I	Análise Matemática I	Base	Não
Guião - Análise Matemática II	Análise Matemática II	Base	Não
Guião - Sistemas Operativos I	Sistemas Operativos I	Base	Sim
Guião - Sistemas Operativos II	Sistemas Operativos II	Base	Sim

Figura 42 - Interface Pesquisa de Guiões.

Outra *interface* desenvolvida foi a Pesquisa de Alunos ilustrada na Figura 43. Esta *interface* permite apresentar e pesquisar alunos, o seu *login*, o número de aluno e o *email*.

Na área inferior são listados os alunos com o Guião Base atribuído que foi selecionado na área central. A atribuição de um Guião Base a um conjunto de alunos é efetuada através do botão *Novo* que efetua a chamada da *interface* de pesquisa de alunos e permite devolver os alunos selecionados para a secção central da *interface* atribuição de guiões. A atribuição do Guião Base aos alunos fica concluída depois de pressionar o botão *Guardar*. A desassociação do Guião Base é efetuada através do botão *Eliminar*.

6.5 Lógica Difusa e Mapeamento de Conteúdos

O mapeamento dos OA de um determinado curso com o perfil do aluno foi realizado com recurso ao *Plug-in Fuzzy Logic Toolbox* (Matlab, 2011) utilizado pela aplicação MatLab R2011a. Este *Plug-in* utiliza a *Fuzzy Control Language* (FCL) na implementação do modelo difuso, que depois de exportado para um ficheiro com extensão *.fcl* pode ser importado para um outro projeto. Este ficheiro contém informações tais como regras, variáveis e respetivos domínios do modelo difuso. A Figura 45 apresenta uma captura de ecrã do ambiente de desenvolvimento com o projeto do módulo STI onde se encontra o ficheiro *ILS.fcl* que possui o modelo difuso utilizado na plataforma ADAPT. De modo a interpretar a FCL foi necessário importar também para o projeto o conjunto de bibliotecas *jFuzzyLogic* que possui vários recursos relacionados com lógica difusa.

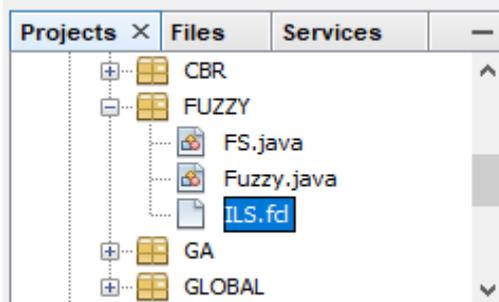


Figura 45 - Ficheiro *.fcl* com o modelo difuso utilizado no ADAPT.

Para cada uma das dicotomias de cada dimensão resultantes do questionário ILS de Felder-Soloman, foi criada uma variável, o que origina um sistema com 8 variáveis de entrada: *Ativo*, *Reflexivo*, *Sensorial*, *Intuitivo*, *Visual*, *Verbal*, *Sequencial* e *Global*. Sendo o objetivo efetuar o mapeamento com a classificação VARK, as variáveis de saída do sistema são caracterizadas por cada uma das dimensões: *Visual*, *Auditivo*, *Leitura/Escrita* e *Cinestésico*.

A Figura 46 apresenta o sistema difuso implementado.

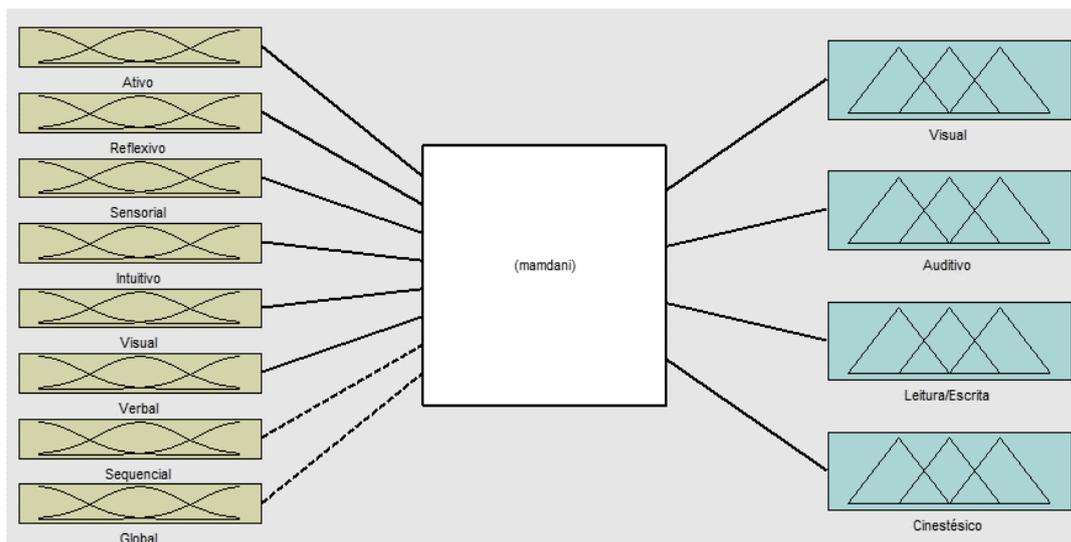


Figura 46 - Sistema Difuso utilizado na plataforma ADAPT (MatLab, 2011).

Para as variáveis de entrada e de saída definiram-se os seguintes termos linguísticos: *Muito Fraco*, *Fraco*, *Médio*, *Forte* e *Muito Forte*. Relativamente aos domínios definiu-se que as variáveis de entrada possuem um domínio compreendido entre [1, 11] e as variáveis de saída possuem um domínio de [1, 100]. A Figura 47 ilustra a variável Ativo e respetivas funções de pertinência.

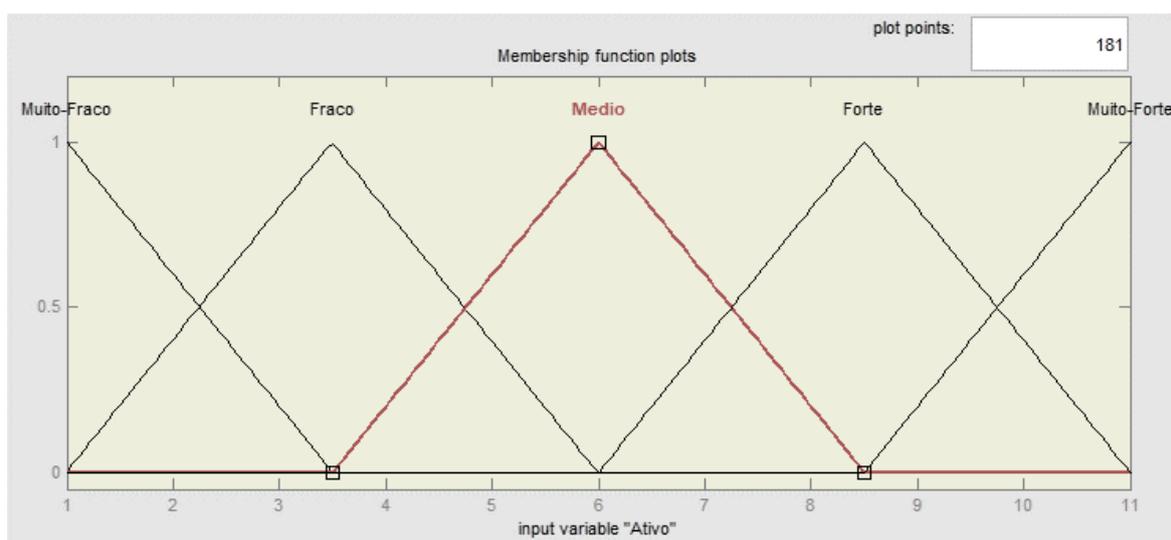


Figura 47 - Variável Ativo e respetivas funções de pertinência (MatLab, 2011).

As regras de inferência do sistema difuso são expressas através de implicações do tipo: **Se** (antecedente) **Então** (consequente). No antecedente podem figurar conjunções e disjunções de termos linguísticos.

O sistema difuso da plataforma possui um total de 75 regras. A Figura 48 apresenta cinco dessas regras.

R1. SE (<u>Ativo</u> é Muito-Forte) E (<u>Reflexivo</u> é Médio) ENTÃO (<u>Leitura/Escrita</u> é Forte)(<u>Cinestésico</u> é Forte)
R2. SE (<u>Ativo</u> é Muito-Forte) E (<u>Reflexivo</u> é Fraco) ENTÃO (<u>Leitura/Escrita</u> é Fraco)(<u>Cinestésico</u> é Muito-Forte)
R3. SE (<u>Sensorial</u> é Médio) E (<u>Intuitivo</u> é Muito-Forte) ENTÃO (<u>Visual</u> é Médio)(<u>Leitura/Escrita</u> é Muito-Forte)
R4. SE (<u>Visual</u> é Fraco) E (<u>Verbal</u> é Forte) ENTÃO (<u>Auditivo</u> é Forte)
R5. SE (<u>Visual</u> é Fraco) E (<u>Verbal</u> é Médio) ENTÃO (<u>Auditivo</u> é Fraco)

Figura 48 - Exemplo de regras do sistema difuso.

Conforme referido, optou-se por escolher a inferência de Mamdani pelo fato de possuir uma representação mais intuitiva e conseqüentemente mais fácil de entender e de manter. A inferência de Sugeno possui um processamento com melhor desempenho (Jassbi et al., 2006), sendo por isso bastante utilizada em sistemas de controlo. Pelo facto do pretendido neste projeto não ser a realização de um controlador, mas sim de um sistema que ocasionalmente determine o grau de pertença de um aluno às dimensões do modelo de estilo de aprendizagem escolhido, não se optou pela inferência de Sugeno.

De forma a exemplificar o modo de funcionamento do sistema difuso, dá-se em seguida um exemplo do mapeamento de conteúdos efetuado através de inferência difusa num aluno cujas respostas ao questionário tiveram como resultado o seguinte perfil: *Ativo*=10; *Reflexivo*=5; *Visual*=4; *Verbal*=9; *Sensorial*=2; *Intuitivo*=8; *Sequencial*=1; *Global*=11.

A primeira etapa é a fuzificação e consiste em determinar o grau de pertença das variáveis de entrada a cada um dos conjuntos difusos.

A Figura 49 representa linhas verticais traçadas a partir dos valores numéricos das variáveis de entrada, que intercetam as funções de pertença dos diversos termos linguísticos. Por exemplo, para a variável *Ativo* o valor 10 a que correspondem valores aproximados de $\mu_{Ativo}(0.7)$ para as regras R1 e R2, e $\mu_{Ativo}(0)$ para as restantes.

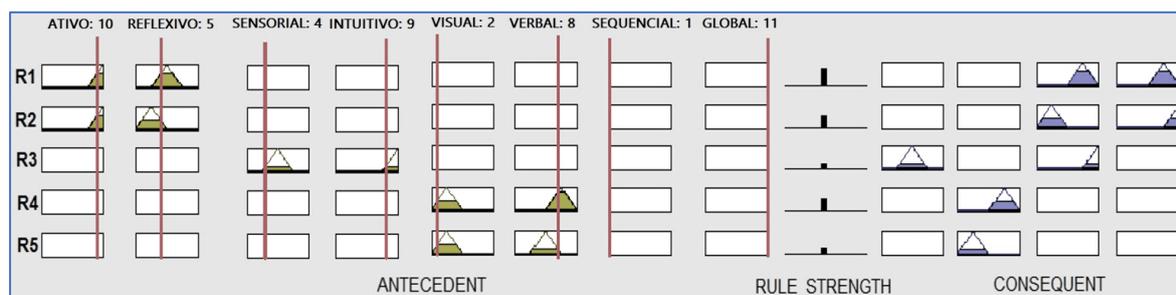


Figura 49 - Processo de inferência difusa (MatLab, 2011).

A etapa seguinte é o processo de inferência que restringirá a função de pertinência do consequente através do seu corte pelo valor de μ para o antecedente de cada regra.

Por isso, e tendo a regra R1 como exemplo, os seus antecedentes possuem o operador (E), o que significa que é considerado o menor grau de pertinência do μ dos seus termos linguísticos. Como os seus antecedentes $\mu_{\text{Ativo}}(0.7)$ e $\mu_{\text{Reflexivo}}(0.7)$ possuem ambos o mesmo valor $\mu=0.7$ é este o valor passado para a variável linguística de saída. No caso da regra R2 com os antecedentes de $\mu_{\text{Ativo}}(0.7)$ e $\mu_{\text{Reflexivo}}(0.5)$ e também com o operador (E) nos antecedentes, é passado para a variável linguística de saída $\mu=0.5$ por ser o menor grau de pertinência.

A próxima etapa é a agregação e consiste em agregar todas as funções de pertinência dos consequentes de cada regra num único conjunto difuso (Figura 50).

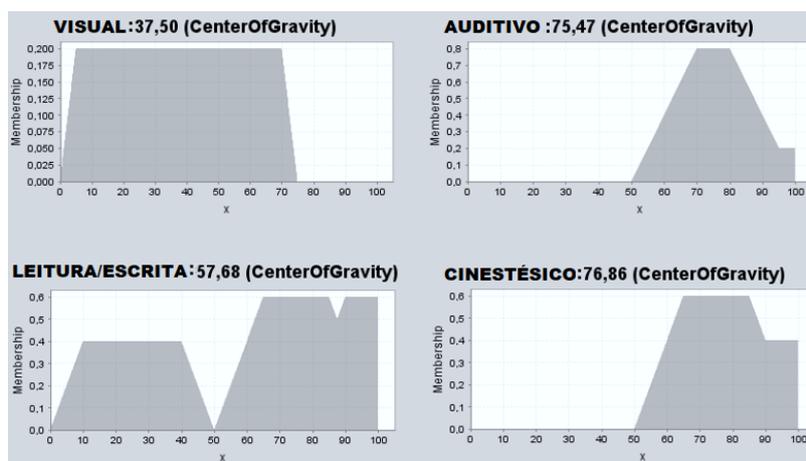


Figura 50 - Conjunto difuso resultante do processo de agregação (MatLab, 2011).

Depois de se obterem as funções de saída, segue-se a “desfuzificação”, em que foi utilizado o método *centroid* conforme a equação (7) na [secção 4.1.5.4](#).

O resultado obtido através da utilização do método centroid nas funções de saída (Figura 50) é: Visual: 37,50; Auditivo: 75,47; Leitura/Escrita: 57,68 e Cinestésico: 76,86.

O passo final consiste em escolher o OA mais adequado e é efetuado comparando este resultado com as características pertencentes ao OA presente num dado ponto do guião. O cálculo é efetuado com a função de avaliação:

$$F = \frac{|Vf - VOA| \times WV + |Af - AOA| \times WA + |Rf - ROA| \times WR + |Kf - KOA| \times WK}{WV + WA + WR + WK} \quad (14)$$

onde:

Vf: valor da preferência difusa Visual do aluno
Af: valor da preferência difusa Aural do aluno
Rf: valor da preferência difusa *Read/Write* do aluno
Kf: valor da preferência difusa *Kinesthetic* do aluno
VOA: valor da preferência Visual do OA
AOA: valor da preferência Aural do OA
ROA: valor da preferência *Read/Write* do OA
KOA: valor da preferência *Kinesthetic* do OA
WV: Peso da preferência Visual
WA: Peso da preferência Aural
WR: Peso da preferência *Read/Write*
WK: Peso da preferência *Kinesthetic*

Os coeficientes *WV*, *WA*, *WR*, *WK* são utilizados para atribuir um peso maior à preferência VARK dominante.

Se por exemplo um OA tiver as preferências: Visual: 25,5; Auditivo: 37,2; Leitura/Escrita: 11,2; Cinestésico: 54,5 e assumindo $WV = WA = WR = WK = 1$ é o seguinte:

$$F = \frac{|37,5 - 25,5| \times 1 + |75,47 - 37,2| \times 1 + |57,68 - 11,2| \times 1 + |76,86 - 54,5| \times 1}{1 + 1 + 1 + 1}$$

$$F = 29,885$$

Neste exemplo, o OA em questão é apresentado ao aluno se não existir no mesmo nó um outro OA para o qual esta função de avaliação retorne um valor mais baixo.

6.6 Raciocínio Baseado em Casos

O processo de aquisição de conhecimento pelo sistema RBC da plataforma foi efetuado em diferentes alturas através de diferentes métodos. Numa fase inicial, e de modo a que o sistema RBC pudesse entrar em funcionamento, foram introduzidos na biblioteca casos criados manualmente. Estes casos, denominados “*seed cases*”, foram também úteis numa fase em que foi necessário a realização de testes funcionais à plataforma. De modo a permitir que a plataforma adquirisse casos com maior qualidade, esta foi disponibilizada a um grupo de alunos inscritos na unidade curricular de Sistemas Digitais pertencente ao Curso de Especialização Tecnológica em “Tecnologia e Programação de Sistemas de Informação” lecionada no

DEIS/ISEC. No contexto da plataforma ADAPT, um caso é representado pela sequência dos OA percorrido pelo aluno, pelo resultado obtido na avaliação final e pelo seu estilo de aprendizagem. Como mencionado anteriormente o paradigma RBC é constituído por quatro etapas. De seguida apresentam-se estas etapas no contexto da plataforma ADAPT:

1) Recuperação

A tarefa principal do processo de recuperação é obter da base de casos o exemplo mais similar ao problema atual. Para esse efeito, efetua-se uma consulta que descreve o problema de acordo com uma medida de similaridade entre os atributos que formam o conjunto dos índices do novo problema e o caso recuperado (Wangenhein, 2000). A indexação corresponde ao processo de catalogação de informação e tem como objetivo facilitar o processo de pesquisa.

