

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

JOEL LUIS CARBONERA

**Um arcabouço cognitivamente inspirado  
para representação de conhecimento e  
raciocínio**

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

Orientador: Profa. Dra. Mara Abel

Porto Alegre  
outubro de 2016

## CIP – CATALOGAÇÃO NA PUBLICAÇÃO

Carbonera, Joel Luis

Um arcabouço cognitivamente inspirado para representação de conhecimento e raciocínio / Joel Luis Carbonera. – Porto Alegre: PPGC da UFRGS, 2016.

180 f.: il.

Tese (doutorado) – Universidade Federal do Rio Grande do Sul. Programa de Pós-Graduação em Computação, Porto Alegre, BR–RS, 2016. Orientador: Mara Abel.

1. Representação de conhecimento e raciocínio. 2. Abordagem híbrida para representação de conhecimento. 3. Abordagem híbrida para raciocínio. 4. Similaridade. 5. Abordagens para seleção de instâncias. I. Abel, Mara. II. Título.

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL

Reitor: Carlos Alexandre Netto

Pró-Reitor de Coordenação Acadêmica: Rui Vicente Oppermann

Pró-Reitora de Pós-Graduação: Vladimir Pinheiro do Nascimento

Diretor do Instituto de Informática: Luís da Cunha Lamb

Coordenador do PPGC: Prof. Luigi Carro

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

*“— The real voyage of discovery consists not in seeking new landscapes, but in  
having new eyes.”*

— MARCEL PROUST

*“— Experience is a flame which cannot illuminate without burning.”*

— BENITO PÉREZ GALDÓS



## AGRADECIMENTOS

Inicialmente, eu gostaria de agradecer à UFRGS, ao Instituto de Informática e ao PPGC por acolher os projetos que venho desenvolvendo na instituição desde 2009. Agradeço por todo o suporte oferecido durante este período, sem o qual este projeto não teria acontecido.

Eu gostaria também de agradecer ao programa PRH PB-17, mantido pela ANP/Petrobras. Este programa foi a principal fonte dos recursos financeiros necessários para realizar este projeto.

Agradeço à professora Mara Abel, por orientar o desenvolvimento deste projeto. Agradeço principalmente pela paciência demonstrada, pelas experiências compartilhadas, pela confiança em mim depositada, por todo o suporte oferecido e por todas as oportunidades oferecidas. Eu não seria capaz de listar todas as razões pelas quais eu gostaria de agradecer à professora Mara.

Agradeço ao professor Claiton Marlon dos Santos Scherer, do departamento de Geociências da UFRGS, pelo tempo dedicado e pela disposição em participar da realização deste projeto. Agradeço principalmente pela paciência demonstrada durante as conversas sobre Estratigrafia Sedimentar com um leigo.

Agradeço a todos os membros do grupo BDI, por proporcionaram um ambiente aberto e prolífico para discussão de ideias. Este ambiente foi fundamental para o amadurecimento das ideias desenvolvidas nesta tese. Sou grato a todos os amigos e colegas que passaram pelo grupo nos últimos anos: Alexandre Lorenzatti, Bruno Zanette, Cauã Roca Antunes, Eduardo Bassani Chandelier, Gabriel Moser, Guilherme Schievelbein, Jose Lozano, Luan Fonseca Garcia, Ricardo Linck, Ricardo Werlang e Vinicius Medeiros Grazioli. Agradeço principalmente ao Sandro Rama Fiorini pelo apoio no desenvolvimento dos meus projetos, pela disponibilidade em discutir as ideias que desenvolvi nesta tese, pelas importantes sugestões e, sobretudo, pela amizade. Também gostaria de agradecer ao Vitor Machado Jorge, ao Vitor Fortes Rey e ao professor Edson Prestes; colegas e amigos que foram fundamentais para o desenvolvimento de projetos muito gratificantes durante este período. Sou grato a todas essas pessoas pelas conversas prolíficas, pelos longos e reveladores debates filosóficos, pelas importantes sugestões e também pelos momentos de descontração que tornaram a realização desse trabalho ainda mais agradável.

Agradeço aos grandes amigos Douglas Ceccagno, Fábio Valle, Jônatas Luis Maria, Juliana Soares, Juliano Fontanive Dupont, Rafael (Teclas) Vignatti, Renata Todeschini e Vagner Perondi. Agradeço sobretudo por me acompanharem nesta caminhada. Agradeço pela motivação constante, pelas conversas intelectualmente instigantes e por todos os grandes momentos que vivemos juntos.

Agradeço aos meus pais, José Carlos Carbonera e Maria Dolores Bés Carbonera, pelo esforço em garantir a minha educação, pelo apoio, incentivo, dedicação e compreensão durante todos os momentos da minha vida. Agradeço por sempre confiarem em meu julgamento e nunca duvidarem de minhas capacidades. Agradeço à minha irmã, Jocinara Carbonera, por todo apoio durante a realização dos meus projetos.

Agradeço à minha namorada, Marina Dal Ponte, pela paciência necessária para viver a realização deste projeto comigo. Agradeço sobretudo pelo apoio fornecido nos momentos de dúvida e apreensão. Agradeço também por todos os vários e constantes momentos felizes que vivemos juntos. Esses momentos foram determinantes para continuar o trabalho com energia renovada.

## RESUMO

Seres humanos são capazes de desenvolver complexas estruturas de conhecimento que podem ser utilizadas de modo flexível para lidar com o ambiente de maneira apropriada. Estas estruturas de conhecimento constituem um núcleo que suporta processos cognitivos, tais como a percepção, a categorização, o planejamento, etc. A Inteligência Artificial, enquanto área de investigação, ocupa-se de desenvolver meios que viabilizem a reprodução destas capacidades cognitivas em agentes artificiais. Por este motivo, a investigação de abordagens que permitam a representação de conhecimento de um modo flexível se revela altamente relevante.