No contexto da plataforma ADAPT, a biblioteca de casos é constituída por tabelas existentes na base de dados e os índices são aplicados em vários campos dessas tabelas. Os campos das tabelas da base de dados que foram indexados foram os seguintes:

Vark - visual, aural, readwrite, kinesthetik;

Navegacalog - idNavegacaoLog, idUtilizador, idOA, idGuiiao, idNo;

UtilizadorAvaliacaoFinal - classificacao;

OA - visual, aural, readwrite, kinesthetik.

Os índices criados nas respetivas tabelas da base de dados são ilustrados na Figura 51.

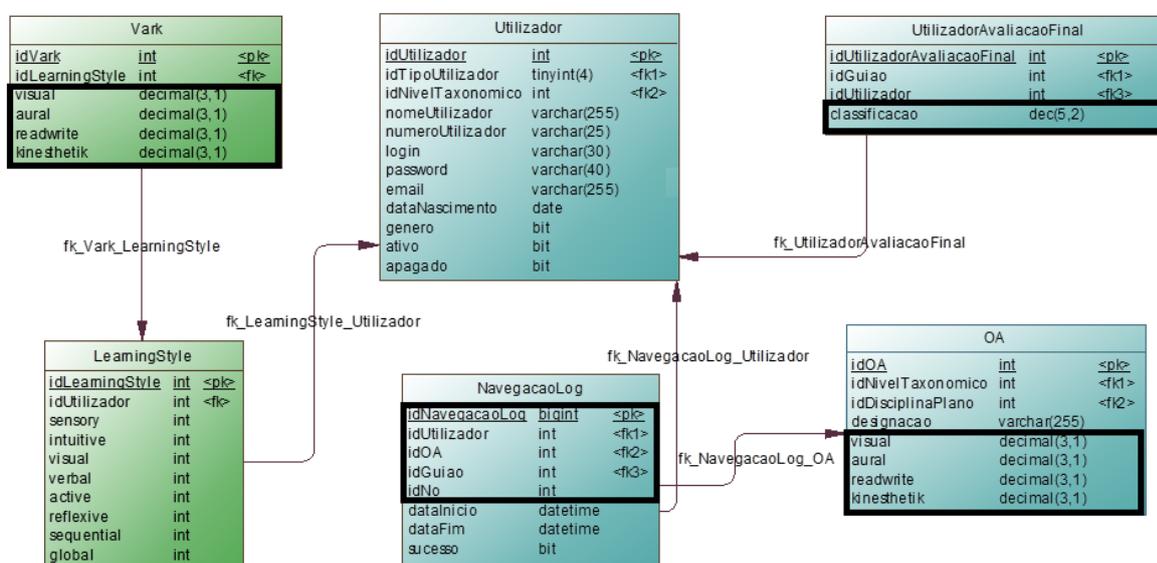


Figura 51 - Índices utilizados no processo de indexação de um caso.

Depois da indexação, o conceito de medida de similaridade é essencial no processo de pesquisa de casos na biblioteca de casos. Estando a biblioteca de casos inserida na base de dados, no desenvolvimento da plataforma optou-se por efetuar a recuperação de casos de forma ordenada através de uma *query* efetuada à base de dados. Esta técnica denominada de *Order-based retrieval* consiste numa abordagem com aplicação em sistemas de recomendação (Bridge e Ferguson, 2002). Este método efetua uma consulta, expressa através de uma *query* em linguagem SQL, para definir e combinar relações com base em critérios de ordenação. O resultado desta consulta tem como finalidade a recuperação dos casos ordenados parcialmente. Esta técnica aplicada na plataforma ADAPT traduz-se na recuperação de casos através de uma *query* SQL (Figura 52) sendo agrupados pelos critérios de ordenação: distância linear entre as preferências VARK do aluno com a totalidade dos OA do guião (distância global) e a classificação final do aluno.

```
String sql = "SELECT DISTINCT(nl.idUtilizador), "
+ "VARKAluno.visual, "
+ "VARKAluno.aural, "
+ "VARKAluno.readwrite, "
+ "VARKAluno.kinestetik, "
+ "notaFinal.classificacao AS classificacaoCurso,\n"
+ "(SUM( (ABS(VARKAluno.visual-oa.visual)*"+Wv+"+"
+ "ABS(VARKAluno.aural-oa.aural)*"+Wa+"+"
+ "ABS(VARKAluno.readwrite-oa.readwrite)*"+Wr+"+"
+ "ABS(VARKAluno.kinestetik-oa.kinestetik)*"+Wk+" )"
+ "/("+Wv+"+"+Wa+"+"+Wr+"+"+Wk+" )"
+ "/OACount.OANum) AS distanciaGlobal\n"
+ "FROM navegacaolog nl, oa, \n"
+ "(SELECT ls.idUtilizador, vark.visual, vark.aural, vark.readwrite, vark.kinestetik "
+ "from vark, learningstyle ls where vark.idLearningStyle = ls.idLearningStyle "
+ "AND ls.idUtilizador = "+idAluno+") AS VARKAluno,\n"
+ "(SELECT COUNT(nl.idOA) AS OANum FROM navegacaolog nl "
+ "WHERE nl.idUtilizador = "+idAluno+" AND UAF.idGuiao = "+idGuiao+") AS OACount,\n"
+ "(SELECT idutilizador, classificacao FROM utilizadoravaliacaofinal UAF "
+ "WHERE UAF.idUtilizador = "+idAluno+" AND UAF.idGuiao = "+idGuiao+") AS notaFinal\n"
+ "WHERE nl.idOA = oa.idOA\n"
+ "AND nl.idUtilizador = "+idAluno+"\n"
+ "AND nl.idUtilizador = VARKAluno.idUtilizador\n"
+ "AND nl.idUtilizador = notaFinal.idUtilizador\n"
+ "AND nl.idGuiao = "+idGuiao+"\n"
+ "GROUP BY nl.idUtilizador\n"
+ "ORDER BY distanciaGlobal ASC, classificacaoCurso DESC";
```

Figura 52 - Query sql utilizada no retorno de casos da biblioteca de casos.

O valor da distância global calcula-se usando a equação (15) incluída na própria *query* realçada, como ponto 1, na Figura 52. Para implementar as equações (15) e (16) foram utilizadas as funções SUM(), ABS() e COUNT() existentes na linguagem SQL e que permitem efetuar o cálculo de um somatório, módulo e contagem, respetivamente.

$$F_{DG} = \frac{F}{n} \quad (15)$$

$$F = \sum_{i=1}^n \frac{|Vf - ViOA| \times WV + |Af - AiOA| \times WA + |Rf - RiOA| \times WR + |Kf - KiOA| \times WK}{WV + WA + WR + WK} \quad (16)$$

De seguida descrevem-se os símbolos utilizados nas equações (15) e (16):

- Vf*: valor da preferência difusa Visual do aluno
- Af*: valor da preferência difusa Aural do aluno
- Rf*: valor da preferência difusa Read/Write do aluno
- Kf*: valor da preferência difusa Kinesthetic do aluno
- VioA*: valor da preferência Visual do OA
- AioA*: valor da preferência Aural do OA
- RioA*: valor da preferência Read/Write do OA
- KioA*: valor da preferência Kinesthetic do OA
- WV*: Peso da preferência Visual
- WA*: Peso da preferência Aural
- WR*: Peso da preferência Read/Write
- WK*: Peso da preferência Kinesthetic
- n*: N.º de OA existentes no caso
- i*: Índice do OA a ser analisado
- F*: Função de Avaliação
- F_{DG}*: Distância global entre o perfil VARK do aluno e as características VARK dos OA pertencentes ao guião

Os coeficientes *WV*, *WA*, *WR*, *WK* são utilizados para atribuir um peso maior à preferência VARK dominante.

A Figura 53 exemplifica o resultado da *query* apresentada na Figura 52. Como se pode observar os casos obtidos estão ordenados de forma ascendente pela distância global e descendente pela nota obtida no final do curso. O resultado da *query* inclui os seguintes atributos: o id do aluno (coluna *idUtilizador*); as preferências VARK do aluno (colunas: *visual*, *aural*, *readwrite*, *kinesthetic*); a classificação obtida no final do curso (coluna: *classificacaoCurso*) e a proximidade VARK do guião com o perfil VARK do aluno (coluna: *DistanciaGlobal*). É de referir que por uma questão de apresentação não estão ilustrados na Figura 53 os OA pertencentes a cada um dos casos.

idUtilizador	visual	aural	readwrite	kinesthetik	classificacaoCurso	distanciaGlobal ▲ 1
374	50.0	10.0	60.0	30.0	17.00	19.485294118
369	40.0	10.0	10.0	10.0	15.00	22.607142857
12	40.0	10.0	60.0	10.0	15.00	27.937500000
39	70.0	30.0	30.0	20.0	12.00	28.250000000
49	40.0	20.0	10.0	20.0	11.00	29.216292135
367	50.0	30.0	80.0	20.0	11.00	29.895833333
360	35.0	50.0	10.0	10.0	12.00	31.590909091
13	70.0	20.0	30.0	50.0	12.00	32.916666667
368	40.0	20.0	60.0	90.0	12.00	35.477941176
361	40.0	10.0	60.0	90.0	13.00	37.500000000
376	60.0	80.0	30.0	50.0	17.00	38.312500000
372	50.0	80.0	30.0	50.0	14.00	39.625000000
41	20.0	70.0	60.0	10.0	10.00	39.891304348
358	70.0	20.0	70.0	90.0	11.00	40.000000000
150	20.0	10.0	60.0	90.0	13.00	40.625000000
35	40.0	80.0	70.0	50.0	16.00	41.250000000
356	35.0	80.0	30.0	40.0	14.00	42.187500000
359	20.0	80.0	10.0	20.0	14.00	43.409090909
375	20.0	30.0	70.0	90.0	10.00	44.309210526
357	40.0	30.0	80.0	50.0	16.00	45.000000000
366	20.0	80.0	30.0	40.0	18.00	45.666666667

Figura 53 – Exemplo do resultado de uma pesquisa de casos.

2) Reutilização

O processo de reutilização no ciclo CBR é responsável por propor uma solução para um novo problema a partir das soluções existentes nos casos recuperados.

Na maioria das situações, reutilizar um caso consiste em devolver a solução recuperada, inalterada, como a solução proposta para o novo problema. Contudo, em situações em que existem diferenças significativas entre o novo problema e o caso recuperado, a solução recuperada pode precisar de ser adaptada.

O processo de verificação que analisa a necessidade de uma solução ter que ser adaptada é efetuado pela equação (15).

Em situações em que o grau de similaridade da solução seja muito distante e ultrapasse um certo limite previamente definido, é executado o algoritmo genético (secção 6.7) de modo a que este proceda à otimização da solução. Este limite é definido programaticamente no módulo de algoritmos genéticos. Como possível exemplo podem considerar-se as preferências VARK do perfil do aluno e dos OA expressas no intervalo [1, 100]. Se $F_{DG} = 30$, e o limiar de distância for $L=25$, a partir do qual o AG seria chamado, então o módulo com o algoritmo genético seria chamado para proceder a uma otimização do guião, ou seja, para realizar uma adaptação da solução inicialmente encontrada.

3) Revisão

O objetivo da fase de revisão consiste em efetuar a avaliação da solução criada na fase anterior. A avaliação pode ser efetuada por um utilizador do sistema, por meio de uma simulação ou através da aplicação da solução num ambiente real.

Na plataforma ADAPT a fase de revisão pode ser feita por um professor com conhecimento específico do domínio, em que através de uma *interface* gráfica tem a possibilidade de avaliar a solução, medir a sua qualidade, efetuar as alterações e reparos que entender. A verificação final da solução é completada, naturalmente, durante a execução ou término do guião. Apenas as soluções marcadas pelo professor como válidas são utilizáveis.

4) Retenção

A fase de retenção completa o ciclo RBC e constitui o processo em que a solução é incorporada na biblioteca de casos para futura utilização. É nesta fase que o sistema RBC “aprende”. Terminada a execução de um guião, este é potencialmente armazenável. No entanto, para isso tem que ser explicitamente validado pelo professor, ou corresponder a um caso de sucesso de um aluno. Naturalmente que ao longo do tempo serão gerados casos que não têm interesse em ser armazenados. Exemplos possíveis são aqueles em que o aluno obteve uma má avaliação final ou casos repetidos porque foram sugeridos com base em casos anteriores sem ter havido necessidade de efetuar qualquer adaptação. Para lidar com situações deste tipo a plataforma ADAPT possibilita a manutenção de casos armazenados.

6.7 Algoritmos Genéticos

A plataforma ADAPT utiliza um AG quando a solução devolvida na segunda fase do ciclo RBC (reutilização) não é considerada satisfatória, procedendo à sua adaptação. Esta adaptação consiste numa otimização, efetuada através da substituição dos OA do guião original de modo a aumentar a similaridade entre o estilo de aprendizagem do aluno e a classificação VARK dos conteúdos.

Atualmente, o AG utiliza os OA recomendados na pesquisa local efetuada pelo motor de busca na exploração de novas soluções. Futuramente, será utilizado na procura de novas soluções resultantes de uma pesquisa global estendida até ao domínio da *Internet*.

No decorrer da navegação de um guião podem ser apresentados ao aluno OA contidos noutros Guiões Base que podem ter sido sugeridos pelo motor de busca ([secção 6.8.1](#)) quando este

sugere conteúdos alternativos aos que o aluno está a visualizar no momento, ou quando foi detetado uma alteração no perfil de aprendizagem do aluno pelo classificador de estilos de aprendizagem (secção 6.8.2) passando a navegação a ser definida pelo motor de busca. Em ambas as situações, ao efetuar uma pesquisa local com base em parâmetros como a média das notas dos alunos que consultaram os OA e o seu tempo de visualização médio, o motor de busca ao não estar limitado aos OA do Guião Base, pode selecionar OA de outros Guiões Base pertencentes à mesma ou a outras disciplinas. Como exemplo, pode considerar-se o caso de existirem outras disciplinas em que o Guião Base contenha conteúdos considerados relevantes dado a sua proximidade com o tema que o aluno está a seguir no momento: a um aluno que esteja a seguir o guião da disciplina de Sistemas Digitais ser-lhe sugerido um OA pertencente ao Guião Base da disciplina de Eletrónica pelo facto de o tema ser semelhante e também porque os alunos que consultaram o OA em questão obtiveram um bom desempenho.

Posteriormente, com a realização das alterações ao motor de busca da plataforma ADAPT previstas para trabalho futuro (secção 6.8.3) e que consistem na integração da API do motor de busca da Google (*Google Custom Search*, 2018) vai permitir que a pesquisa de OA deixe de ser exclusivamente local e passe a ter um carácter mais global ao utilizar a *Internet* como espaço de procura. Esta pesquisa global vai permitir abranger um leque consideravelmente maior de soluções possíveis sendo necessário um algoritmo que as consiga determinar e avaliar a sua qualidade.

As situações mencionados anteriormente tornam a utilização de um AG um método eficaz no processo de adaptação de um guião, dado permitir encontrar novas soluções e possibilitar a criação de sequências de navegação que possam ainda não ter sido exploradas e deste modo obter uma solução que possua uma qualidade superior.

No processo de otimização efetuado pelo AG, atualmente são consideradas apenas as preferências VARK e não as taxonomias de Bloom pelo facto de no período de desenvolvimento da plataforma ADAPT não estarem ainda disponíveis OA com níveis taxonómicos diferentes que pudessem ser utilizados.

Os cromossomas utilizados no AG são constituídos pela sequência de id dos OA pertencentes ao guião. A Figura 54 ilustra um exemplo de um cromossoma:



Figura 54 - Exemplo de um cromossoma.

A população inicial é obtida pela ordenação de N soluções candidatas que foram obtidas na fase *Retrieve* do ciclo RBC, sendo N definido na *interface* Configurações de Algoritmos Genéticos. De seguida é iniciado um processo iterativo em que é utilizada a função de avaliação representada pela equação (15) para medir a qualidade dos indivíduos. Posteriormente, a seleção é outra etapa do algoritmo que é executada a seguir à avaliação. Na plataforma ADAPT, é utilizado o método de seleção por torneio sendo selecionados 2 indivíduos para cada torneio, sendo o mais apto selecionado. O passo seguinte consiste no processo de recombinação.

A mutação, representada na Figura 55, é utilizada para modificar aleatoriamente um ou mais pontos do guião através da substituição de um OA por outro diferente.

Neste processo todos os OA têm uma probabilidade pequena de serem alterados. Para esse fim gera-se um valor aleatório para cada OA para determinar se o objeto vai sofrer a mutação. Na Figura 55 ilustra-se o operador de mutação onde apenas o segundo elemento sofre a mutação. Assim, o OA é substituído pelo OA 19 formando assim o novo guião. De salientar que os OA que podem substituir o OA selecionado tem de pertencer ao mesmo nó no Guião Base.

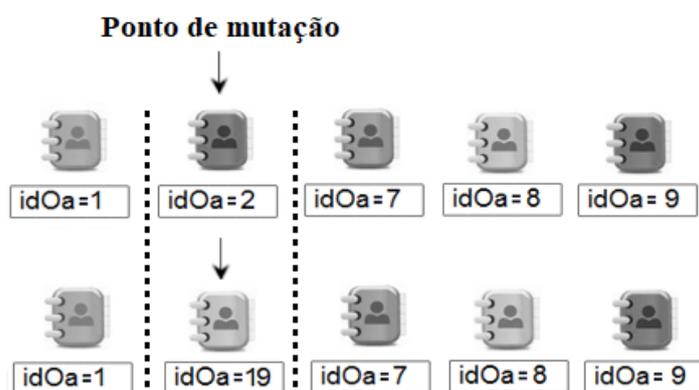


Figura 55 - Exemplo do operador genético Mutação.

A Figura 56 descreve o operador genético de cruzamento multiponto utilizado pela plataforma. Os OA assinalados pelos pontos de cruzamento, selecionados aleatoriamente, serão trocados entre os guiões progenitores. Assim, o primeiro descendente será formado pelo material inicial do primeiro guião, o material intermédio do segundo indivíduo e pela parte final do indivíduo 1. O descendente 2 será formado pelo material restante. Este operador é responsável pela

recombinação de características dos progenitores durante o processo de reprodução, permitindo que as próximas gerações herdem essas características.

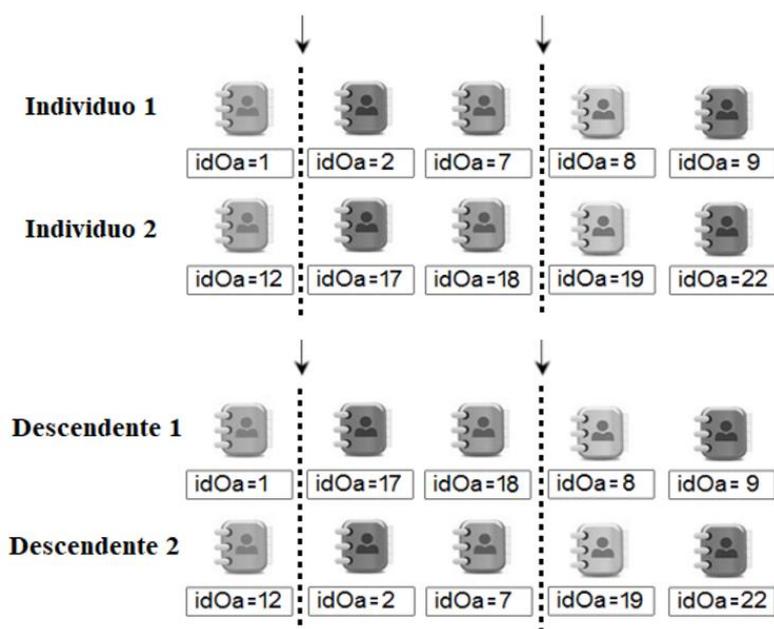


Figura 56 - Exemplo do operador genético Cruzamento em dois pontos.

O processo termina com o retorno da melhor solução encontrada depois de o algoritmo ter realizado N iterações. A Figura 57 ilustra a *interface* gráfica que permite configurar os parâmetros utilizados pelo algoritmo genético da plataforma:

Configurações

Configurações Algoritmos Genéticos:

População Inicial: Operador Mutação(%)

Nº de Iterações: Operador Cruzamento(%)

Nº de Cortes:

Figura 57 - Interface para introdução de parâmetros dos Algoritmos Genéticos usados no ADAPT.

6.8 *Data Mining* e pesquisa local

Esta secção descreve a implementação das funcionalidades dos módulos de *data mining* e pesquisa local e o classificador de estilos de aprendizagem. Para efetuar a pesquisa local de conteúdos alternativos foi desenvolvido um motor de busca (secção 6.8.1) que permite sugerir a cada aluno os melhores conteúdos complementares, partindo de parâmetros sociais tais como a média das notas dos alunos que consultaram os artigos e o seu tempo de visualização médio. Para detetar alterações no perfil do aluno procedeu-se ao desenvolvimento de um classificador de estilos de aprendizagem (secção 6.8.2) que avalia se um aluno tem vindo a alterar o seu estilo de aprendizagem. Em caso afirmativo, é sugerido o ajuste do guião que ele está a seguir.

Por fim, na secção 6.8.3 apresentam-se as alterações ao módulo de *data mining* e pesquisa local, a implementar no futuro, de modo a que a pesquisa de conteúdos deixe de ser realizada de forma exclusivamente local passando a ter uma componente mais global.

O motor de busca e o classificador de estilos de aprendizagem fazem parte do módulo de *data mining* e pesquisa local tendo sido desenvolvido no projeto "Sistema de Recomendação Inteligente para uma Plataforma de *E-learning*" - DEIS-ISEC, bolseiro Pedro Neves.

6.8.1 Motor de busca

Os motores de busca implementam algoritmos próprios, mas o seu modo de funcionamento básico é algo semelhante, recorrendo a algoritmos de indexação e pesquisa.

A indexação corresponde ao processo de catalogação da informação e é necessária para que a pesquisa seja mais rápida e simples de efetuar. A indexação dos OA efetuada por este módulo foi desenvolvida com base no método de indexação da *framework* Lucene, utilizando os métodos *IndexWriter* e *Document* (Lucene, 2013). Os campos da base de dados que foram indexados pertencem às tabelas “OA” onde são guardados os dados descritivos de cada conteúdo; tabela “OADetalhe” onde são guardados os detalhes de cada conteúdo; tabela “NavegacaoLog” que regista o tempo de visualização de um OA por um determinado aluno; a tabela “UtilizadorAvaliacaoFinal” que regista a nota obtida por cada aluno. Os campos indexados e respetivas tabelas são ilustrados na Figura 58 e permitem determinar o id, pontuação média e tempo médio de navegação de cada OA (em segundos). Esta informação em conjunto com os índices fornecidos pelo *Lucene* formam os índices deste motor de busca.

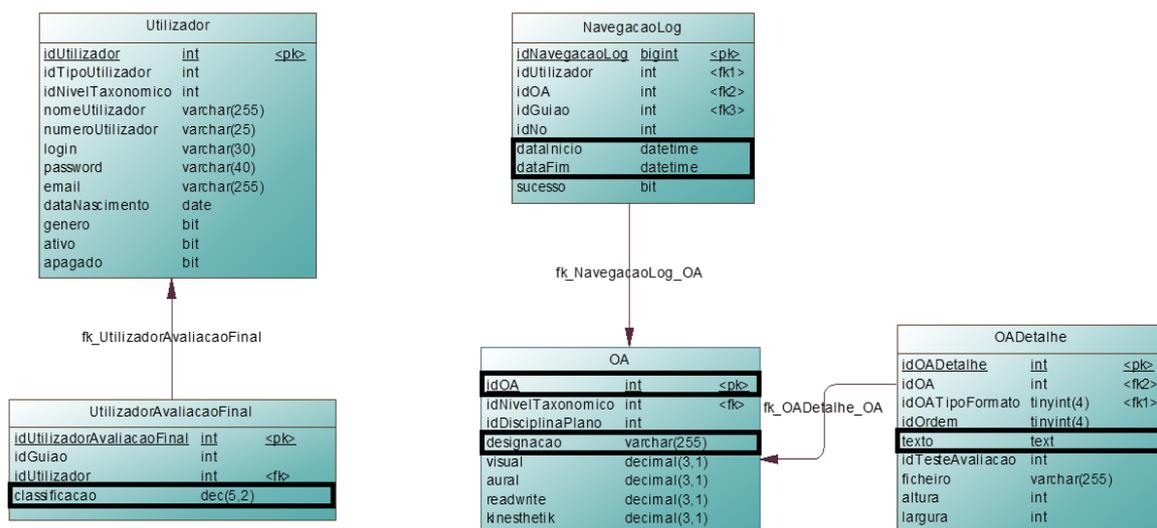


Figura 58 - Campos utilizados na indexação e respectivas tabelas.

O processo de pesquisa consiste na procura de informação sobre os índices criados e é efetuado em dois passos: a construção da *query* de pesquisa e a procura de informação relevante nos índices de acordo com a *query* em questão.

A construção da *query* é efetuada através de técnicas de *text mining* nas quais se incluem *N-Grams* e *Stemming*.

N-Gramming é o processo de subdivisão de uma determinada frase em várias palavras originando várias combinações possíveis. No algoritmo de *N-Gram*, N pode tomar qualquer valor no intervalo de $[1, +\infty[$. Deste modo é possível obter-se *1-Gram* (*Unigram*), *2-Gram* (*Bigram*), *3-Gram* (*trigram*), ..., *N-Gram*. Aplicando o algoritmo *N-Gram* com N igual a 3 na frase: “Simplificação Funções teoremas” o resultado obtido é o seguinte:

Tabela 13 - Exemplo de utilização N-Grams (Neves, 2014).

<i>Queries geradas</i>
Simplificação
Simplificação funções
Simplificação funções teoremas
Funções
Funções teoremas
Teoremas

A implementação de algoritmos de *N-Gramming* é fundamental uma vez que permite abranger uma maior quantidade de combinações de palavras. Este algoritmo permite a criação de várias *queries* que poderão fazer sentido utilizar, uma vez que estas combinações são compostas por

palavras provenientes da frase original (Neves, 2014). Outro algoritmo utilizado foi o *Stemming* que consiste na técnica de redução das palavras à sua raiz e eliminação de plurais. Por exemplo, utilizando a palavra “muitíssimo”, o resultado obtido a partir do algoritmo é “muito”. Após a criação destas *queries*, as mesmas são adicionadas a uma *boolean query* (Lucene API) – *query* que verifica de forma binária se um termo se encontra ou não num texto – que será utilizada posteriormente pela *framework Lucene* como objeto de pesquisa.

Os OA devolvidos pelo *Lucene* como “*match*” sofrem uma ordenação segundo os seguintes parâmetros (Neves, 2014):

- **Similaridade de Cosseno** - Esta medida representa a semelhança entre dois vetores de documentos, medindo o cosseno do ângulo entre si. Neste caso esta medida calcula a distância entre um termo de uma *query* e um documento (nome e descrição de um OA presente na base de dados). Este valor é calculado pela *framework Lucene* segundo a fórmula (Lucene, 2013):

$$\text{Score}(q, d) = \text{Coord}(q, d) \times \text{QueryNorm}(q) \times \sum_{t \text{ em } q} \text{tf}(t \text{ em } d) \times \text{id}(t)^2 \times t.\text{GetBoost}() \times \text{Norm}(t, d) \quad (17)$$

em que:

- **Coord(q,d):** fator de coordenação que permite definir se um documento tem de fazer *match* com todos os termos de uma *query* multitermo ou não;
- **QueryNorm(q):** fator normalizante que não afeta o score, visto que todos os documentos são multiplicados pelo mesmo valor;
- **tf(t em d):** frequência dos termos, i.e. número de vezes que o termo t aparece no documento d;
- **id(t):** Número de documentos onde o termo aparece;
- **t.GetBoost():** importância do termo na *query*;
- **Norm(t,d):** encapsula alguns fatores normalizantes como por exemplo a normalização do tamanho do parágrafo (caso se aplique) e a potenciação (importância) de um dado termo;

- **Pontuação do Conteúdo** - Média das notas de todos os alunos que consultaram o OA. Esta pontuação pode ser zero, uma vez que o OA pode ou não ter sido consultado ou ser consultado por alunos que ainda não foram avaliados;
- **Tempo de consulta** - Média do tempo de consulta do OA por parte de todos os utilizadores da plataforma. O tempo de consulta pode ser zero, significando assim que o OA ainda não foi consultado;
- **Estilo de aprendizagem do OA** - Um OA do mesmo estilo de aprendizagem do aluno é mais importante que um que seja diferente. Assim, um OA de estilo diferente do aluno verá a sua pontuação penalizada em 50% face a um que seja do mesmo estilo;

A ordenação dos resultados de uma pesquisa é efetuada tendo em conta os seguintes critérios:

1. Ordenação dos OA pelo seu valor de similaridade de cosseno: assim, obtêm-se primeiramente os OA que estão mais próximos do OA que o utilizador está de momento a consultar;
2. Em caso de empate dos valores da similaridade de cosseno de vários OA, o critério de desempate utiliza uma fórmula que relaciona os valores da pontuação, tempo de navegação e estilo de aprendizagem predominante do OA. A fórmula utilizada na criação da pontuação final para um artigo é a seguinte:

$$PontuaçãoFinal = \frac{Q1 \times OATempoNavegacao + Q2 \times OAPontuacao}{Q1 + Q2 + EstiloAprendizagem} \quad (18)$$

O parâmetro estilo de aprendizagem pode tomar os valores 0 ou 1 consoante este seja ou não do mesmo estilo de aprendizagem do aluno, penalizando assim os artigos de estilo de aprendizagem diferentes ao do aluno, face aos OA do mesmo estilo de aprendizagem.

Através da junção dos dois parâmetros obtém-se um bom resultado pois se a pontuação (OAPontuacao) e o tempo de navegação do OA (OATempoNavegacao) forem altos, o OA terá uma boa qualificação, e se forem baixos terá presumivelmente uma baixa qualidade ou interesse. A junção dos dois parâmetros traz algum balanceamento à escolha, tornando-a menos drástica (Neves, 2014).

Quando o módulo STI da plataforma ADAPT necessita de invocar o motor de busca, tem de especificar cinco parâmetros (Neves, 2014):

Frase a pesquisar - Corresponde à pesquisa a efetuar;

Linguagem - Corresponde à linguagem na qual a pesquisa será feita. Este parâmetro é essencial para saber que língua deve ser considerada ao efetuar o *stemming* da frase de pesquisa;

Coefficiente Q1 - Corresponde ao coeficiente a multiplicar pelo tempo de consulta;

Coefficiente Q2 - Corresponde ao coeficiente a multiplicar pela pontuação;

Id do aluno autenticado na plataforma – Permitirá identificar o aluno e o seu estilo de aprendizagem para o qual a sugestão de novos OA será feita.

Ao invocar o motor de busca passando-lhe uma determinada frase como parâmetro, este devolverá sempre resultados. Isto porque a pesquisa é efetuada com base no OA que o utilizador está a visualizar no momento da invocação e portanto, pelo menos um resultado será sempre mostrado. Os resultados devolvidos são apresentados aos alunos sob a forma de *links* que apontam para os OA, permitindo ao aluno navegar para o conteúdo que desejar (Neves, 2014).

6.8.2 Classificador de estilos de aprendizagem

Um aluno pode sofrer alterações no seu estilo de aprendizagem ao longo do tempo. Uma pessoa que no passado preferia aprender através de conteúdos ricos em imagens e animações, pode começar a favorecer conteúdos com uma predominância mais marcada da componente leitura. De modo a permitir detetar e atuar em situações como esta, procedeu-se ao desenvolvimento de funcionalidades que permitissem dotar a plataforma ADAPT com um mecanismo de verificação de modificação de estilo de aprendizagem.

Para isso, o módulo de *data mining* tira partido da classificação de cada OA nas quatro dimensões do modelo VARK, verificando se o perfil de aprendizagem de cada aluno está em concordância com os conteúdos que ele tem consultado nas semanas antecedentes. Se não estiver em concordância, o módulo alerta para esse facto e sugere ao STI do sistema ADAPT uma adaptação do guião do curso para aquele indivíduo (Neves, 2014).

IDUSER	VISUAL	AURAL	READWRITE	KINESTHETIK	TempoPermanecidoNoLink	BLOOM
26	50.0	0.0	30.0	20.0	4500	6
26	0.0	99.9	0.0	0.0	36482	5
26	50.0	0.0	30.0	20.0	1986	6
26	30.0	0.0	20.0	50.0	4080	3
26	35.0	0.0	30.0	35.0	1206	5
26	50.0	50.0	0.0	0.0	1380	4
26	15.0	0.0	90.0	50.0	7800	1
27	65.0	0.0	50.0	30.0	30780	3
27	50.0	0.0	30.0	20.0	5100	6

Figura 59 - Exemplo dos resultados obtidos pela query SQL (Neves, 2014).

O primeiro passo deste algoritmo consiste em efetuar uma *query* SQL que determina quais os OA consultados por cada aluno. Uma consulta implica um tempo de permanência mínimo de 2 minutos no OA em questão e por um período de X semanas, sendo X definido na chamada do módulo, e obtendo-se informação do tipo da representada na Figura 59.

Depois de obter os resultados da *query* anterior, determina-se o EA predominante de cada OA, que é calculado com base no parâmetro VARK mais elevado. Neste exemplo, o primeiro OA consultado terá a classificação de *visual*, o segundo OA será auditivo e assim sucessivamente. Os OA consultados por cada aluno são separados por estilo de aprendizagem e os parâmetros “TempoPermanenciaLink” (tempo de consulta do OA) e “Bloom” (classificação do OA de acordo com as taxonomias de Bloom) são somados ao contador de OA de cada estilo de aprendizagem para cada aluno de acordo com a equação (19) (Neves, 2014):

$$M_i = \sum_{j=0}^l (TempoPermanenciaLink \times Bloom) \quad (19)$$

em que:

M_i - Valor da pontuação para a preferência VARK “*i*”.

l - Número de artigos que o aluno consultou da preferência VARK “*i*”;

j - Iterador de artigos consultados pelo aluno para a preferência VARK “*i*” ;

i - Preferência VARK. Pode tomar o valor de visual, auditiva, leitura/escrita, cinestésico;

O valor de M_i dado pela equação (19) corresponde à contribuição “M” do OA “*j*” para a preferência VARK “*i*” de cada aluno. Desta equação resultam as novas preferências VARK do aluno obtidas através da multiplicação do “TempoPermanenciaLink” e “bloom” de cada OA consultado (Neves, 2014). Ambos os parâmetros “TempoPermanencia” e “bloom” são normalizados e surgem porque é importante analisar o tempo de permanência no *link*, que pode ser influenciado pelo grau de dificuldade do mesmo (Neves, 2014).