Com o objetivo de superar algumas das limitações típicas da teoria clássica, que é adotada por várias abordagens propostas na Inteligência Artificial, este trabalho propõe um arcabouço cognitivamente inspirado para representação de conhecimento e raciocínio que integra aspectos de três diferentes teorias cognitivas a respeito de como conceitos são representados na cognição humana: teoria clássica, teoria do protótipo e teoria do exemplar. O arcabouço resultante é capaz de suportar a composicionalidade, a tipicidade, a representação de instâncias atípicas dos conceitos, e a representação da variabilidade de indivíduos classificados por cada conceito. Consequentemente, o arcabouço proposto também suporta raciocínio lógico e baseado em similaridade.

As principais contribuições deste trabalho são a concepção teórica e a formalização de um arcabouço cognitivamente inspirado para representação de conhecimento e raciocínio. Uma outra contribuição deste trabalho é uma abordagem de raciocínio para classificação que utiliza a abordagem de representação de conhecimento proposta. Além disso, este trabalho também apresenta duas abordagens para seleção de exemplares representativos de cada conceito e uma abordagem para extração de protótipos de conceitos.

Nesta tese também é apresentado um sistema para interpretação automática de processos deposicionais que adota o arcabouço proposto. Experimentos realizados em uma tarefa de classificação sugerem que o arcabouço proposto é capaz de oferecer classificações mais informativas que as oferecidas por uma abordagem puramente clássica.

**Palavras-chave:** Representação de conhecimento e raciocínio. Abordagem híbrida para representação de conhecimento. Abordagem híbrida para raciocínio. Similaridade. Abordagens para seleção de instâncias.





## ABSTRACT

Human beings can develop complex knowledge structures that can be used for dealing with the environment in suitable ways. These knowledge structures constitute a core that supports several cognitive processes, such as perception, categorization, planning, etc. The Artificial Intelligence, as a research field, aims at developing approaches for mimicking these cognitive capabilities in machines. Due to this, it is important to investigate approaches that allow representing the knowledge in flexible ways.

In order to overcome some limitations of the classical theory of knowledge representation, which is adopted by several approaches proposed in the Artificial Intelligence field, this work proposes a cognitively-inspired framework for knowledge representation and reasoning which integrates aspects from three different cognitive theories about concept representation in the human cognition: classical theory, prototype theory and exemplar theory. The resulting framework can support compositionality, typicality, representation of atypical instances of concepts, and representation of the variability of the individuals classified by each concept. Consequently, the proposed framework also supports logical reasoning and similarity-based reasoning.

The main contributions of this work are the formalization of a cognitively-inspired framework for knowledge representation and reasoning, two approaches for selecting representative exemplars of each concept and an approach of reasoning for classification that integrates logical reasoning and similarity-based reasoning and that is supported by definitions, prototypes and exemplars of concepts.

This thesis also presents a system for automatic interpretation of depositional processes application that adopts the proposed framework. The experiments, which were performed on a classification task, suggest that the proposed framework provides classifications that are more informative than the ones provided by a classical approach.

**Keywords:** knowledge representation and reasoning, instance-based classification, instance selection approaches.



## LISTA DE FIGURAS

Figura 2.1	Esquema ilustrando um caso de semelhança de família.....	30
Figura 3.1	Esquema ilustrando uma representação híbrida do conceito de cachorro, incluindo definição, protótipos e exemplares.....	59
Figura 3.2	Exemplo de representação espacial de indivíduos.....	60
Figura 3.3	Exemplo de extração de centroides locais.....	67
Figura 3.4	Visão geral do processo de raciocínio.....	70
Figura 3.5	Exemplo de processo de classificação de um indivíduo de acordo com a estratégia híbrida proposta.....	75
Figura 3.6	Ilustração do conceito de conjunto local.....	81
Figura 3.7	Ilustração do conceito de internalidade e de nível de ruído potencial.....	82
Figura 3.8	Exemplo ilustrativo de aplicação do algoritmo ASBI.....	84
Figura 3.9	Exemplo ilustrativo de aplicação do algoritmo LDIS.....	87
Figura 4.1	Exemplo de afloramento de rocha.....	89
Figura 4.2	Exemplo de testemunho de sondagem.....	90
Figura 4.3	Ambientes sedimentares.....	91
Figura 4.4	Exemplo de fácies sedimentar.....	92
Figura 4.5	Exemplo de estrutura sedimentar.....	93
Figura 4.6	Exemplo de estrutura sedimentar.....	93
Figura 4.7	Exemplo de estrutura sedimentar.....	94
Figura 4.8	Esquema do processo de interpretação de processos deposicionais.....	95
Figura 4.9	Representação esquemática da arquitetura do sistema para interpretação de processos deposicionais.....	97
Figura 4.10	Representação do núcleo do modelo de conhecimento clássico adotado na aplicação para interpretação de processos deposicionais.....	99
Figura 4.11	Diagrama de classes UML que representa a taxonomia de Processos Deposicionais.....	100
Figura 4.12	Diagrama de classes UML que representa a taxonomia de Estruturas Sedimentares.....	101
Figura 4.13	Exemplo de conversão de um indivíduo OWL para vetor de características.....	102
Figura 5.1	Representação da quantidade de instâncias de cada tipo de processo deposicional presente no conjunto de dados.....	106
Figura 5.2	Gráfico ilustrando a variação da quantidade de interpretações em cada classe obtidas pela abordagem híbrida proposta na tese, em função do parâmetro <i>limiar</i> .....	111
Figura A.1	Esquema de validação cruzada adotada.....	144
Figura A.2	Comparação do tempo de execução dos algoritmos de seleção de instâncias.....	148