O passo final do algoritmo consiste em verificar se o estilo de aprendizagem de cada aluno está de acordo com os tipos de OA predominantes que este consultou durante as X semanas anteriores. No caso de não estarem de acordo com o seu estilo de aprendizagem, é sugerido ao STI da plataforma ADAPT uma adaptação do guião do curso segundo os novos parâmetros VARK do aluno. O novo estilo de aprendizagem do aluno é dado por M_j ($w\%$ *visual*, $x\%$ de *auditiva*, $y\%$ de *leitura/escrita* e $z\%$ de *cinestésico*) calculados segundo a equação (19). O classificador de estilos de aprendizagem é ativado periodicamente e devolve ao módulo STI da plataforma um array da classe “Utilizadores” que tem como atributos o id de cada aluno e os novos parâmetros VARK do utilizador. Por sua vez, o módulo STI recebe este array e efetua uma atualização na base de dados dos atributos VARK pertencentes aos alunos em que se detetou a alteração do seu estilo de aprendizagem.

6.8.3 Trabalho futuro

Atualmente o motor de busca existente na plataforma ADAPT efetua uma pesquisa local no próprio Guião Base ou noutros Guiões Base que possuam conteúdos que estejam de alguma forma relacionados, fazendo com que a pesquisa de novos OA e consequentemente de novas soluções seja limitada. Para superar esta limitação está previsto efetuar uma pesquisa global por forma a estender o alcance da pesquisa ao espaço da *Internet* onde é possível encontrar novos conteúdos, ampliando desta forma o número de soluções possíveis.

Esta pesquisa global será efetuada através da utilização da [API Google Custom Search \(2018\)](#) que permite exibir, refinar, categorizar e criar mecanismos de pesquisa personalizados com base no motor de pesquisa da Google.

Esta API está disponível em várias linguagens de programação (Python, Javascript, C#, Java, etc.) sendo neste caso utilizada a biblioteca [Google API Client Library for Java \(2018\)](#) que depois de importada para o projeto do ADAPT permitirá obter de forma programática os resultados de uma pesquisa no Google.

A *query* utilizada nessa pesquisa seria a descrição do OA que o aluno estivesse a consultar naquele momento e seriam selecionados para recomendação os primeiros resultados devolvidos pela pesquisa Google que seriam sugeridos em conjunto com os OA devolvidos na pesquisa local. No caso do aluno aceitar a recomendação e aceder ao OA sugerido este é copiado para o SGA da plataforma ADAPT, caso ainda não exista uma cópia, onde ficará sinalizado como não catalogado. Posteriormente a catalogação será efetuada por alguém com as respetivas

permissões de acesso ao SGA. Só os OA catalogados com VARK serão tidos em consideração na criação de novos guiões pelo AG.

A integração da capacidade de efetuar uma pesquisa global constitui uma mais-valia importante, uma vez que permite a recomendação de novos OA que possam ter um impacto positivo no processo de aprendizagem do aluno e conseqüentemente na sua avaliação final.

6.9 Resumo

No presente capítulo apresentou-se a arquitetura da plataforma ADAPT (secção 6.2), os módulos que a compõem, o seu propósito e a forma como interagem entre si.

O módulo SGA criado para gerir e apresentar os OA que fazem parte dos guiões apresentados aos alunos foi integrado na plataforma tendo sido sujeito a testes funcionais e de integração. Os OA foram carregados no SGA que permite a sua catalogação pelas normas SCORM, LOM, preferências VARK e taxonomia de Bloom (secção 6.3).

O módulo STI possui um conjunto de *interfaces* gráficas para criar e editar guiões que depois de concluídos podem ser atribuídos a alunos que os vão seguir (secção 6.4). De modo a possibilitar a escolha do guião a apresentar é utilizado um sistema difuso que determina a preferência VARK de um aluno com base no questionário ILS de Felder-Soloman. Posteriormente é efetuado o mapeamento dos OA catalogados com as preferências VARK existentes no módulo SGA com base na similaridade com o perfil VARK do aluno (secção 6.5).

Os guiões a apresentar são retirados da base de casos do sistema RBC da plataforma ADAPT que com base na similaridade das preferências VARK dos OA em relação à preferência VARK do aluno devolve o guião mais adequado (secção 6.6). Quando o grau de similaridade média obtida é igual ou superior ao limite máximo definido na plataforma são utilizados algoritmos genéticos na otimização do guião (secção 6.7).

De modo a complementar o processo de aprendizagem oferecido pela plataforma foi desenvolvido o módulo *data mining* e pesquisa local. Este módulo utiliza um motor de busca (secção 6.8.1) que pesquisa conteúdos alternativos para apresentar ao aluno recorrendo a técnicas de *text mining*. Outra funcionalidade consiste na monitorização e deteção de alterações no perfil de aprendizagem do aluno efetuada pelo módulo classificador de estilos de aprendizagem. Esta funcionalidade recorre a técnicas de *link mining* que com base nos *links*

accedidos pelo aluno e no seu tempo de permanência em cada OA consegue detetar alterações nos padrões de aprendizagem (secção 6.8.2). Por último, na secção 6.8.3 foi identificado o trabalho futuro necessário realizar para modificar o motor de busca de modo a que este possa efetuar uma pesquisa com um alcance global ao utilizar a *Internet* como espaço de procura de novos OA.

O funcionamento conjunto dos módulos apresentados, em simultâneo com as técnicas de IA descritas anteriormente, permite a apresentação de um curso personalizado e adaptado à forma de aprender de cada aluno sendo este o desígnio e o objetivo principal da plataforma ADAPT.

7

Avaliação da Plataforma ADAPT

No presente capítulo são apresentados os resultados da avaliação da plataforma ADAPT. Na secção 7.1 é efetuada uma análise estatística do desempenho dos alunos que utilizaram a plataforma e na secção 7.2 são descritos os testes de usabilidade e os respetivos resultados.

7.1 Análise estatística dos resultados obtidos

O processo para avaliar o papel da plataforma na aprendizagem realizou-se no Departamento de Engenharia Informática e Sistemas do Instituto Superior de Engenharia de Coimbra utilizando duas turmas de anos distintos, que frequentaram a unidade curricular de Sistemas Digitais do Curso de Especialização Tecnológica (CET).

Esta avaliação teve como objetivo o de confirmar a hipótese de que “a utilização da plataforma ADAPT como ferramenta de apoio ao processo de aprendizagem contribuiu para que os alunos alcancem melhores resultados”. Desta forma, a avaliação foi realizada durante 2 anos letivos onde se utilizou a plataforma ADAPT em apenas um desses anos. A turma do ano letivo 2012/2013 que utilizou a plataforma ADAPT foi denominado de grupo experimental. Por outro lado, a turma do ano letivo 2013/2014 que não utilizou a plataforma ADAPT foi designada por grupo de controlo. A utilização de dois grupos em anos letivos diferentes possui a vantagem de permitir um maior controlo sobre os alunos que utilizam a plataforma e também o de permitir a utilização de amostras maiores no processo de análise estatística.

No processo de avaliação foi efetuada uma análise univariada que incluiu vários métodos de Estatística Descritiva. Uma análise univariada considera um conjunto de dados com amostras dos dois grupos distintos, onde cada uma das amostras possui um conjunto de variáveis em que o objetivo consiste em extrair as diferenças que melhor diferenciem estes dois grupos. Estas diferenças podem ser encontradas estatisticamente efetuando comparações de cada amostra variável a variável, ou seja, através de uma análise univariada (Friston et al.,1995).

Neste caso, as variáveis que se pretendem medir são as notas das duas turmas de alunos com o objetivo de determinar se existiram diferenças significativas resultantes da utilização da plataforma ADAPT. No processo de análise foram utilizadas medidas de tendência central como a média e a mediana e medidas de dispersão como a variância e o desvio padrão. A Figura 60 ilustra o gráfico com as frequências das classificações finais dos alunos que utilizaram a plataforma ADAPT, ou seja, o grupo experimental.



Figura 60 - Frequências das notas finais da unidade curricular se Sistemas Digitais (2012/2013).

No gráfico apresentado na Figura 60 pode verificar-se que existiram 2 alunos com nota final de 10 valores, 2 alunos com 11 valores, 3 alunos com 12 valores, 2 alunos com 13 valores, 4 alunos com 14 valores, 5 alunos com 15 valores e 3 alunos com 16 valores somando um total de 21 alunos. A análise estatística efetuada na Figura 60 é resumida na Tabela 14.

Tabela 14 - Análise estatística (Grupo experimental)

	Resultados
<i>Número de alunos</i>	21
<i>Média</i>	13
<i>Mediana</i>	14
<i>Variância</i>	3,76
<i>Desvio Padrão</i>	1,93
<i>Mínimo</i>	10
<i>Máximo</i>	16

A Figura 61 contém as frequências das classificações finais dos alunos que constituíram o grupo de controlo (alunos do ano letivo de 2013/2014). Neste grupo houve 3 alunos que obtiveram 8 valores na classificação final, 3 alunos com 9 valores, 2 alunos com 10 valores, 1 aluno com 11 valores, 4 alunos com 12 valores, 3 alunos com 13 e 14 valores respetivamente e dois alunos com 15 valores atingindo um total de 21 alunos.

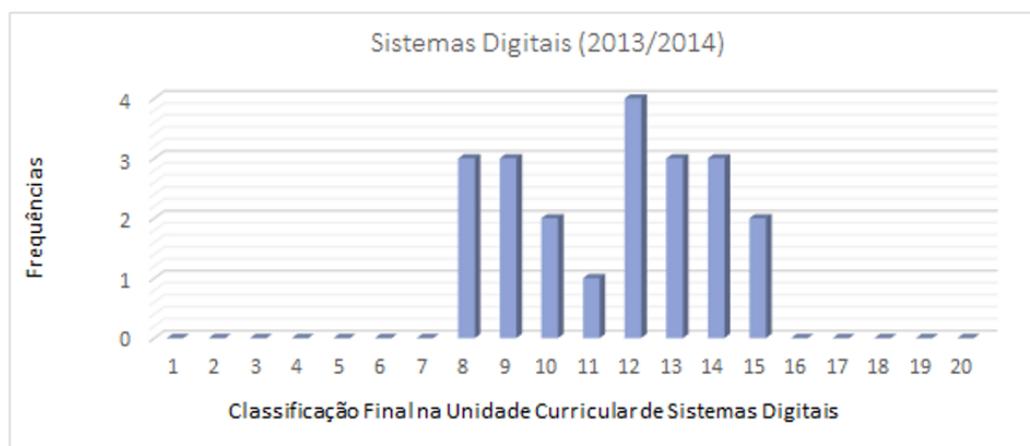


Figura 61 - Frequências das notas finais da unidade curricular se Sistemas Digitais (2013/2014).

A análise efetuada às notas dos alunos deste grupo é descrita na Tabela 15.

Tabela 15 - Análise estatística (Grupo de controlo)

	<i>Resultados</i>
<i>Número de alunos</i>	21
<i>Média</i>	11
<i>Mediana</i>	12
<i>Variância</i>	5,56
<i>Desvio Padrão</i>	2,35
<i>Mínimo</i>	8
<i>Máximo</i>	15

A Figura 62 apresenta o resumo das notas finais do grupo experimental e do grupo de controlo:

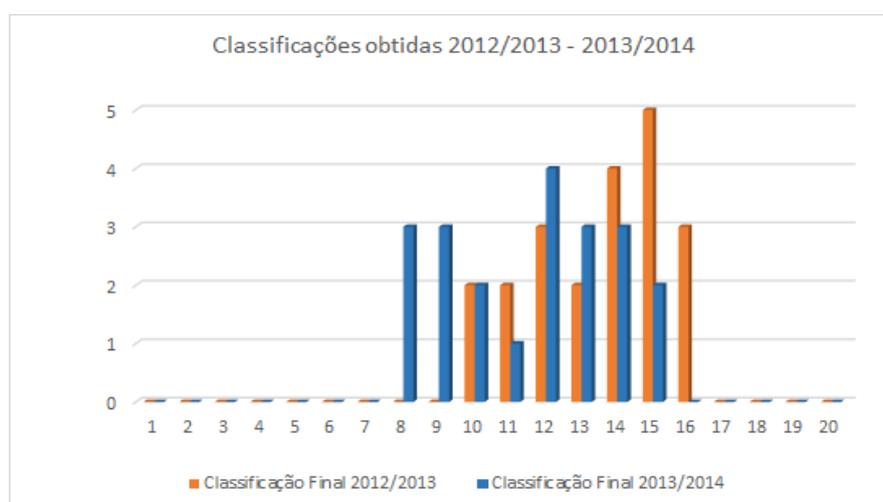


Figura 62 - Resumo das frequências das notas finais da unidade curricular se Sistemas Digitais (2012/2013 - 2013/2014).

O resumo da análise estatística efetuado aos dois grupos é apresentado na Tabela 16, onde se pode observar que a média do grupo experimental é de 13 valores e o desvio padrão (dp) de

1,93 é superior à do grupo de controlo com média de 11 valores e dp de 2,35. O grau de liberdade 40 é dado pela diferença entre a quantidade de amostras e a quantidade de grupos analisados e permite determinar as variáveis que apresentam uma diferença maior ou igual a um determinado nível estatístico de significância esperado. Os dois grupos foram comparados estatisticamente através da utilização do teste t para a comparação das médias entre amostras independentes, com um nível de significância de 0,05 (5%) (Bland, 2000).

Tabela 16 - Análise estatística (Resumo)

	Resultados (Grupo Experimental)	Resultados (Grupo de Controlo)
<i>Observações (N)</i>	21	21
<i>Média</i>	13	11
<i>Mediana</i>	14	12
<i>Variância</i>	3,76	5,56
<i>Desvio Padrão</i>	1,93	2,35
<i>Mínimo</i>	10	8
<i>Máximo</i>	16	15
<i>Grau de liberdade</i>	40	
<i>p</i>	0.004611	

As diferenças observadas são estatisticamente significativas ($p=0,0046$) o que confirma que os resultados obtidos constituem um bom indicador, podendo ser ainda mais expressivos se os tamanhos das amostras fossem superiores.

Os resultados da avaliação da plataforma ADAPT realizada através da análise estatística efetuada às classificações finais dos dois grupos de alunos, são estatisticamente significativos, o que confirma a hipótese de que “a utilização da plataforma ADAPT como ferramenta de apoio ao processo de aprendizagem contribuiu para que os alunos alcancem melhores resultados”.

7.2 Testes de Usabilidade

De modo a obter *feedback* foi apresentado um questionário de usabilidade aos alunos logo depois destes terem terminado o curso apresentado pela plataforma. Este questionário foi elaborado com perguntas de fácil leitura e resposta com o objetivo de avaliar temas como o nível de interatividade, impacto visual, linguagem, duração e estrutura da plataforma.

A avaliação do nível de interatividade é importante porque mede o interesse do aluno e a retenção de conhecimento dando uma indicação da eficácia da experiência de *e-learning* a que o aluno foi submetido. O impacto visual é importante porque se os conteúdos programáticos forem constituídos por imagens e animações apelativas o aluno vai sentir-se mais motivado a

utilizar a plataforma. A linguagem utilizada também é um aspeto importante a ter em conta dado ser necessário utilizar uma linguagem apropriada ao tipo de audiência com que se pretende comunicar. A utilização de exemplos, a construção de cenários, a construção de parágrafos em número adequado e de forma sucinta são fatores que contribuem para manter o interesse durante o processo de aprendizagem. A duração é outro aspeto importante pois permite avaliar se o tempo passado em cada OA e o tempo total de curso é o mais adequado ou se precisa de ser alterado. Por último, o aspeto da estruturação do curso é importante pois permite saber se o conteúdo do curso é apresentado numa sequência lógica e organizada de modo que a audiência o perceba com facilidade. Nesta secção são apresentados os resultados dos testes de usabilidade e a discussão dos mesmos. O questionário elaborado para realizar o teste de usabilidade encontra-se no [Apêndice A](#) do presente documento.

Os testes de usabilidade foram realizados pelos alunos do Departamento de Engenharia Informática e de Sistemas do Instituto Superior de Engenharia de Coimbra. Estes alunos foram contactados por email onde lhes foi dado a conhecer a plataforma ADAPT e a possibilidade de realizar testes de usabilidade da mesma. Dos alunos contactados, 466 alunos utilizaram a plataforma, e destes 174 responderam ao questionário de usabilidade cujos resultados se apresentam nesta secção.

Para determinar o nível de satisfação dos alunos, as respostas possíveis do questionário de usabilidade consideraram quatro opções: Mau, Satisfatório, Bom e Muito Bom. Estas opções foram utilizadas de modo a medir o nível de satisfação em algumas áreas genéricas sendo que noutras áreas específicas se optou por respostas diretas.

Com o intuito de avaliar a opinião dos alunos relativamente ao nível de interatividade da plataforma ADAPT, foram efetuadas várias perguntas cujo resultado se encontra na Figura 63. Na pergunta “Como classifica a facilidade de navegação entre conteúdos?”, a maioria dos alunos avalia a plataforma de forma positiva com 40,8% dos alunos a considerar “Bom”, e 24,1% a avaliar com “Muito Bom”. 33,8% dos alunos atribui uma classificação de “Satisfatório” e 1,3% avalia com um “Mau.”

Em relação à pergunta “É facilmente perceptível o que se deve fazer para avançar?” 43,7% dos alunos avalia a plataforma com “Muito Bom” e 35,6% atribui “Bom”. Para a mesma pergunta 19% considera “Satisfatório” e apenas 1,7% atribui a classificação de “Mau”.

Relativamente à pergunta “O nível de interatividade é adequado para os conteúdos exibidos?” 14,4% dos alunos avalia com “Muito Bom” e 35,6% atribui “Bom”. A classificação de “Satisfatório” foi dada por 45,4% dos alunos e 4,6% atribui “Mau”.

À Pergunta “Classifique a qualidade das animações que foram apresentadas.” a maioria dos alunos considera o nível de interatividade “Satisfatório” com 43,1%, seguido de 29,3% que avalia com “Bom” e 23,6% que classifica com “Muito Bom”. A classificação de “Mau” foi atribuída por 4,0% dos alunos.

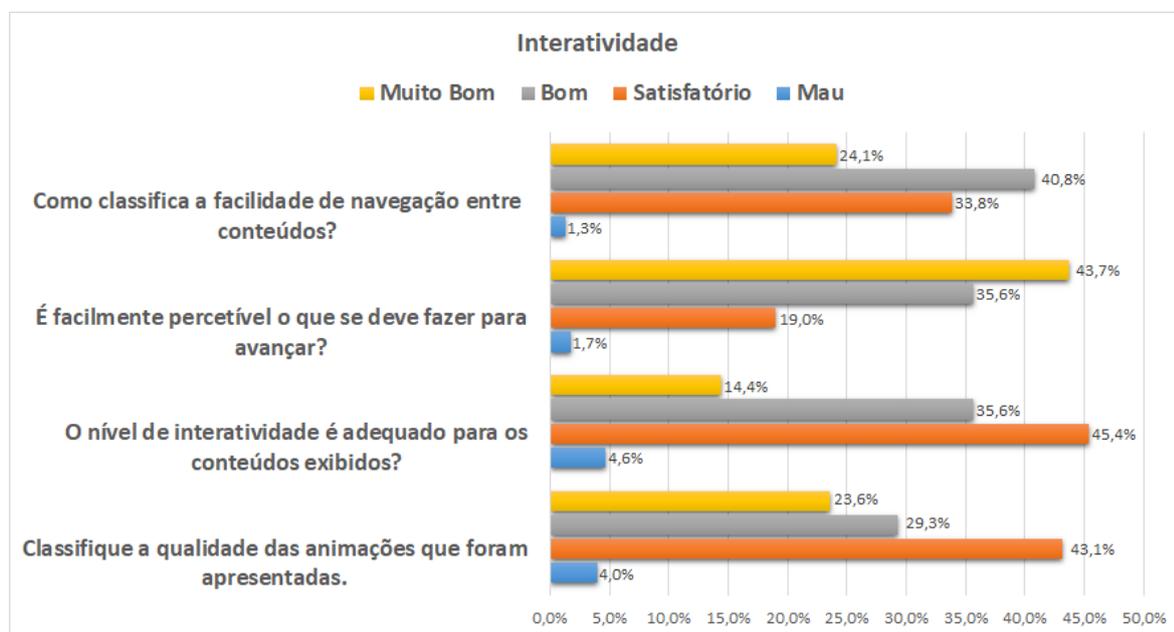


Figura 63 - Resultado do questionário de usabilidade: Nível de Interatividade.

De modo a avaliar a opinião dos alunos em relação ao impacto visual dos objetos de aprendizagem apresentados pela plataforma, foram efetuadas várias questões cujo resultado se encontra na Figura 64. Deste modo, em relação à pergunta “Como avalia de forma geral a estética dos conteúdos do curso?” 17,2% dos alunos deram uma classificação de “Muito Bom”, 38,5 dos alunos avaliaram com “Bom”, 43,7% classificaram o impacto visual de satisfatório e apenas 0,6% atribuíram a nota “Mau”.

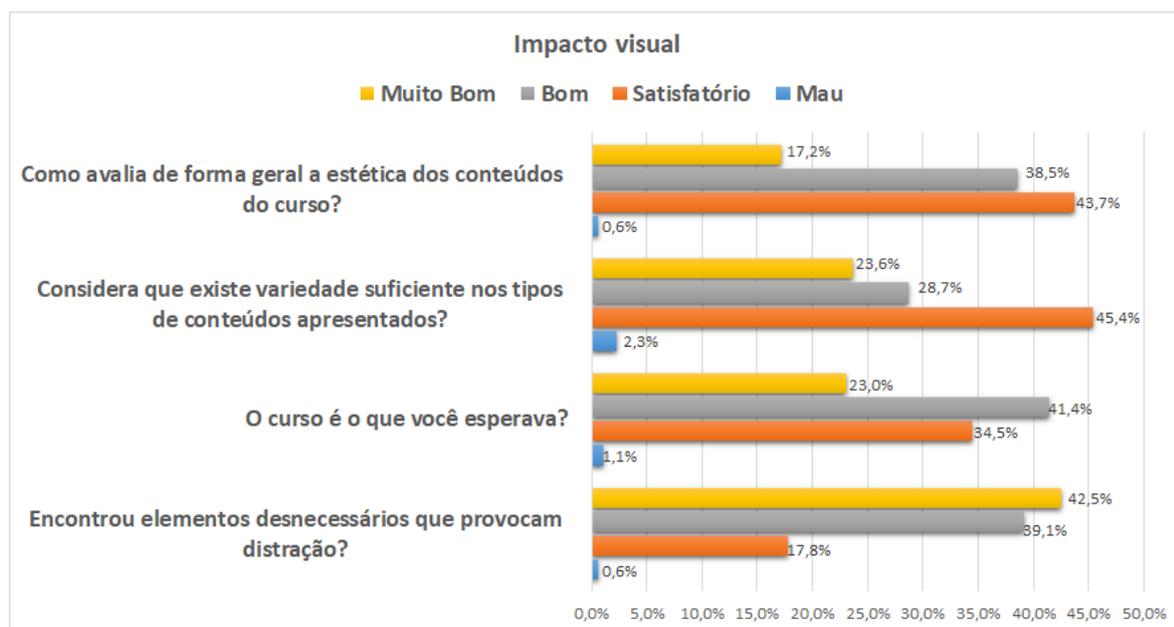


Figura 64 - Resultado do questionário de usabilidade: Impacto visual.

Na pergunta “Considera que existe variedade suficiente nos tipos de conteúdos apresentados?” foi atribuída a classificação de “Muito Bom” por 23,6% dos alunos, a classificação de “Bom” foi atribuída por 28,7% dos alunos, 45,4% atribuíram “Satisfatório” e 2,3% classificaram de “Mau”.

Relativamente à pergunta “O curso é o que você esperava?”, foi atribuída uma classificação de “Muito Bom” por 23,0% dos alunos, “Bom” foi atribuída por 41,4% dos alunos enquanto 34,5% atribuíram “Satisfatório” e 1,1% classificaram com “Mau”. Na pergunta “Encontrou elementos desnecessários que provocam distração?” a maior percentagem das respostas obtidas, cerca de 42,5%, classificou a plataforma com “Muito Bom”, 39,1% dos alunos classificou com um “Bom” enquanto 17,8% dos alunos avaliaram como “Satisfatório” os elementos desnecessários exibidos pela plataforma. Apenas 0,6% dos alunos atribuiu a classificação de “Mau”.

A avaliação efetuada pelos alunos relativamente à qualidade da escrita encontrada na plataforma ADAPT é apresentada na Figura 65.



Figura 65 - Resultado do questionário de usabilidade: Escrita.

Na pergunta “Compreendeu completamente o que leu?” a maior percentagem das respostas dadas incidiu na classificação de “Bom” com 41,4% seguida de “Muito Bom” com 31,6% das respostas. A classificação de “Satisfatório” foi dada por 26,4% dos alunos e apenas 0,6% classificou esta matéria como “Mau”.

Em relação à questão “Considera que as frases estão bem escritas?” 41,2% dos alunos classificou com “Bom” e 39,0% com “Muito Bom”. A avaliação de “Satisfatório” foi atribuída por 19,2% dos alunos e apenas um valor residual de alunos responderam “Mau”.

Na questão relativa aos parágrafos apresentados “Os parágrafos são breves e sucintos?” 46,6% dos alunos respondeu com “Bom” e 33,9% atribuiu “Muito Bom”. A classificação de “Satisfatório” foi dada por 18,9% dos alunos e apenas 0,6% atribuíram “Mau”.

Relativamente à questão “Avalie a legibilidade do texto e o tipo de letra utilizado.” 42,5% dos alunos classificou com “Muito Bom”, 40,2% atribuiu “Bom”, 16,7% “Satisfatório” e 0,6% “Mau”.

Para avaliar o período de tempo despendido na realização de algumas tarefas, foram abordadas várias questões apresentadas na Figura 66. Na pergunta “Como classifica o ritmo a que o curso avança?” a maior percentagem das respostas dados pelos alunos, cerca de 46,0% avaliou com “Bom” o ritmo do curso seguido de 32,2% que avaliaram com “Bom”. Relativamente à pergunta “Como avalia o tempo necessário para completar o curso?” cerca de 43,1% atribuiu a classificação de “Bom” e 36,2% de “Muito Bom”. Em relação à pergunta “Como avalia o tempo

despendido por página (objeto de aprendizagem)?” 47,7% dos alunos avaliaram a plataforma com uma classificação de “Bom” e 36,8% de “Muito Bom”. Na pergunta “Considera que a utilização da plataforma permite diminuir o tempo de estudo sem prejudicar a aprendizagem?”, a maioria dos alunos, cerca de 59%, respondeu afirmativamente, ao considerar que a utilização da plataforma permite uma redução no tempo de estudo.

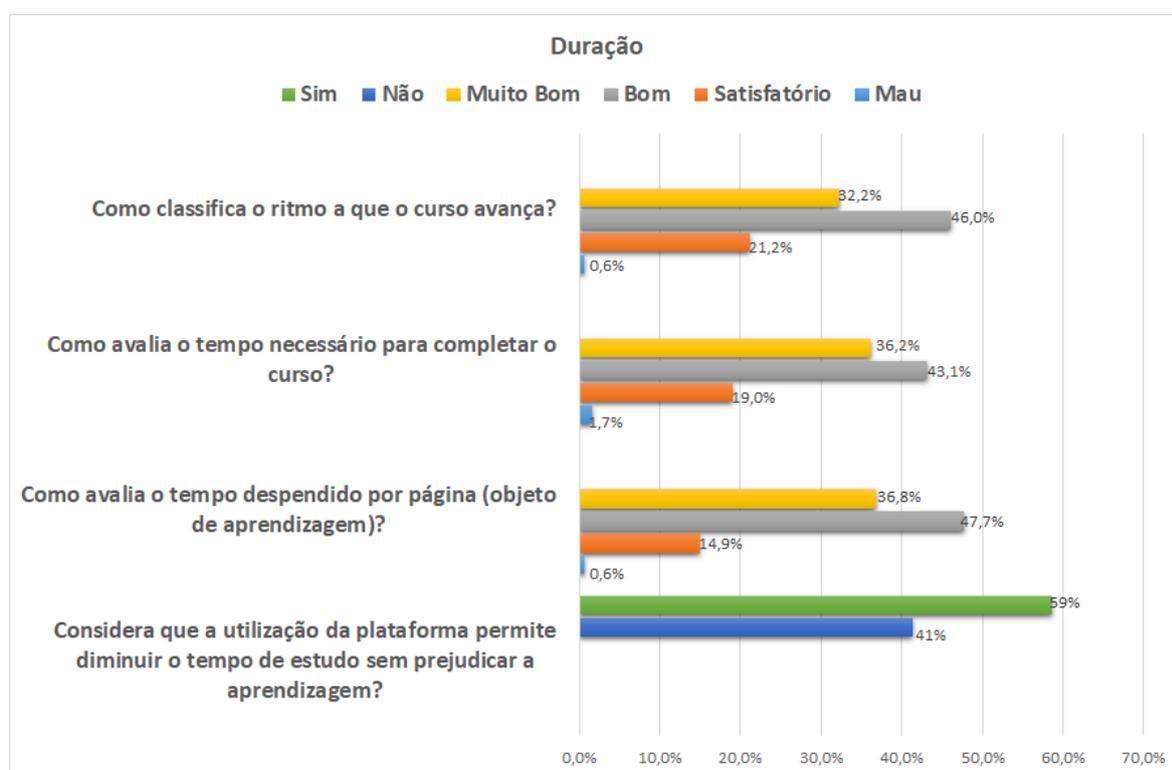


Figura 66 - Resultado do questionário de usabilidade: Duração.

Por último, de modo a obter *feedback* em relação a temas relacionados com a estrutura, qualidade técnica, direção do curso, entre outros, foram realizadas várias perguntas no questionário de usabilidade, apresentando-se os resultados na Figura 67. Na pergunta “Avalie a qualidade técnica dos materiais do curso.” 51,1% dos alunos que utilizaram a plataforma, avaliaram com “Bom” e 18,4% atribuíram “Muito Bom”. A classificação de “Satisfatório” foi atribuída por 29,9% dos alunos.

Relativamente à pergunta “O curso de *e-learning* seguiu uma direção clara?” a maioria dos alunos avaliou a plataforma com “Bom” e “Muito Bom” com percentagens de 43,6% e 42,0%, respetivamente. Quando questionados os alunos com a pergunta “Qual o contributo da utilização da plataforma na melhoria do seu conhecimento em relação aos temas abordados?” 47,7% classificaram a plataforma com “Bom” e 33,3% classificaram com “Muito Bom”. Na questão que permite determinar a preferência de realização do curso, “Preferiria realizar este

curso *on-line* ou numa sala de aula?”, uma percentagem de 82,2% dos alunos respondeu que escolheria a opção *on-line* em relação a 17,8% que optaria pela realização numa sala de aula.

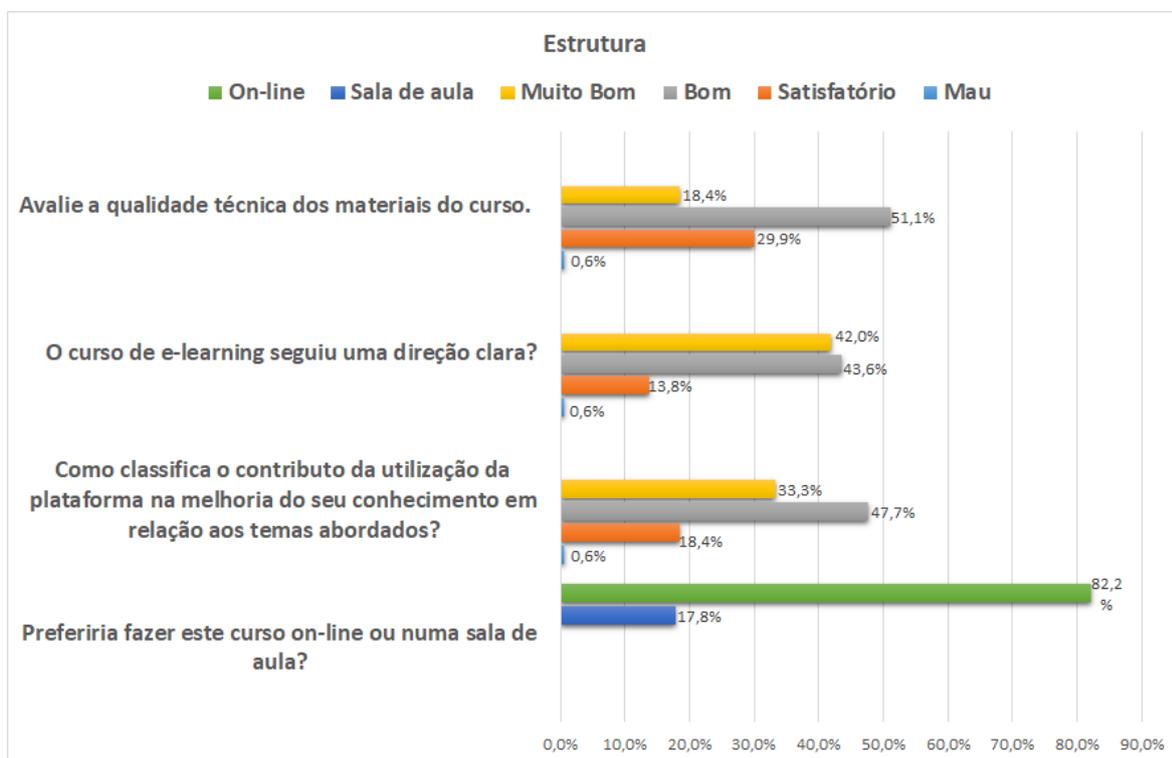


Figura 67 - Resultado do questionário de usabilidade: Estrutura.