## LISTA DE TABELAS

Tabela 5.1 Variação da quantidade de interpretações em cada classe obtidas pela abordagem híbrida proposta na tese, em função da variação dos valores do parâmetro <i>limiar</i> , adotando-se o parâmetro $n = 4$ . Tais resultados também são comparados com as interpretações obtidas por uma abordagem puramente clássica. ....	110
Tabela 5.2 Variação da quantidade de interpretações em cada classe obtidas pela abordagem híbrida proposta na tese, em função da variação dos valores do parâmetro $n$ , adotando-se o parâmetro <i>limiar</i> = 0.0. ....	112
Tabela 5.3 Variação da quantidade de interpretações em cada classe obtidas pela abordagem híbrida proposta na tese, em função da variação dos valores do parâmetro $k$ do algoritmo LDIS, adotando-se o parâmetro <i>limiar</i> = 0.0 e o parâmetro $n = 4$ . Também são apresentadas as taxas de redução média do conjunto de exemplares obtidas pela aplicação do algoritmo LDIS, com cada valor de $k$ , bem como os resultados das interpretações realizadas sem a utilização do algoritmo LDIS e os resultados das interpretações realizadas pela abordagem clássica. ....	113
Tabela 5.4 Comparação da performance de 4 abordagens: a abordagem proposta (adotando a $MAC$ ), a abordagem que adota a $MAC_P$ , a abordagem que adota a $MAC_E$ e a abordagem clássica. ....	116
Tabela A.1 Detalhes dos conjuntos de dados utilizados nos experimentos. ....	142
Tabela A.2 Comparação da <i>acurácia</i> alcançada pelo conjunto de instâncias selecionado por cada algoritmo de seleção de instâncias em cada um dos conjuntos de dados. ....	145
Tabela A.3 Comparação da <i>redução</i> alcançada por cada algoritmo de seleção de instâncias em cada um dos conjuntos de dados. ....	146
Tabela A.4 Comparação da <i>eficiência</i> alcançada por cada algoritmo de seleção de instâncias em cada um dos conjuntos de dados. ....	147
Tabela A.5 Comparação da <i>acurácia</i> alcançada pelo algoritmo LDIS, com diferentes valores de $k$ , para cada conjunto de dados. ....	149
Tabela A.6 Comparação da <i>redução</i> alcançada pelo algoritmo LDIS, com diferentes valores de $k$ , para cada conjunto de dados. ....	150
Tabela A.7 Comparação da <i>eficiência</i> alcançada pelo LDIS, com diferentes valores de $k$ , para cada conjunto de dados. ....	151



## SUMÁRIO

<b>1 INTRODUÇÃO</b> .....	<b>17</b>
<b>1.1 Contexto</b> .....	<b>17</b>
<b>1.2 Motivação</b> .....	<b>19</b>
<b>1.3 Hipóteses e objetivos</b> .....	<b>21</b>
<b>1.4 Escopo</b> .....	<b>22</b>
<b>1.5 Contribuições</b> .....	<b>22</b>
<b>1.6 Estrutura da tese</b> .....	<b>24</b>
<b>2 REVISÃO DA LITERATURA</b> .....	<b>25</b>
<b>2.1 Fundamentos cognitivos</b> .....	<b>25</b>
2.1.1 Conceitos.....	25
2.1.2 Teorias sobre representação de conceitos .....	27
2.1.2.1 Teoria clássica .....	27
2.1.2.2 Teoria do protótipo.....	32
2.1.2.3 Teoria do exemplar.....	34
2.1.2.4 Teorias híbridas e pluralistas.....	35
<b>2.2 Representação de conhecimento e raciocínio na Ciência da Computação</b> .....	<b>36</b>
2.2.1 Abordagens clássicas para representação de conhecimento .....	39
2.2.1.1 Lógica de descrição.....	39
2.2.1.2 OWL.....	41
2.2.2 Extensões de abordagens clássicas .....	43
2.2.2.1 Integração entre lógica de descrição e lógica default .....	43
2.2.2.2 Extensão de lógica de descrição com circunscrição .....	44
2.2.2.3 Lógica de descrição com operador de typicalidade .....	45
2.2.3 Abordagens híbridas .....	46
2.2.3.1 Integração de abordagem clássica com protótipos.....	46
2.2.3.2 Ontologias com múltiplos protótipos.....	47
2.2.3.3 Representação de typicalidade e significados vagos em ontologias .....	48
2.2.3.4 Integração de abordagem clássica, protótipos e exemplares.....	49
<b>2.3 Abordagens para seleção de instâncias</b> .....	<b>51</b>
<b>3 ABORDAGEM COGNITIVAMENTE INSPIRADA PARA REPRESENTAÇÃO DE CONHECIMENTO E RACIOCÍNIO</b> .....	<b>55</b>
<b>3.1 Visão geral da proposta</b> .....	<b>55</b>
<b>3.2 Arcabouço híbrido para representação de conhecimento</b> .....	<b>60</b>
<b>3.3 Estratégia de raciocínio híbrido para classificação</b> .....	<b>64</b>
3.3.1 Medida de ajustamento conceitual.....	66
3.3.2 Combinando informações clássicas, protótipos e exemplares .....	70
<b>3.4 Abordagens para extração de protótipos e seleção de exemplares</b> .....	<b>77</b>
3.4.1 Abordagem para extração de protótipos .....	77
3.4.2 Abordagens para seleção de exemplares.....	79
3.4.2.1 Abordagem para identificação de instâncias limítrofes .....	80
3.4.2.2 Abordagem baseada em densidade local para identificação de instâncias representativas .....	85
<b>4 APLICAÇÃO DA ABORDAGEM PROPOSTA</b> .....	<b>89</b>
<b>4.1 Visão geral da Estratigrafia Sedimentar</b> .....	<b>89</b>
<b>4.2 Uma abordagem para interpretação de processos deposicionais</b> .....	<b>95</b>
<b>5 AVALIAÇÃO</b> .....	<b>105</b>
<b>5.1 Experimento 1</b> .....	<b>109</b>
<b>5.2 Experimento 2</b> .....	<b>111</b>