Outra informação que se procurou extrair com este questionário foi, dos alunos que utilizaram a plataforma, qual a percentagem que frequentou alguma unidade curricular relacionada com o curso disponibilizado na plataforma. Os resultados obtidos são apresentados na Figura 68.

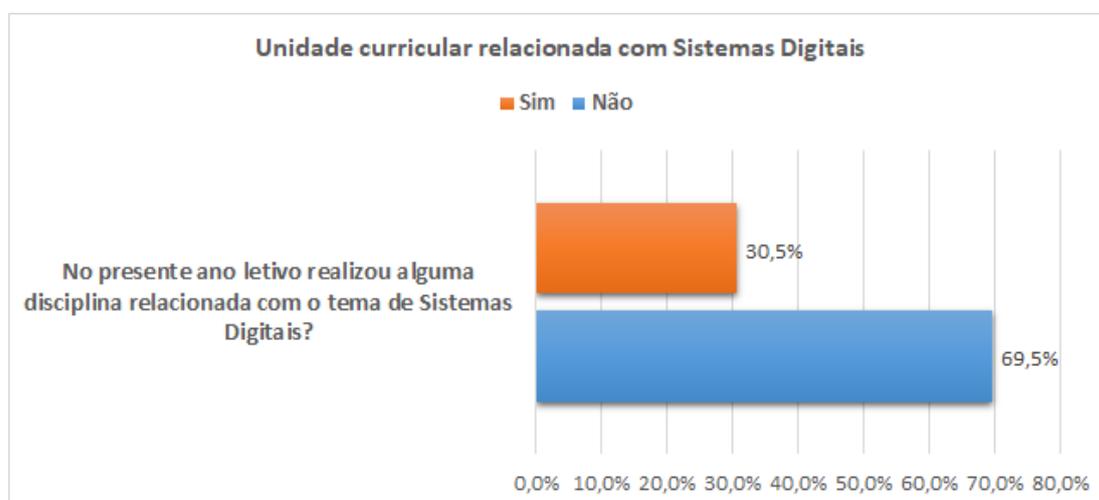


Figura 68 - Percentagem de alunos que frequentaram a unidade curricular de Sistemas Digitais.

A Tabela 17 apresenta a percentagem das classificações atribuídas pelos utilizadores a cada uma das questões, no teste de usabilidade da plataforma.

Tabela 17 - Resumo dos resultados obtidos no teste de usabilidade.

1. Nível de interatividade						
	<i>Muito bom</i> (%)	<i>Bom</i> (%)	<i>Satisfatório</i> (%)	<i>Mau</i> (%)		
Como classifica a facilidade de navegação entre conteúdos?	24,1%	40,8%	33,8%	1,3%		
É facilmente perceptível o que se deve fazer para avançar?	43,7%	35,6%	19,0%	1,7%		
O nível de interatividade é adequado para os conteúdos exibidos?	14,4%	35,6%	45,4%	4,6%		
Classifique a qualidade das animações que foram apresentadas.	23,6%	29,3%	43,1%	4,0%		
2. Impacto Visual						
	<i>Muito bom</i> (%)	<i>Bom</i> (%)	<i>Satisfatório</i> (%)	<i>Mau</i> (%)		
Como avalia de forma geral a estética dos conteúdos do curso?	17,2%	38,5%	43,7%	0,6%		
Considera que existe variedade suficiente nos tipos de conteúdos apresentados?	23,6%	28,7%	45,4%	2,3%		
O curso é o que você esperava?	23,0%	41,4%	34,5%	1,1%		
Encontrou elementos desnecessários que provocam distração?	42,5%	39,1%	17,8%	0,6%		
3. Escrita						
	<i>Muito bom</i> (%)	<i>Bom</i> (%)	<i>Satisfatório</i> (%)	<i>Mau</i> (%)		
Compreendeu completamente o que leu?	31,6%	41,4%	26,4%	0,6%		
Considera que as frases estão bem escritas?	39,0%	41,2%	19,2%	0,6%		
Os parágrafos são breves o sucintos?	33,9%	46,6%	18,9%	0,6%		
Avalie a legibilidade do texto e o tipo de letra utilizado.	42,5%	40,2%	16,7%	0,6%		
4. Duração						

	Muito bom (%)	Bom (%)	Satisfatório (%)	Mau (%)	Sim (%)	Não (%)
Como classifica o ritmo a que o curso avança?	32,2%	46,0%	21,2%	0,6%		
Como avalia o tempo necessário para completar o curso?	36,2%	43,1%	19,0%	1,7%		
Como avalia o tempo despendido por página (objeto de aprendizagem)?	36,8%	47,7%	14,9%	0,6%		
Considera que a utilização da plataforma permite diminuir o tempo de estudo sem prejudicar a aprendizagem?					59,0 %	41,0 %
5. Estrutura						
	Muito bom (%)	Bom (%)	Satisfatório (%)	Mau (%)	On-line (%)	Sala de aula (%)
Avalie a qualidade técnica dos materiais do curso.	18,4%	51,1%	29,9%	0,6%		
O curso de <i>e-learning</i> seguiu em uma direção clara?	42,0%	43,6%	13,8%	0,6%		
Como classifica o contributo da utilização da plataforma na melhoria do seu conhecimento em relação aos temas abordados?	33,3%	47,7%	18,4%	0,6%		
Preferiria fazer esse curso <i>on-line</i> ou na sala de aula?					82,2 %	17,8 %

7.3 Discussão dos Resultados

Nesta secção são analisados os resultados obtidos na análise estatística e no questionário de usabilidade apresentados na secção anterior.

Os resultados obtidos na análise estatística efetuada às classificações finais de dois grupos de alunos em anos letivos diferentes, são estatisticamente significativos, e vêm confirmar que a utilização da plataforma constituiu um contributo para que os alunos alcancem melhores resultados. Considera-se também a importância da realização de novos testes utilizando amostras com dimensões superiores de modo a obter resultados mais expressivos e assim reafirmar a importância da utilização da plataforma.

Relativamente aos resultados obtidos no teste de usabilidade pode afirmar-se que a solução desenvolvida e que se pretendia que fosse inovadora na forma de resolver algumas das questões dos STI atuais, é válida. Estes resultados permitem também suportar a tese de que o uso das preferências de aprendizagem em conjunto com técnicas adequadas de adaptação ao perfil de aprendizagem do aluno contribui para melhorar as suas competências através do processo de aquisição de conhecimento, confirmada pelos 47,7% dos alunos que responderam “Bom” e 33,3% “Muito Bom” à questão “Como classifica o contributo da utilização da plataforma na melhoria do seu conhecimento em relação aos temas abordados?” .

A utilização da plataforma permite também a diminuição do tempo despendido na aquisição de conhecimento. Esta afirmação é suportada por 59% de alunos que responderam afirmativamente à questão “Considera que a utilização da plataforma permite diminuir o tempo de estudo sem prejudicar a aprendizagem?”.

A análise dos dados, demonstrou também ser muito positiva em relação à preferência de utilização da plataforma tendo 82,2% dos alunos escolhido a opção on-line na questão “Preferiria fazer este curso on-line ou numa sala de aula?”.

Analisando os resultados obtidos nas áreas avaliadas, interatividade, impacto visual, escrita, duração e estrutura do curso - são na generalidade bons, salvo raras exceções. Nestas exceções incluem-se por exemplo, o nível de interatividade, tendo a questão “O nível de interatividade é adequado para os conteúdos exibidos?” obtido uma avaliação de “Satisfatório” em 45,4% das respostas. Esta questão representa um aspeto que pode ser melhorado. Outra questão relacionada com a plataforma que obteve resultados mais modestos foi na variedade de tipos de conteúdos tendo 45,4% dos alunos avaliado com “Satisfatório” a questão “Considera que existe variedade suficiente nos tipos de conteúdos apresentados?”. Estes dois aspetos mencionados anteriormente podem ser incluídos na lista de melhorias a realizar num trabalho futuro, apresentado na [secção 8.2](#) do presente documento.

8 Conclusões

O projeto ADAPT teve como objetivo principal o de conceber um STI inovador ao permitir relacionar a representação do conhecimento, preferências de aprendizagem e estilos de aprendizagem do aluno com objetos de aprendizagem catalogados segundo o modelo VARK e compatíveis com a norma LOM. Este mapeamento entre preferências de aprendizagem com os OA é efetuado através de técnicas de IA.

A primeira fase desta investigação centrou-se na análise das soluções existentes e no estado da arte dos STI. Relativamente ao estado da arte a investigação efetuada permitiu inteirar as últimas funcionalidades incorporadas nos STI. Deste modo, apresentaram-se os Sistemas Tutores Afetivos (STA) que permitem detetar a emoção expressa pelo aluno, os Sistemas Tutores Inteligentes Conversacionais que comunicam verbalmente com o aluno através de um tutor virtual. Também foram apresentados STI com reconhecimento de escrita e com *Eye Tracking*, que monitorizam os padrões do olhar do aluno para identificar o seu estado de atenção.

A segunda fase da investigação consistiu em efetuar um levantamento das várias teorias de aprendizagem assim como dos modelos de aprendizagem existentes e que permitem capturar o estilo de aprendizagem. Os modelos analisados foram: o modelo *Myers-Briggs Type Indicator*; o modelo de aprendizagem de Kolb; o modelo de estilos de aprendizagem de Felder-Silverman; e o paradigma VARK.

Fazer uma avaliação de modelos de estilos de aprendizagem não é fácil. Contudo, dos quatro modelos analisados, o modelo de Felder-Silverman mostrou-se o mais indicado pelo facto de ser o mais objetivo pelas dimensões que considera e pelo facto de ser muito utilizado no domínio das engenharias.

No que diz respeito ao mapeamento com o paradigma VARK, todos os modelos analisados possuem informação que permite fazer o mapeamento entre as suas dimensões e conteúdos do modelo VARK que se pretendem exhibir. No entanto, também aqui o modelo de Felder-Silverman parece ser mais vantajoso que os restantes pelo facto de uma das suas quatro dimensões avaliar como um indivíduo têm preferência na receção de informação.

Em relação às taxonomias, a escolhida foi a taxonomia de Bloom revista, pelo facto de ser uma taxonomia de objetivos educacionais que é bastante aceite e também por ser muito utilizada no domínio das engenharias.

Relativamente à implementação da plataforma, a utilização de Lógica Difusa para inferir o grau de pertença de um aluno a cada uma das dimensões do modelo de estilos de aprendizagem considera-se uma boa opção, pois permitiu realizar um mapeamento com o paradigma VARK.

Para a seleção dos guiões foi utilizado o paradigma RBC. Este modelo é constituído por uma biblioteca de casos, em que cada caso representa um guião com o conjunto conteúdos que vão ser exibidos. Quando a seleção de guiões retorna um resultado que não é considerado adequado, é utilizado um algoritmo genético para fazer uma adaptação e assim gerar um novo guião.

Paralelamente a estas técnicas recorreu-se também a *data mining* e pesquisas locais para deteção de alterações de perfil e sugestão de conteúdos complementares e alternativos.

Finalmente, a análise estatística efetuada aos resultados obtidos pelos alunos que utilizaram a plataforma permitiu observar melhorias no seu desempenho sendo esse o objetivo principal da plataforma ADAPT. Os resultados obtidos nos testes de usabilidade confirmaram uma vez mais a preferência dos alunos em relação à utilização da plataforma.

8.1 Objetivos alcançados

Como mencionado anteriormente, a realização deste trabalho teve como objetivo final a conceção e implementação de um STI dotado de uma arquitetura que permitisse apresentar um curso com uma abordagem adaptativa e assim apoiar e melhorar o desempenho dos alunos. Em termos gerais, considera-se que este objetivo foi atingido. No entanto, para que tal fosse possível, foi necessário atingir um conjunto de outras metas, tanto a nível de implementação como a nível de integração. Os principais objetivos alcançados são listados de seguida.

- Implementação, na plataforma, do sistema difuso responsável pelo mapeamento de objetos de aprendizagem no perfil do aluno;
- Implementação do paradigma RBC que permite efetuar a adaptação dos conteúdos de acordo com a experiência de utilização passada;
- Implementação de um Algoritmo Genético que realize a adaptação da solução apresentada pelo RBC, caso esta não seja considerada satisfatória;
- Implementação e integração do módulo de simulação de resultados de adaptação ao perfil do aluno com base em valores parametrizáveis. Este módulo permite

efetuar testes aos resultados provenientes do paradigma RBC e do Algoritmo Genético;

- Integração do módulo de *data mining* e pesquisa local com o módulo STI;
- Desenvolvimento de OA e sua catalogação, pelas normas LOM/SCORM, VARK e Taxonomia de Bloom e carregamento desses OA na plataforma;
- Disponibilização da plataforma a um grupo de alunos com vista à realização de testes aplicativos e de usabilidade.

8.2 Limitações e perspectivas de trabalho futuro

Na realização deste trabalho foram detetadas algumas limitações que podem ter um impacto direto no seu funcionamento. Uma delas está relacionada com a dificuldade na criação de OA quer em quantidade, quer em variedade, de forma a abrangerem o maior número de perfis de aprendizagem. Um exemplo desta situação é que todos os OA existentes na plataforma foram catalogados através do modelo VARK, o que pressupõem que existam OA catalogados como sendo predominantemente visuais, auditivos, de leitura/escrita ou então como cinestésicos. Ora, durante o desenvolvimento destes conteúdos não foi possível desenvolver OA do tipo auditivo, o que limitou o processo de adaptação dos alunos que tenham inclinação para este tipo de aprendizagem.

Outra limitação encontrada foi no tamanho da base de casos. No módulo RBC foram inicialmente introduzidos casos gerados manualmente na base de dados. Numa segunda fase foi possível a obtenção de casos reais através da utilização da plataforma por uma turma de Sistema Digitais que a utilizou, permitindo assim recolher dezenas de casos válidos, ou seja, casos em que os alunos completaram o curso. A nível do módulo RBC seria desejável a obtenção de casos em maior número, pois quanto maior o número de casos, maior a experiência adquirida e conseqüentemente mais eficaz o processo de adaptação.

De modo a superar as limitações identificadas, sugere-se como trabalho futuro, a utilização de um maior número de OA de modo a abranger o maior número possíveis de preferências de aprendizagem e assim melhorar quer o processo de adaptação, quer a experiência de utilização da plataforma. Também seria útil obter um maior número de casos de utilização.

Adicionalmente, consideram-se as alterações ao módulo de *data mining* e pesquisa local ao integrar a API *Google Custom Search*, (2018) permite que a pesquisa de OA passe a ter uma dimensão mais global ao utilizar a *Internet* como espaço de procura. A integração da capacidade de efetuar uma pesquisa global constitui a finalização da plataforma ADAPT e representa uma mais-valia importante, uma vez que permite alargar os horizontes do aluno ao introduzir novos OA que possam ser relevantes e deste modo melhorar o seu processo de aprendizagem e consequentemente na sua avaliação final.

Para finalizar, conclui-se que apesar das várias limitações, os objetivos propostos inicialmente para este trabalho foram alcançados com sucesso.

Referências bibliográficas

- Aamodt, A., Plaza, E. (1994). "Case-Based Reasoning: Foundational Issues, Methodological Variations, and System Approaches" *Artificial Intelligence Communications* 7, 39-52.
- Abowd, G.D. (1999). Software engineering issues for ubiquitous computing. In: *Proceedings of International Conference on Software Engineering, ISCE'99*. ACM, NY, pp. 75–84.
- ADAPT - Plataforma Adaptativa de Ensino à Distância,
https://www.fct.pt/apoios/projectos/consulta/vglobal_projecto?idProjecto=115175&idElemConcurso=3643.
 (Consultado em 21 de Outubro de 2016).
- Agrawal, R., Imielinski, T., Swami, A. (1993). Mining Association Rules Between Sets of Items in Large Databases", *SIGMOD Conference*, vol. 22, no. 2, pp. 207-216.
- Anastasi, A., Urbina, S. (2000). *Testagem Psicológica*.
- Anderson, J. R. (1987). Production systems, learning and tutoring. In *Production System Models of Learning and Development* (eds D. Klahr, P. Langley, R. Neches). MIT Press, London, pp.437-458.
- Anderson, L. W., Krathwohl, D. R. (2001). A Taxonomy for Learning, Teaching, and Assessing: A Revision of Bloom's Taxonomy of Educational Objectives. New York: Longman.
- Anthony, L., Yang, J., Koedinger, K. R. (2012). A paradigm for handwriting-based intelligent tutors. *International Journal of Human Computer Studies*, 70(11), 866–887. <http://doi.org/10.1016/j.ijhcs.2012.04.003>
- Ausubel, D.P. (1963). *The psychology of meaningful verbal learning*. New York, Grune and Stratton.
- Ausubel, D. P. (1968). *Educational Psychology: A Cognitive View*. New York: Holt, Rinehart and Winston.
- Ausubel, D.P. (2000). *The acquisition and retention of knowledge: A cognitive view*. Boston: Kluwer.
- Azevedo, F. Desenvolvimento de Conteúdos para a Plataforma ADAPT. (2013). Trabalho de Conclusão de Curso, Licenciatura em Eng^a Informática. Departamento de Engenharia Informática. Instituto Superior de Engenharia de Coimbra, Coimbra.
- Banzhaf, W., Nordin, P., Keller, R. E., Francone, F. D. (1998). *Genetic Programming: An Introduction*. ISBN 155860510x. Morgan Kaufmann.
- Barros, C. S. G. (1998). *Pontos de Psicologia Escolar*. São Paulo: Editora Atica.
- Berkin, P. (2002). Survey of clustering data mining techniques, Technical report, Accrue Software, San Jose, CA.
- Bland, M. (2000). An introduction to medical statistics, 3rd ed. Oxford: Oxford University Press.
- Bloom, B.S. (1956). Taxonomy of Educational Objectives: The Classification of Educational Goals. *Handbook I: Cognitive Domain*. McKay, New York.
- Bloom, B.S. (1984). The 2 Sigma Problem: The Search for Methods of Group Instruction as Effective as One-to-One Tutoring. *Educational Researcher*, 13, pp. 3-16.
- Bolzan, W., Giraffa, L. (2002). Estudo Comparativo sobre Sistemas Tutores Inteligentes Multiagentes Web, *Technical Report N.º24*. PUCRS Faculdade de Informática, Brasil.

Bridge, D., Ferguson, A. (2002). An expressive query language for product recommender systems. *Artificial Intelligence Review* 18(3-4), 269-307.

Bruner, J. (1975). *Uma Nova teoria de Aprendizagem* (3ª Edição ed.). Brasília: Bloch Editores SA.

Bruner, J. (2000). *Cultura de Educação*. Lisboa: edições 70.

Buchanan, B. (2006). A (Very) Brief History of Artificial Intelligence. *AI Magazine* 26(4). pp.53-60.

Capelo, F. M. (2000). Aprendizagem Centrada na Pessoa: Contribuição para a compreensão do modelo educativo proposto por Carl Rogers. *Revista de Estudos Rogerianos A Pessoa como Centro* N.º 5 Primavera-Verão.

Carbonell, J. R. (1970). An artificial intelligence approach to computer-assisted instruction. *IEEE Transactions on Man-Machine Systems*, 11,190-202.

Carvalho, A., Ludemir, A. (1998). *Fundamentos de Redes Neurais Artificiais: 11ª Escola de Computação*. Imprinta Gráfica e Editora Ltda.

Castro, L., Zuben, F. (2003). Rede Neural de Kohonen e Outras Técnicas para Treinamento Não-Supervisionado. IA353 - Redes Neurais. Universidade Estadual de Campinas.

Chambers, J., Sprecher, J. (1983). *Computer-Assisted Instruction: Its Use in the Classroom*. Englewood Cliffs, New Jersey: Prentice-Hall Inc.

Coffield F., Moseley D., Hall E., Ecclestone K. (2004). *Learning styles and pedagogy in post-16 learning. A systematic and critical review*.

Coll, C., Gilliéron. C. (1987). Jean Piaget: O desenvolvimento da inteligência e a construção do pensamento racional. In, Leite, L.B. (org) *Piaget e a Escola de Genebra*. São Paulo: Cortez, p. 15-49.

Cooper, S. (2009). *Theories of Learning in Educational Psychology* <http://www.lifecircles-inc.com/Learningtheories/behaviorism/Thorndike.html>.

Costa-Lobo, C. (2011). Abordagem Socio-Cognitiva do Ajustamento à Carreira no Ensino Superior: O Papel das Atividades em Grupo, da Auto-Eficácia e dos Interesses. *Braga: Escola de Psicologia*, Universidade do Minho.

Darwin, C. (1859). "On the Origin of Species by Means of Natural Selection, or the Preservation of Favoured Races in the Struggle for Life", *Nature, London: John Murray*, 5 (121): 502.

Deng, H., Runger, G., Tuv, E. (2011). "Bias of importance measures for multi-valued attributes and solutions", *Proceedings of the 21st International Conference on Artificial Neural Networks (ICANN)*, pp. 293-300.

D'Mello, S., Graesser, A. (2012). AutoTutor and affective autotutor. *ACM Transactions on Interactive Intelligent Systems*, 2(4), 1–39. <http://doi.org/10.1145/2395123.2395128>.

D'Mello, S., Olney, A., Williams, C., Hays, P. (2012). Gaze tutor: A gaze-reactive intelligent tutoring system. *International Journal of Human Computer Studies*, 70(5), 377–398. <http://doi.org/10.1016/j.ijhcs.2012.01.004>.

Elsom-Cook, M. (1987). Intelligent Computer-aided instruction research at the Open University. *Technical Report No: 63. Computer-Assisted Learning Research Group*. The Open University, Milton Keynes.

European Comission, *Education and Training*. http://ec.europa.eu/education/lifelong-learning-policy/doc28_en.html. (Consultado em 16 de Abril de 2011).

Fayyad, U., Piatetsky-Shapiro, G., Smyth, P. (1996). From data mining to knowledge discovery: An overview. In: *Advances in Knowledge Discovery and Data Mining*, AAAI Press/The MIT Press, England, p.1-34.

- Felder, R., Soloman, B. *Index of Learning Styles*. <https://www.webtools.ncsu.edu/learningstyles/> (Consultado em 18 de Abril de 2011).
- Felder, R.M. (1996). *Matters of style*. *ASEE Prism* 6(4), 18-23.
- Felder, R.M., Silverman, L.K. (1988). *Learning and teaching styles in engineering education* [Electronic Version]. *Engr. Education*, 78(7), 674-681.
- Felder, R.M., Spurlin, J. (2005). *Applications, reliability, and validity of the index of learning styles* [Electronic Version]. *Int. J. Engng Ed.* Vol.21, No.1, pp.103-112.
- Fleming, N. (1992). *A guide to learning styles*. <http://vark-learn.com/english/page.asp?p=faq> (Consultado em 16 de Maio de 2011).
- Friston, K.J., Holmes, A.P., Worsley, K.J., Poline, J.B., Frith, C., Frackowiak, R.S.J (1995), Statistical parametric maps in functional imaging: A general linear approach. *Human Brain Mapping*, 2:189–210.
- Fry, E. (1960). Teaching Machine Dichotomy: Skinner vs. Pressey. *Psychological Reports* (6) 11-14. Southern University Press.
- Fuller, U., Johnson, C. G., Ahoniemi, T., Cukierman, D., Hernán-Losada, I., Jackova, J., Lahtinen, E., Lewis, T., Thompson, D., Riedesel, C., Errol. (2007). Developing a computer science-specific learning taxonomy. *SIGCSE Bulletin*, 39 (4) 152-170.
- Getoor, L., Diehl, C. (2005). Link mining: A survey. *ACM SIGKDD Explorations Newsletter* 7:3.
- Godfrey, T., Thorndike, E. L. (1949). *Nature*. V 164. p474.
- Goldberg, D., (1989). *Genetic Algorithms in Search, Optimization and Machine Learning*, Addison-Wesley.
- Gomes, A. (2010). *Dificuldades de aprendizagem de programação de computadores: contributos para a sua compreensão e resolução*.
- Google API Client Library for Java, <https://developers.google.com/api-client-library/java/google-api-java-client/app-engine>. (Consultado 10 de Agosto em 2018).
- Google Custom Search, https://en.wikipedia.org/wiki/Google_Custom_Search. (Consultado 10 de Agosto em 2018).
- Graesser, A. C., Chipman, P., Haynes, B. C., Olney, A. (2005). AutoTutor: An intelligent tutoring system with mixed-initiative dialogue. 48(4) 612-618.
- Graessner A. C., Kurt VanLehn, C. P R., Jordan, P., Harter, D. (2001). Intelligent tutoring systems with conversational dialogue. *AI Magazine*, 22(4), 39.
- Graf, S., Viola, S.R., Kinshuk, T.L. (2006). *Representative characteristics of Felder-Silverman learning styles: an empirical model*.
- Han, J., Kamper, M. (2000). *Data mining: Concepts and techniques*. First Edition, New York; Morgan Kaufmann.
- Haykin, S. (1999). *Neural Networks - A comprehensive Foundation*. Prentice Hall. Second Edition.
- Hearst, M. A. (1997). Text data mining: Issues, techniques, and the relationship to information access. Presentation notes for UW/MS workshop on data mining.
- Hevner, A.R., March, S.T., Park, J. (2004). Design research in information systems research. *MIS Quarterly*, 28, 1, 75–105.

Holland, J.H. (1992). *Adaptation in Natural and Artificial Systems*. Boston, MA, MIT Press.

IEEE-LTSC, (2018). IEEE Learning Technology Standards Committee, Working Group 12, <http://ieeeltsc.org/wg12LOM/> (Consultado em 06 de Abril de 2018).

IMS Global, (2018). IMS Meta-data Best Practice Guide for IEEE 1484.12.1-2002 Standard for Learning Object Metadata. https://www.imsglobal.org/metadata/mdv1p3/imsmd_bestv1p3.html (Consultado em 06 de Abril de 2018).

Ioannou, A., Hannafin, R. (2008). “Deficiencies of course management systems: do students care?”, *Quarterly Review Of Distance Education*, Vol. 4, pp. 415-425.

Jain, A. K., Murty, M. N., Flynn, P. J. (1999). Data clustering: A review, *ACM Computing Surveys*.

Jassbi, J., Serra, P. A., Ribeiro, R. A., Donati, A. (2006). Comparison of Mamdani and Sugeno fuzzy inference systems for a space fault detection application. *World Automation Congress*, 1-7.

Kantardzic, M. (2003). *Data mining: concepts, models, methods, and algorithms*, WileyInterscience.

Kelly, G. A. (1963). *A theory of personality: the psychology of personal constructs*. New York: Norton.

Klosgen, W., Zytkow, J. (1996). Knowledge discovery in databases terminology. *Advances in Knowledge Discovery and Data Mining*, pp. 573-592.

Kolb, D. (1984). *Experiential Learning: experience as the source of learning and development*.

Kolb, D. (1985). *Learning style inventory*. Boston, MA: McBer and Company.

Kovács, Z. (1996). *Redes Neurais Artificiais: Fundamentos e Aplicações*. Segunda Edição, Collegium Cognitionis.

Kumar, L., Chacko, T. (2010). Using appreciative inquiry on learning styles to facilitate student learning. *Med Educ*. 2010; 44:1121-2.

La Taille, Y., Oliveira, M.K., Dantas, H. (1992). PIAGET, VYGOTSKY, WALLON Teorias psicogenéticas em discussão. 13.ed. São Paulo: Summus, p.47-74.

Leake, D. B., Kinley, A., Wilson, D. (1996). Acquiring Case Adaptation Knowledge : A Hybrid Approach. 13th National Conference on Artificial Intelligence.

Leite, Walter L., Svinicki, M., Shi, Y. (2009). *Attempted Validation of the Scores of the VARK: Learning Styles Inventory With Multitrait–Multimethod Confirmatory Factor Analysis Models*, pg. 2. SAGE Publications.

Lewis, R. (2000). An introduction to classification and regression tree (CART) analysis, *Annual Meeting of the Society for Academy Emergency Medicine*, San Francisco, California. USA.

Litzinger, T.A., Lee, S.H., Wise, J.C., Felder, R.M., (2005) “A Study of the Reliability and Validity of the Felder-Soloman Index of Learning Styles,” *Proceedings, 2005 ASEE Annual Conference and Exposition*.

Lucene, <http://lucene.apache.org/core/>. (Consultado em 09 de Setembro de 2013).

Luke, S. (2012). *Essentials of Metaheuristics* (First Edition (Rev. C), online version 1.3 ed.): www.lulu.com.

Mainemelis, C., Boyatzis, R., Kolb, D. A. (2002). *Adaptive Flexibility: Testing Experiential Learning Theory of Development*.

Mamdani, E. H. (1973). *Applications of fuzzy algorithms for control of simple dynamic plant*. *Proc. IEEE* 121, vol. 12, p. 1585-1588.

- Mamdani, E. H., Assilian S. (1975). *An experiment in linguistic synthesis with a fuzzy logic controller*. *Int. J. Man-Machine Studies*, vol. 7, p. 1-13.
- Martins C., Faria L., Carrapatoso E. (2008). Constructivist Approach for an Educational Adaptive Hypermedia Tool. *The 8th IEEE International Conference on Advanced Learning Technologies (ICALT 2008)*, University of Cantabria, Santander on July 1st to 5th.
- MATLAB - Mathworks. (2011). <https://www.mathworks.com/products/matlab.html> (Consultado em 28 de Março 2011).
- Matos, Amélia M. (1995). Behaviorismo metodológico e behaviorismo radical. In: *Range, B. Psicoterapia comportamental e cognitiva. Campinas: Psy II*.
- Matthews, P. (2004). *The MBTI is a flawed measure of personality*.
- Mitchell, M. (1997). *An introduction to genetic algorithms*. Cambridge: MIT Press.
- MOODLE - Modular Object-Oriented Dynamic Learning Environment. (2017). <https://moodle.org/> (Consultado em 28 de Setembro 2017).
- Moreira, M. A. (1999). *Teorias de Aprendizagem*. São Paulo: EPU.
- Murthy, S. (1998). Automatic construction of decision trees from data: A multidisciplinary survey, *Data Mining and Knowledge Discovery*.
- Myers, I. B. (1980). *Gifts Differing: Understanding Personality Type*. Davies-Black Publishing.
- Myers, I. B., MCCAuley, M.H. (1985). *A guide to the development and use of the Myers-Briggs Type Indicator*. Palo Alto, CA: Consulting Psychologists Press.
- Neves, P. Sistema de Recomendação Inteligente para uma Plataforma de *E-learning*. (2014). *Dissertação de Mestrado em Informática e Sistemas*. Departamento de Engenharia Informática. Instituto Superior de Engenharia de Coimbra, Coimbra.
- Nunamaker, J.F., Chen, M., Purdin, T.D.M. (1990-91). Systems development in information systems research. *Journal of Management Information Systems*, 7, 3, 89-106.
- Organizing for Action*, (2012). <https://www.my.barackobama.com/page/community/post/> (Consultado em 12 de Setembro de 2012).
- Pecheanu, E., Stefanescu, D., Dumitriu, L. e Segal, C. (2011). “Methods to evaluate open source learning platforms”. *2011 IEEE Global Engineering Education Conference (EDUCON)*, pp. 1152-1161.
- Pessoa, M. de C., Benitti, F. B. V. (2008). Proposta de um processo para produção de objetos de aprendizagem. *Revista Hifen*, 32(62), 172–180.
- Piaget, J. (1953). *The origin of intelligence in the child*. New Fetter Lane, New York: Routledge & Kegan Paul.
- Picard, R. W. (1997). *Affective Computing*, MIT Press.
- Pinto-Ferreira, E., Costa-Lobo, C. (2009). Active learning in Large introductory Classes in Mathematic. Singapore: 5th International CDIO Conference. *Reframing Engineering Education: Impact and Future Direction*.
- Pittenger, David J. (1993). *Measuring the MBTI...And Coming Up Short*. *Journal of Career Planning and Employment* 54 (1): 48–52.

- Pratas E., Marques V.M. (2013). *Adaptive E-learning Systems Foundational Issues of the ADAPT Project*. In: Madureira A., Reis C., Marques V. (eds) Computational Intelligence and Decision Making. Intelligent Systems, Control and Automation: Science and Engineering, vol 61. Springer, Dordrecht.
- Primo, A. (2009). Conhecimento e interação: fronteiras entre o agir humano e inteligência artificial. In: Lemos, A.; Cunha, P. (Eds.). *Olhares sobre a cibercultura*. Porto Alegre: Sulina, p. 37-56.
- Quinlan, J. (1986). Introduction of Decision Trees, *Machine learning*, vol. 1, no. 1, pp. 81-106.
- Rajkumar, N., Ramalingam, V. (2015). Cognitive intelligent tutoring system based on affective state. *Indian Journal of Science and Technology*, 8(24). <http://doi.org/10.17485/ijst/2015/v8i24/80145>.
- Read, J.C., MacFarlane, S.J., Casey, C., (2000). Where's the 'm' on the keyboard, mummy? In Womens'. Engineering Society.
- Read, J.C., MacFarlane, S.J., Casey, C., (2001). Can natural language recognition technologies be used to enhance the learning experience of young children? *Computers and Learning*.
- Reis, C., Machado, J.T., (2007). Computational Intelligence in Circuit Synthesis, *Journal of Advanced Computational Intelligence and Intelligent Informatics*, Fuji Technology Press, pp. 1122-1127, vol. 11, No. 9, Nov. 2007, ISSN 1343-0130.
- Ripley, B.D. (1996). *Pattern Recognition and Neural Networks*, Cambridge: Cambridge University Press.
- Rogers, C. (1989). *Sobre o Poder Pessoal*, 3ª. Edição, S. Paulo, Martins Fontes Editora.
- Rosenblatt, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6), 386-408.
- Rossi, M., Sein, M.K. (2003). Design research workshop: A proactive research approach. Paper presented at the Twenty-Sixth Information Systems Research Seminar in Scandinavia, Information Systems Research in Scandinavia Association, Haikko, Finland.
- Santos, M., Azevedo, C. (2005). *Data Mining - Descoberta de Conhecimento em Bases de Dados*, FCA - Editora de Informática.
- Schank, R. (1982). *Dynamic Memory: A Theory of Learning in Computers and People* (New York: Cambridge University Press).
- Scielo - The Scientific Electronic Library Online. <http://www.scielo.br/img/revistas/rem/v58n3/11f2.gif>. (Consultado em 10 de Setembro de 2017).
- SCORM Explained, (2018). <https://scorm.com/scorm-explained/technical-scorm/> (Consultado em 07 de Abril de 2018).
- Sério, T. (2005). The radical behaviorism and the psychology as science. *Revista brasileira de terapia comportamental e cognitiva*, São Paulo, v. 7, n. 2, p. 247-262.
- Shute, V. J., Psotka, J. (1994). Intelligent Tutoring Systems: Past, Present, and Future. *Human resources directorate manpower and personnel research division*. pp. 2-52.
- Silva, D. R., Seno, W. P., Vieira, M. T. P. (2001). Acompanhamento do Aprendizado em Educação a Distância com Uso de *Data Mining*. In: *Conferência Latinoamericana de Informática*, Mérida, Venezuela.
- Simões, T., Rodrigues, J., Torre, I. (2013). Personal Learning Environment Box (PLEBOX): A New Approach to *E-learning Platforms*, *Computer Applications In Engineering Education*, Vol. 21, N.º 1, pp. 100-109.