<b>5.3 Experimento 3 .....</b>	<b>112</b>
<b>5.4 Experimento 4 .....</b>	<b>115</b>
<b>5.5 Discussão dos resultados.....</b>	<b>116</b>
<b>6 CONCLUSÃO .....</b>	<b>119</b>
<b>6.1 Principais contribuições .....</b>	<b>120</b>
6.1.1 Abordagem híbrida para representação de conhecimento .....	120
6.1.2 Abordagem híbrida para raciocínio .....	121
6.1.3 Abordagens para seleção de exemplares.....	122
6.1.4 Aplicação para interpretação de processos deposicionais .....	123
<b>6.2 Perspectivas de trabalhos futuros.....</b>	<b>125</b>
<b>REFERÊNCIAS.....</b>	<b>129</b>
<b>APÊNDICE A — AVALIAÇÃO DOS ALGORITMOS LDIS E ASBI NA TA- REFA DE SELEÇÃO DE INSTÂNCIAS.....</b>	<b>141</b>
<b>APÊNDICE B — MODELO DE CONHECIMENTO CLÁSSICO.....</b>	<b>153</b>
<b>APÊNDICE C — CONJUNTO DE DADOS SOBRE FÁCIES SEDIMENTARES</b>	<b>175</b>



## 1 INTRODUÇÃO

Nesta tese, é proposto um arcabouço híbrido para representação de conhecimento e raciocínio. Nas próximas seções serão apresentados o contexto em que esta tese se insere, as motivações, as hipóteses e objetivos, os resultados alcançados e a estrutura geral da tese.

### 1.1 Contexto

É notória a capacidade que o ser humano possui de processar o constante fluxo de estímulos não estruturados que chegam do ambiente a sua volta através dos sentidos, gerando conhecimento estruturado, que pode ser utilizado de modo flexível para lidar com o ambiente da maneira apropriada. Estas estruturas de conhecimento constituem a base que suporta processos cognitivos realizados por seres humanos, tais como a percepção, a categorização, o planejamento, etc. A Inteligência Artificial, enquanto área de investigação, ocupa-se de desenvolver meios que viabilizem a reprodução destas capacidades cognitivas em máquinas. Por este motivo, a investigação de abordagens que permitam a representação de conhecimento de um modo flexível se revela altamente relevante.

Em geral, assume-se que o conhecimento, em um nível abstrato, é constituído por unidades denominadas *conceitos* e por relações entre conceitos (MURPHY, 2002). No entanto, a natureza da noção de conceito ainda está em debate nas ciências cognitivas, apesar do protagonismo que esta noção exerce nos estudos da área (PICCININI; SCOTT, 2006; WEISKOPF, 2009; GONNERMAN; WEINBERG, 2010; KEIL, 2010; SCARANTINO, 2010; VICENTE; MANRIQUE, 2014). De acordo com (MURPHY, 2002), atualmente, existem diversas teorias a respeito do que são os conceitos. Dentre estas teorias, a chamada *teoria clássica* é uma das mais intuitivas, de modo que costuma ser adotada em concepções ingênuas a respeito da cognição. Esta teoria remete à concepção aristotélica a respeito dos conceitos e afirma que conceitos são *definições*, estabelecidas em termos de *condições necessárias e suficientes* que as entidades devem atender para serem considerados instâncias dos conceitos. Entre as principais vantagens desta teoria, está o fato de que ela oferece um suporte direto para *raciocínio lógico* e para a *composicionalidade* (capacidade que permite definir o significado de conceitos em termos dos significados de outros conceitos).

No entanto, estudos realizados pelas ciências cognitivas, tais como os apresentados em (ROSCH, 1973; ROSCH; MERVIS, 1975; ROSCH, 1975b; ROSCH, 1975a; ROSCH; SIMPSON; MILLER, 1976; ROSCH, 1978), vêm levantando diversas objeções à adoção desta concepção como uma teoria a respeito da natureza dos conceitos. Por exemplo, para a maior parte dos conceitos, encontrar condições necessárias e suficientes

é uma tarefa não trivial. Além disso, em geral, estudos (ROSCH; SIMPSON; MILLER, 1976) sugerem que os seres humanos tendem a considerar algumas instâncias de um conceito mais *típicas* que outras e que tendem a raciocinar com base em informações típicas. Este tipo de comportamento, relacionado à noção de *tipicalidade*, não é explicada pela teoria clássica. Outras fontes de evidência (CANTOR et al., 1980) também sugerem que seres humanos são capazes de realizar classificação de novos objetos com base na similaridade destes objetos com objetos previamente conhecidos ou com protótipos (objetos ideais de uma determinada categoria). No entanto, a concepção clássica também não oferece uma boa base para classificação com base em similaridades.

Devido às dificuldades encontradas pela teoria clássica em lidar com diversos fenômenos cognitivos, teorias alternativas à teoria clássica vêm sendo propostas nas ciências cognitivas (MURPHY, 2002). Por exemplo, a *teoria do protótipo* estabelece que cada conceito é representado por um ou mais protótipos e que a classificação de um novo objeto ocorre com base na *similaridade* entre o objeto e os protótipos dos conceitos. Já a *teoria do exemplar* estabelece que cada conceito é representado por um conjunto de objetos que exemplificam este conceito e que a classificação de um novo objeto é suportada pela *similaridade* entre o objeto e os exemplares dos conceitos. No entanto, nenhuma das teorias propostas têm se mostrado capaz de explicar a ampla gama de fenômenos cognitivos e de capacidades que os conceitos devem ser capazes de suportar. Propostas recentes sinalizam na direção de teorias híbridas, que concebem conceitos como entidades que integram diferentes tipos de informações.

Neste contexto, é interessante notar que a concepção clássica do conceito é adotada em muitas abordagens amplamente utilizadas na *Inteligência Artificial*. Em particular, muitos dos formalismos de representação de conhecimento utilizados atualmente (como lógicas de descrição e OWL) adotam esta concepção (GÄRDENFORS, 2004c). Devido a isto, apesar destes formalismos herdarem muitas das vantagens da concepção clássica dos conceitos, eles também herdam muitas das limitações desta concepção. Isto sugere que, apesar das abordagens clássicas suportarem com sucesso aspectos importantes da cognição, tais como o raciocínio lógico, tais abordagens não são suficientes para viabilizar processos com flexibilidade similar aos processos cognitivos humanos.

Do ponto de vista pragmático, as características do paradigma clássico limitam as possibilidades de inferências que as abordagens computacionais de representação de conhecimento são capazes de realizar. Por exemplo, uma vez que para um indivíduo  $i$  ser classificado em um determinado conceito  $c$ , é necessário que ele satisfaça todas as condições necessárias e suficientes de  $c$ , caso a descrição de  $i$  seja imperfeita (isto é, caso não sejam informadas todos os atributos e relações necessários para  $i$  atender às condições de  $c$ ), não é possível inferir que  $i$  é instância de  $c$ . No entanto, cenários em que a descrição dos indivíduos é imperfeita são muito comuns em problemas reais. Isto ocorre, por exemplo, em cenários nos quais os indivíduos devem ser caracterizados diretamente

por meio de medidas de sensores, como em sistemas de visão computacional. Além disso, uma abordagem baseada no paradigma clássico também não é capaz de inferir que  $i$  é instância de  $c$  em casos em que a definição de  $c$  não está completamente especificada. No entanto, conforme discutido em (PRESTES et al., 2013), em geral, a maior parte dos conceitos em modelos de conhecimento clássicos são definidos apenas em termos de *condições necessárias*. Em cenários como esses, abordagens baseadas na concepção clássica dos conceitos não são capazes de realizar inferências informativas.

## 1.2 Motivação

Nas últimas décadas, tem havido um aumento acelerado da quantidade de dados produzidos e disponibilizados para uso. Isto se deve a diversos fatores, tais como o aumento da capacidade de processamento e armazenamento, o aperfeiçoamento das tecnologias de redes e comunicação de dados, a popularização de plataformas sociais de publicação e compartilhamento de dados, a popularização de dispositivos capazes de coletar dados (como os *smartphones*), adoção em larga escala de sensores remotos, etc (CHE; SAFRAN; PENG, 2013; KAISLER et al., 2013; KATAL; WAZID; GOUDAR, 2013; CHEN; MAO; LIU, 2014; HASHEM et al., 2015). Além do volume de dados desafiar a capacidade analítica disponível, muitos desses dados são incompletos e ruidosos. Tal cenário demanda soluções automatizadas para análise e *classificação* de dados em larga escala. Tais soluções devem necessariamente ser robustas, resilientes e flexíveis, para produzir interpretações inteligentes desses dados, que sejam significativas para os especialistas humanos.

Além disso, a própria promessa da Web Semântica (BERNERS-LEE et al., 2001; SHADBOLT; BERNERS-LEE; HALL, 2006), bem como a própria atividade de busca de informações na web (SIEG; MOBASHER; BURKE, 2007; KASNECI et al., 2008), colocam a necessidade de soluções versáteis para representação de conhecimento e raciocínio. Em (GÄRDENFORS, 2004c), argumenta-se que a noção de web semântica, tal como foi originalmente proposta, herda diversas limitações típicas das abordagens de representação que seguem o paradigma clássico. Entre tais limitações, pode-se destacar, por exemplo, a impossibilidade de se classificar objetos com descrição imperfeita (em que nem todos os atributos são descritos) ou quando nem todos os conceitos são completamente definidos em termos de condições necessárias e suficientes (LIETO, 2012).

Do mesmo modo, na área da robótica, tem havido um aumento da complexidade dos comportamentos dos robôs, em diferentes tipos de tarefas, que incluem desde coleta de dados, até vigilância e resgate. Tais tarefas envolvem uma capacidade crescente de cooperação entre robôs e entre robôs e humanos, bem como flexibilidade e adaptação para lidar com um ambiente dinâmico (BAYAT et al., 2016). Tais objetivos demandam

a capacidade de representação de conhecimento complexo (TENORTH; BEETZ, 2009; PRESTES et al., 2013; CARBONERA et al., 2013; JORGE et al., 2015; FIORINI et al., 2015; BAYAT et al., 2016) e raciocínio flexível sobre os dados sensoriais capturados do ambiente (SUH et al., 2007; JOHNSTON et al., 2008; TENORTH et al., 2012). Por exemplo, em abordagens baseadas em conhecimento para reconhecimento visual de objetos em robôs, tais como as apresentadas em (STANTON; WILLIAMS, 2003; MENDOZA; WILLIAMS, 2005; LIM; SUH; SUH, 2011), é de fundamental importância a adoção de abordagens de raciocínio para classificação capazes de lidar com dados ruidosos, objetos com descrição imperfeita e com conceitos cujas definições não incluem condições necessárias e suficientes.

É importante também salientar que mesmo os sistemas baseados em conhecimento, de modo geral, poderiam ser beneficiados com abordagens mais flexíveis de representação de conhecimento e raciocínio. Em geral, sistemas baseados em conhecimento adotam uma abordagem *top-down*, na qual o conhecimento relevante para a resolução de problemas é explicitamente representado (geralmente em um paradigma clássico de representação) de uma forma computacionalmente processável e o processo de resolução de problemas envolve o processamento deste conhecimento representado. Esta abordagem pode ser aplicada em casos nos quais não há dados disponíveis para aplicar abordagens *bottom-up*, como as técnicas típicas de aprendizado de máquina. No entanto, sistemas baseados em conhecimento, que adotam um paradigma clássico de representação, costumam ser pouco *resilientes* (SMOLENSKY, 1987). Ou seja, sistemas deste tipo costumam não lidar adequadamente com casos que não se ajustam bem às restrições estabelecidas na representação de conhecimento adotada. Um dos aspectos apontados em (GÄRDENFORS, 2004b) como sendo um dos responsáveis pela falta de resiliência dos sistemas baseados em conhecimento é a rigidez típica da abordagem clássica de representação de conhecimento.