- Singh, H., Gupta, M. M., Meitzler, T., Hou, Z.-G., Garg, K. K., Solo, A. M. G., & Zadeh, L. A. (2013). Real-Life Applications of Fuzzy Logic. *Advances in Fuzzy Systems*. <http://doi.org/10.1155/2013/581879>.
- Tafner, M., Xerez, M., Filho, I. (1996). *Redes Neurais Artificiais: Introdução e Princípios de Neurocomputação*. Blumenau, SC: EKO.
- Takagi, T., Sugeno M. (1983). *Derivation of fuzzy control rules from human operator's control action*. IFAC Symposium on Fuzzy Information Knowledge.
- Takeda, H., Veerkamp, P., Tomiyama, T., Yoshikawam, H. Modeling. (1990). Design processes. *AI Magazine*, 11, 4, 37-48.
- Thorndike, E. (1932). *The Fundamentals of Learning*, AMS Press Inc., ISBN 0-404-06429-9.
- TIOBE Index, <https://www.tiobe.com/tiobe-index/>. (Consultado em 03 de Março de 2018).
- Training, test, and validation sets. (2018). https://en.wikipedia.org/wiki/Training,_test,_and_validation_sets. (Consultado em 22 de Fevereiro 2018).
- Van Aken, J. (2004). Management research based on the paradigm of the design sciences: The quest for field-tested and grounded technological rules. *Journal of Management Studies*, 41, 219-246.
- VanLehn, K. (2006). The behavior of tutoring systems. *Int. J. Artif. Intell. Educ.* 16, 3, 227–265.
- VanLehn, K. (2011). The Relative Effectiveness of Human Tutoring, Intelligent Tutoring Systems, and Other Tutoring Systems. *Educational Psychologist*, 46(4), 197–221. doi:10.1080/00461520.2011.611369.
- VARK. (2017). VARK a guide to learning styles. <http://www.vark-learn.com/introduction-to-vark/research-statistics/>. (Consultado em 24 de Setembro de 2017).
- Walls, J., Widmeyer, G., El Sawy. (1992) O. Building an information system design theory for vigilant EIS. *Information Systems Research*, 3, 1, 36-59.
- Wangenhein, C. (2000). Case-based reasoning - a short introduction. *Relatório Técnico 02/00*. Federal University of Santa Catarina.
- Watson, J. B. (1913). Psychology as the Behaviorist Views it. *Psychological Review*, 20, p. 158-177.
- Watson, J. B. (1924). *Behaviorism*. New York: People's Institute Publishing Company.
- Wierstra, R. F. A., DeJong, J.A. (2002). *A scaling theoretical evaluation of Kolb's learning style inventory*.
- Xu, R., Wunsch, D. (2005). Survey of clustering algorithms, *IEEE Transactions on Neural Networks*, 16(3), pp. 645–678.
- Zadeh, Lofti (1973). *Fuzzy Sets. Outline of a New Approach to the Analysis of Complex Systems and Decision Process*. IEEE Transactions on Systems, Man and Cybernetics.
- Zimmermann, J. (1996). *Fuzzy Set Theory - and its applications*, 3rd Ed.

Apêndices

Apêndice A

Neste apêndice encontra-se o questionário de avaliação de *e-learning* apresentado no final do curso (Tabela 18). O questionário é constituído por 20 perguntas agrupadas por 5 categorias: Nível de interatividade, Impacto visual, Linguagem, Duração e Estrutura.

Tabela 18 - Questionário de avaliação de *e-learning*.

1. Nível de interatividade				
	Muito bom	Bom	Satisfatório	Mau
Como classifica a facilidade de navegação entre conteúdos?	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
É facilmente perceptível o que se deve fazer para avançar?	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
O nível de interatividade é adequado para os conteúdos exibidos?	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
Classifique a qualidade das animações que foram apresentadas.	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
2. Impacto Visual				
	Muito bom	Bom	Satisfatório	Mau
Como avalia de forma geral a estética dos conteúdos do curso?	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
Considera que existe variedade suficiente nos tipos de conteúdos apresentados?	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
O curso é o que você esperava?	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
Encontrou elementos desnecessários que provocam distração?	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
3. Escrita				
	Muito bom	Bom	Satisfatório	Mau
Compreendeu completamente o que leu?	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
Considera que as frases estão bem escritas?	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
Os parágrafos são breves e sucintos?	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>

Avalie a legibilidade do texto e o tipo de letra utilizado.	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
4. Duração				
	Muito bom	Bom	Satisfatório	Mau
Como classifica o ritmo a que o curso avança?	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
Como avalia o tempo necessário para completar o curso?	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
Como avalia o tempo despendido por página (objeto de aprendizagem)?	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
Considera que a utilização da plataforma permite diminuir o tempo de estudo sem prejudicar a aprendizagem?	<input type="checkbox"/> Sim		<input type="checkbox"/> Não	
5. Estrutura				
	Muito bom	Bom	Satisfatório	Mau
Avalie a qualidade técnica dos materiais do curso.	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
O curso de <i>e-learning</i> seguiu uma direção clara?	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
Como classifica o contributo da utilização da plataforma na melhoria do seu conhecimento em relação aos temas abordados?	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
Preferiria fazer este curso <i>on-line</i> ou numa sala de aula?	<input type="checkbox"/> On-line		<input type="checkbox"/> Sala de aula	

Apêndice B

Neste apêndice encontra-se o questionário ILS apresentado no início do curso e que é responsável por determinar o perfil de aprendizagem do aluno (Tabela 19). O questionário é constituído por 44 perguntas agrupadas em 4 dimensões: Ativo/Reflexivo, Sensorial/Intuitivo, Visual/Verbal, Sequencial/Global. A tabela seguinte apresenta as 44 perguntas e respetivas respostas disponíveis do ILS.

Tabela 19 - Index of Learning Styles (ILS)

1. Eu entendo algo melhor depois de			
A		B	
experimentá-lo.	<input type="checkbox"/>	pensar sobre isso.	<input type="checkbox"/>
2. Eu prefiro ser considerado			
A		B	
realista..	<input type="checkbox"/>	inovador.	<input type="checkbox"/>
3. Quando penso sobre o que fiz ontem, sou mais propenso a recorrer a			
A		B	
uma imagem.	<input type="checkbox"/>	palavras.	<input type="checkbox"/>
4. Eu costumo			
A		B	
compreender os detalhes de um assunto, mas posso ficar confuso sobre a sua estrutura global.	<input type="checkbox"/>	compreender a estrutura geral, mas posso ficar confuso sobre os detalhes.	<input type="checkbox"/>
5. Quando estou a aprender algo novo, ajuda-me			
A		B	
falar sobre isso.	<input type="checkbox"/>	pensar sobre isso.	<input type="checkbox"/>
6. Se fosse um professor, eu preferiria ensinar um curso			
A		B	
que lida com factos e situações da vida real.	<input type="checkbox"/>	que lida com ideias e teorias.	<input type="checkbox"/>
7. Eu prefiro obter novas informações em			
A		B	
imagens, diagramas, gráficos ou mapas.	<input type="checkbox"/>	direções escritas ou informações verbais.	<input type="checkbox"/>

8. Depois de eu entender			
A		B	
todas as partes, entendo o todo.	<input type="checkbox"/>	o todo, eu percebo como as partes se encaixam.	<input type="checkbox"/>
9. Num grupo de estudos trabalhando em matérias difíceis, eu sou mais propenso a			
A		B	
entrar e contribuir com ideias.	<input type="checkbox"/>	sentar e ouvir.	<input type="checkbox"/>
10. Acho que é mais fácil			
A		B	
aprender factos.	<input type="checkbox"/>	aprender conceitos.	<input type="checkbox"/>
11. Num livro com muitas imagens e gráficos, eu provavelmente			
A		B	
examino as imagens e gráficos com cuidado.	<input type="checkbox"/>	concentro-me no texto escrito.	<input type="checkbox"/>
12. Quando resolvo problemas de matemática			
A		B	
costumo trabalhar o meu caminho para as soluções, um passo de cada vez.	<input type="checkbox"/>	costumo trabalhar o meu caminho para as soluções, um passo de cada vez.	<input type="checkbox"/>
13. Nas aulas a que assisti			
A		B	
eu normalmente cheguei a conhecer a maior parte dos alunos.	<input type="checkbox"/>	eu normalmente cheguei a conhecer a maior parte dos alunos.	<input type="checkbox"/>
14. Na leitura não ficcionada, eu prefiro			
A		B	
algo que me ensina factos novos ou me diz como fazer alguma coisa.	<input type="checkbox"/>	algo que me ensina factos novos ou me diz como fazer alguma coisa.	<input type="checkbox"/>
15. Eu gosto de professores			
A		B	
que colocam muitos diagramas no quadro.	<input type="checkbox"/>	que passam muito tempo a explicar.	<input type="checkbox"/>
16. Quando estou a analisar uma história ou um romance			
A		B	
penso nos incidentes e tento colocá-los juntos para descobrir os temas.	<input type="checkbox"/>	só sei o que os temas são quando termino de ler e então tenho que voltar a trás e encontrar os incidentes que eles demonstram.	<input type="checkbox"/>

17. Quando eu começo um problema de um trabalho de casa, sou mais propenso a			
A		B	
começar imediatamente a trabalhar sobre a solução.	<input type="checkbox"/>	tentar compreender o problema em primeiro lugar.	<input type="checkbox"/>
18. Eu prefiro a ideia de			
A		B	
certeza.	<input type="checkbox"/>	teoria.	<input type="checkbox"/>
19. Lembro-me melhor			
A		B	
do que vejo.	<input type="checkbox"/>	do que ouço.	<input type="checkbox"/>
20. É mais importante para mim que um instrutor			
A		B	
disponha o material em etapas sequenciais claras.	<input type="checkbox"/>	me dê uma visão global e relacione o material com outros assuntos.	<input type="checkbox"/>
21. Eu prefiro estudar			
A		B	
num grupo de estudo.	<input type="checkbox"/>	sozinho.	<input type="checkbox"/>
22. É mais provável eu ser considerado			
A		B	
cuidadoso com os detalhes do meu trabalho.	<input type="checkbox"/>	criativo sobre como faço o meu trabalho.	<input type="checkbox"/>
23. Quando eu obtenho direções para um novo lugar, prefiro			
A		B	
um mapa.	<input type="checkbox"/>	instruções escritas.	<input type="checkbox"/>
24. Eu aprendo			
A		B	
a um ritmo bastante regular. Se estudar bastante, eu compreendo.	<input type="checkbox"/>	irregularmente. Ficarei totalmente confuso e, de repente, dá-se um “clique”.	<input type="checkbox"/>
25. Eu prefiro primeiro			
A		B	
experimentar as coisas.	<input type="checkbox"/>	pensar em como vou fazer.	<input type="checkbox"/>
26. Quando eu leio por lazer, gosto de escritores que			

A	B
dizem claramente o que pretendem. <input type="checkbox"/>	dizem coisas de maneira criativa e interessante. <input type="checkbox"/>
27. Quando vejo um diagrama ou desenho numa sala de aula, sou mais propenso a lembrar-me	
A	B
da imagem. <input type="checkbox"/>	do que o professor disse sobre isso. <input type="checkbox"/>
28. Ao considerar um conjunto de informações, eu sou mais propenso a	
A	B
concentrar-me em detalhes e perder o quadro geral. <input type="checkbox"/>	tentar entender o quadro geral antes de entrar em detalhes. <input type="checkbox"/>
29. Eu lembro-me com mais facilidade de	
A	B
algo que eu tenha feito. <input type="checkbox"/>	algo que eu tenha pensado muito sobre. <input type="checkbox"/>
30. Quando eu tenho que executar uma tarefa, eu prefiro	
A	B
ganhar mestria numa das formas de a fazer. <input type="checkbox"/>	encontrar novas maneiras de a fazer. <input type="checkbox"/>
31. Quando alguém me está a mostrar dados, eu prefiro	
A	B
tabelas ou gráficos. <input type="checkbox"/>	texto que resume os resultados. <input type="checkbox"/>
32. Ao escrever um artigo, eu sou mais propenso a	
A	B
trabalhar (pensar ou escrever) o início do trabalho e depois progredir. <input type="checkbox"/>	trabalhar (pensar ou escrever) diferentes partes do artigo e, de seguida, ordená-las. <input type="checkbox"/>
33. Quando tenho que trabalhar num projeto de grupo, primeiro eu prefiro	
A	B
ter um “brainstorming” em grupo, onde todos contribuem com ideias. <input type="checkbox"/>	ter um “brainstorming” individual e, de seguida, juntar em grupo para comparar ideias. <input type="checkbox"/>
34. Considero um maior elogio chamar a alguém	
A	B
sensato. <input type="checkbox"/>	imaginativo. <input type="checkbox"/>
35. Quando encontro pessoas numa festa, eu sou mais propenso a lembrar-me	
A	B

de como se pareciam. <input type="checkbox"/>	do que disseram sobre si próprios. <input type="checkbox"/>
36. Quando eu estou a aprender um assunto novo, prefiro	
A	B
manter o foco sobre o assunto, aprendendo o máximo que puder. <input type="checkbox"/>	tentar fazer ligações entre esse assunto e assuntos relacionados. <input type="checkbox"/>
37. É mais provável eu ser considerado	
A	B
sociável. <input type="checkbox"/>	reservado. <input type="checkbox"/>
38. Eu prefiro cursos que enfatizam	
A	B
matérias concretas (factos, dados). <input type="checkbox"/>	matérias em abstrato (conceitos, teorias). <input type="checkbox"/>
39. Como entretenimento, eu prefiro	
A	B
ver televisão. <input type="checkbox"/>	ler um livro. <input type="checkbox"/>
40. Alguns professores começam as suas aulas com um esboço do que eles vão falar. Tais linhas são	
A	B
pouco úteis para mim. <input type="checkbox"/>	pensar sobre isso. <input type="checkbox"/>
41. A ideia de fazer um trabalho em grupo, com igual classificação para todo o grupo,	
A	B
pouco úteis para mim. <input type="checkbox"/>	muito úteis para mim. <input type="checkbox"/>
42. Quando eu estou a fazer cálculos longos,	
A	B
tenho tendência a repetir todos os meus passos e verificar o meu trabalho com cuidado. <input type="checkbox"/>	acho cansativo verificar o meu trabalho e tenho que me forçar a fazê-lo. <input type="checkbox"/>
43. Eu tendo a ter uma imagem dos lugares onde estive	
A	B
de forma fácil e com bastante precisão. <input type="checkbox"/>	com dificuldade e sem muito detalhe. <input type="checkbox"/>
44. Ao resolver problemas em grupo, é mais provável que eu	
A	B

pense nas etapas do processo de solução. <input type="checkbox"/>	pense em possíveis consequências ou aplicações da solução numa ampla variedade de áreas. <input type="checkbox"/>
---	---

Na Tabela 20 apresentam-se os fatores associados a cada uma das perguntas do ILS e a respetiva dimensão.

Tabela 20 - Fatores dos *Items* da solução do questionário Felder-Silverman (Litzinger, et al., 2005).

<i>Dimensão</i>	<i>Perguntas</i>	<i>Fatores</i>
<i>Sensorial/Intuitivo</i>	38, 6, 18, 14, 2, 10, 34, 26, 22, 42, 30	Preferência por informação concreta (factos, dados, o “mundo real”) ou abstração (interpretações, teorias, modelos)
<i>Visual/Verbal</i>	7, 31, 23, 11, 15 27, 19, 3, 35, 43, 39	Informação formatada é a preferida como forma de <i>input</i> Informação formatada é a preferida para memorizar ou relembrar
<i>Sequencial/Global</i>	20, 36, 44, 8, 12, 32, 24 28, 4, 16, 40	Pensamento Linear/sequencial ou aleatório/holístico Ênfase no detalhe (árvores) ou na totalidade (floresta)
<i>Ativo/Reflexivo</i>	25, 1, 29, 5, 17 37, 13, 9 21, 33, 41	Age primeiro ou pensa primeiro Extrovertido ou reservado Atitude favorável ou não favorável em relação ao trabalho de grupo