Os casos aqui discutidos constituem meros exemplos de um cenário mais amplo, no qual se faz presente a necessidade de abordagens de representação de conhecimento e raciocínio flexíveis e robustas, capazes de extrair o máximo de informação dos dados disponíveis, e capazes de possibilitar a realização de inferências mesmo em contextos nos quais os dados são ruidosos ou com descrição imperfeita e com modelos de conhecimento incompletos, nos quais nem todos os conceitos possuem definições estabelecidas em termos de condições necessárias e suficientes. Com inspiração nas evidências levantadas na Ciências Cognitivas, trabalhos como (FRANCONI; MAGNINI; STOCK, 1992; LIETO et al., 2015) buscam desenvolver abordagens para representação de conhecimento e raciocínio capazes de atender tais demandas, integrando informações clássicas sobre conceitos,

com protótipos e/ou exemplares. Tais abordagens podem ser consideradas como passos importantes para o desenvolvimento de uma abordagem híbrida efetiva para representação de conhecimento e raciocínio, no entanto, tais abordagens possuem pontos fracos que podem ser melhorados. O objetivo geral desta tese é contribuir neste sentido.

### 1.3 Hipóteses e objetivos

Neste trabalho, assumimos como hipótese principal que um arcabouço computacional para representação de conhecimento que concebesse conceitos como unidades que integram diferentes tipos de informação, suportaria a realização de tarefas intensivas em conhecimento de maneira mais *flexível* que as abordagens puramente clássicas. Esta flexibilidade se traduziria, por exemplo, na possibilidade do arcabouço lidar com contextos nos quais nem todos os conceitos possuem conjuntos de condições necessárias e suficientes completamente especificados, ou com contextos nos quais os objetos possuem descrição imperfeita. Tal capacidade seria viabilizada pela utilização de informações relativas a protótipos e exemplares, que suportariam *raciocínio baseado em similaridade* que, por sua vez, seria capaz de lidar com casos com os quais o *raciocínio clássico* não seria capaz de lidar.

Considerando a hipótese principal deste trabalho, assume-se como principal objetivo deste trabalho o desenvolvimento de um arcabouço cognitivamente inspirado para representação de conhecimento e raciocínio, que integre os principais aspectos das principais teorias cognitivas a respeito da representação de conceitos na cognição humana. Para alcançar este objetivo geral, a seguir, são enumerados os principais objetivos específicos que devem ser alcançados:

- Desenvolvimento de uma concepção teórica de como o conhecimento é representado, integrando diferentes tipos de aspectos sugeridos por diferentes teorias cognitivas.
- Formalização de um arcabouço híbrido para representação de conhecimento e raciocínio que supere as limitações das abordagens oferecidas pela literatura.
- Desenvolvimento de um procedimento de raciocínio capaz de manipular as representações propostas. Este trabalho foca especificamente em métodos de raciocínio para a tarefa de *classificação de objetos*, uma vez que esta tarefa surge como passo intermediário em diversas outras tarefas, tais como reconhecimento visual de objetos (STANTON; WILLIAMS, 2003; MENDOZA; WILLIAMS, 2005; LIM; SUH; SUH, 2011), planejamento (SCHLENOFF et al., 2003; GALINDO et al., 2008), diagnóstico (BERNARAS et al., 1996), etc.
- Avaliação do arcabouço desenvolvido.

Deste modo, o presente trabalho tem o intuito de contribuir para a linha de investigação desenvolvida em trabalhos como os discutidos em (FRANCONI; MAGNINI; STOCK, 1992; LIETO et al., 2015), complementando e aperfeiçoando algumas das noções e abordagens desenvolvidas nesses trabalhos.

#### **1.4 Escopo**

Uma vez que esta tese adota uma postura interdisciplinar, focando nas bordas de diversas áreas do conhecimento, tais como Inteligência Artificial, Psicologia Cognitiva e Filosofia, é importante estabelecer o escopo de abrangência da tese. Assim, apesar desta tese desenvolver um arcabouço cognitivamente inspirado para representação de conhecimento e raciocínio, não assumimos que o arcabouço resultante deve ser compreendido como uma formalização da cognição humana. O objetivo primário da tese é desenvolver meios que permitam o desenvolvimento de sistemas computacionais inteligentes capazes de manipular o conhecimento de modo flexível e robusto, de um modo que se assemelhe à performance cognitiva humana. Ou seja, pode-se compreender esta tese como um empreendimento primariamente pragmático. Deste modo, espera-se que esta tese contribua primeiramente para a área da Inteligência Artificial. A validade das abordagens desenvolvidas nesta tese para outras áreas do saber deve ser investigada em trabalhos futuros.

#### **1.5 Contribuições**

Entre as principais contribuições da tese, pode-se destacar a discussão teórica a respeito da integração de definições, exemplares e protótipos em representações de conceitos. Desta discussão, resulta outra contribuição importante da tese, que é a própria formalização de um arcabouço híbrido para representação de conhecimento e raciocínio. Esta formalização especifica a estrutura formal das *bases de conhecimento estendidas*, de acordo com os requisitos teóricos. É importante salientar que trabalhos anteriores que buscaram investigar este tema, tais como os apresentados em (FRANCONI; MAGNINI; STOCK, 1992; LIETO et al., 2015), não ofereceram uma caracterização formal geral da abordagem de representação adotada. Esta caracterização é importante para permitir a utilização geral do arcabouço em múltiplas aplicações computacionais.

Uma terceira contribuição desta tese é a estratégia de raciocínio híbrido para classificação, que adota o arcabouço de representação de conhecimento proposto nesta tese. Esta abordagem de raciocínio permite classificar indivíduos mesmo em contextos nos quais as informações que descrevem o indivíduo estão incompletas, ou nas quais os conceitos não possuem definições completas (com todas as condições necessárias e suficientes). A ideia geral da abordagem é utilizar o raciocínio clássico (baseado em condições

necessárias e suficientes) para gerar uma primeira classificação e, caso esta classificação não seja a mais específica (e informativa) possível, realizar ciclos de refinamento das classificações e de verificação de consistência das novas classificações obtidas. O ciclo se repete até que sejam alcançadas as interpretações mais específicas possíveis, ou não seja mais possível refinar as classificações. Nestes ciclos, o refinamento é realizado com base nas informações de exemplares e protótipos, enquanto a verificação de consistência é realizada com base nas definições clássicas dos conceitos, utilizando-se raciocínio clássico. Ou seja, nesta abordagem de raciocínio, assume-se uma postura mais arriscada, abrindo-se mão da segurança garantida pelo raciocínio puramente baseado em lógica, para alcançar classificações mais informativas. É importante salientar que, diferentemente da abordagem proposta em (FRANCONI; MAGNINI; STOCK, 1992), a abordagem de raciocínio proposta nesta tese utiliza de modo combinado tanto as definições dos conceitos, quanto os protótipos e exemplares. Além disso, diferentemente da abordagem proposta em (LIETO et al., 2015), a abordagem aqui proposta permite a classificação de uma instância em múltiplos conceitos.

Outras contribuições da tese são dois algoritmos para seleção de exemplares: o LDIS e o ASBI. Ambos os algoritmos podem ser utilizados para selecionar os exemplares (indivíduos representativos) dos conceitos em bases de conhecimento estendidas. O LDIS seleciona os exemplares de cada conceito que possuem a maior densidade local em uma dada vizinhança. Já o ASBI seleciona os exemplares limítrofes de cada conceito. É importante também salientar que tais algoritmos também podem ser utilizados para realizar *seleção de instâncias*, em etapas de pré-processamento de tarefas de Mineração de dados. A performance desses algoritmos nesta atividade também é avaliada neste trabalho.

Finalmente, esta tese também apresenta uma aplicação do arcabouço proposto para o desenvolvimento de um sistema para interpretação automática de processos deposicionais. A interpretação de processos deposicionais é uma tarefa realizada no domínio da Estratigrafia Sedimentar (que é uma subárea da Geologia), que é fundamental para determinar interpretações de ambientes sedimentares e para determinar a localização de reservas de recursos minerais. A aplicação desenvolvida ilustra como o arcabouço desenvolvido nesta tese pode ser utilizado para desenvolver sistemas baseados em conhecimento mais robustos e flexíveis. A aplicação foi avaliada em um conjunto de experimentos, utilizando-se um conjunto de dados reais, selecionados da literatura da área. Os resultados dos experimentos sugerem que o arcabouço proposto nesta tese possibilita que a aplicação ofereça interpretações mais informativas que as interpretações oferecidas por uma abordagem completamente clássica de representação de conhecimento e raciocínio.

## 1.6 Estrutura da tese

A presente tese possui a seguinte estrutura:

- O Capítulo 2 apresenta uma revisão da literatura, onde são discutidas noções e abordagens que são relevantes para este trabalho. Neste capítulo são apresentados os fundamentos cognitivos que nortearão o desenvolvimento teórico da proposta. Além disso, este capítulo também discute abordagens para representação de conhecimento propostas na Ciência da Computação, bem como abordagens para seleção de instâncias e abordagens para classificação baseada em instâncias.
- O Capítulo 3 apresenta as principais contribuições desta tese. Este capítulo discute a proposta do arcabouço híbrido para representação de conhecimento e raciocínio, apresenta a formalização do arcabouço de representação, bem como a abordagem de raciocínio híbrido para classificação e as abordagens para seleção de protótipos e seleção de exemplares.
- O capítulo 4 apresenta uma aplicação para interpretação automática de processos deposicionais, que foi desenvolvida adotando-se o arcabouço para representação de conhecimento e raciocínio proposto nesta tese. Inicialmente, este capítulo oferece uma visão geral a respeito do domínio da Estratigrafia Sedimentar e da tarefa de interpretação de processos deposicionais. A seguir, apresenta-se uma descrição do sistema desenvolvido.
- O capítulo 5 apresenta a avaliação da abordagem proposta nesta tese. Este capítulo descreve os resultados de experimentos conduzidos para avaliar os resultados alcançados pela aplicação descrita no Capítulo 4 durante a interpretação de um conjunto de descrições de fácies sedimentares reais.
- No Capítulo 6 são discutidas as principais conclusões desta tese, bem como algumas perspectivas de trabalhos futuros.



## 2 REVISÃO DA LITERATURA

Neste capítulo serão discutidos conceitos importantes da literatura que são relacionadas à proposta desta tese.

Na Seção 2.1 serão discutidas noções das Ciência Cognitivas que serão utilizadas como fonte de inspiração para o desenvolvimento deste trabalho.

Na Seção 2.2 serão discutidos os principais conceitos relacionados à área de *representação de conhecimento*, que é foco principal deste trabalho. Nesta Seção serão discutidos os principais formalismos de representação de conhecimento que seguem a chamada abordagem clássica: a lógica de descrição (do inglês *description logics*) e OWL (*Web Ontology Language*). Além disso, esta seção também discutirá abordagens desenvolvidas para lidar com as dificuldades encontradas nas abordagens clássicas.

Finalmente, uma vez que nesta tese são propostas abordagens para seleção de exemplares, na Seção 2.3 serão discutidas as principais abordagens para seleção de instâncias disponíveis na literatura.

### 2.1 Fundamentos cognitivos

Conforme estabelecido no Capítulo 1, este trabalho busca desenvolver um arcabouço formal integrado para representação de conhecimento e raciocínio, capaz de permitir a realização computacional de tarefas que em geral são realizadas por seres humanos usando seu conhecimento. Devido a isto, este trabalho busca inspiração nas concepções desenvolvidas nas Ciências Cognitivas a respeito de como o conhecimento é representado. Assim, na Seção 2.1.1 são discutidas as perspectivas elaboradas pelas Ciências Cognitivas sobre noções importantes para este trabalho, como a noção de conceito, para identificar um conjunto de requisitos desejáveis para um arcabouço computacional de representação de conhecimento. Já na Seção 2.1.2 são discutidas as principais teorias elaboradas pelas Ciências Cognitivas sobre como o conhecimento (com foco em conceitos) é representado na cognição humana.

#### 2.1.1 Conceitos

Uma investigação sobre como humanos utilizam seu conhecimento para realizar tarefas cognitivas necessariamente deve incluir uma investigação sobre a natureza dos *conceitos*, visto que intuitivamente eles são considerados as unidades que constituem o conhecimento e os blocos de construção do pensamento (FODOR et al., 1980).

Surpreendentemente, apesar da notória importância que a noção de *conceito* possui quando pensamos em fenômenos cognitivos, nas Ciências Cognitivas ainda persiste um intenso debate sobre o que são conceitos e qual a sua estrutura (como são representados).

Uma das visões mais aceitas sobre os conceitos é a de que eles constituem *representações mentais* de *classes de indivíduos*, que além de estabelecer o conteúdo propriamente dito (*o que é representado*), também especifica *como* esta informação é usada durante os processos de categorização (SMITH, 1989). De acordo com esta visão, as noções de *conceito* e *classe* (ou *categoria*) são diferenciadas, de modo que conceito se refere a uma ideia ou noção possuída mentalmente por alguém, enquanto classe (ou categoria) refere-se a um conjunto de entidades (do qual o conceito constitui uma representação mental). Assim, o conceito de *Cachorro* diz respeito a algum estado psicológico sobre *cachorros*, enquanto a categoria *Cachorro* consiste no conjunto de todas as entidades no mundo real que são apropriadamente consideradas como *cachorros*. No entanto, há controvérsias a respeito da questão de se categorias determinam conceitos ou vice-versa (GOLDSTONE; KERSTEN, 2003).

Segundo (GOLDSTONE; KERSTEN, 2003), um outro aspecto relevante relacionado aos conceitos é que eles estabelecem *classes de equivalência*. Ou seja, diferentes entidades, abstraídas por um mesmo conceito podem ser tratadas de modo equivalente, por alguma razão. Por exemplo, um biólogo que possui o conceito de *Mamífero* pode tratar *cachorros* e *baleias* como equivalentes sob diversos aspectos. Assim, a posse mental de um conceito nos permite enfatizar certos aspectos enquanto ignoramos outros, de modo que entidades perceptualmente muito distintas podem ser consideradas equivalentes. Este é o caso no exemplo fornecido por (BARSALOU, 1983) do conceito de *Coisas para tirar de casa em um incêndio*, que pode incluir desde joias a crianças.

Além disso, (GOLDSTONE; KERSTEN, 2003) também destaca que conceitos nos permitem realizar *predições indutivas*, nas quais somos capazes de generalizar nossas experiências com alguns objetos para outros objetos da mesma categoria. Por exemplo, se sabemos que uma determinada entidade pertence à categoria dos cachorros, então nós sabemos que ela provavelmente possui 4 patas, 2 olhos, late, etc.

Finalmente, conceitos podem ser vistos como um meio de viabilizar uma razoável *economia cognitiva*, uma vez que o armazenamento de conceitos é muito menos dispendioso do que armazenar cada estímulo bruto abstraído pelo conceito. De acordo com (MARKMAN, 1991), os conceitos nos permitem simplificar o ambiente a nossa volta, atuando como uma espécie de filtro através do qual capturamos apenas os aspectos relevantes do ambiente, reduzindo a sobrecarga de memória e nos permitindo *armazenar*

e *recuperar* informações de modo *eficiente*. Se percebêssemos cada aspecto do mundo como único, seríamos sobrecarregados pela diversidade do mundo e, considerando as nossas limitações cognitivas, não seríamos capazes de lembrar do que encontramos em uma fração de segundos.

Na Seção 2.1.2, serão discutidas as principais teorias que tentam explicar como os conceitos são representados na cognição humana.

## 2.1.2 Teorias sobre representação de conceitos

Nas Ciências Cognitivas há um grande debate a respeito de como os conceitos são representados na cognição humana. As três teorias mais conhecidas e debatidas são as chamadas *teoria clássica*, *teoria do protótipo* e *teoria do exemplar*. A seguir, as três teorias serão apresentadas em mais detalhes.

### 2.1.2.1 Teoria clássica

De acordo com (SMITH; MEDIN, 1981), a chamada *teoria clássica* dos conceitos estabelece que conceitos são representados por definições que devem especificar as *condições individualmente necessárias e conjuntamente suficientes* para um determinado indivíduo ser considerado membro da classe representada pelo conceito. Em geral, tais condições são estabelecidas em termos de características do indivíduo, de modo que a teoria clássica assume que a definição de um conceito *c* é especificada em função de características que são *comuns* a todas as instâncias do conceito *c* e que são consideradas como necessárias e suficientes. Assim, quando dizemos *condições individualmente necessárias*, isto significa que cada instância do conceito (ou membro da classe representada pelo conceito) deve necessariamente possuir tais características. Por outro lado, quando dizemos *condições conjuntamente suficientes*, isto significa que *toda e qualquer* entidade possuindo o conjunto de características definido por estas condições necessariamente deve ser instância do conceito definido por elas. Deste modo, de acordo com a teoria clássica, por exemplo, o conceito de *Cachorro* deveria especificar todas as características que são necessárias a todos os cachorros e que, conjuntamente, *apenas* cachorros possuem. Neste sentido *ser um animal* pode ser visto como uma condição (ou característica) necessária para todo cachorro, mas não é suficiente, porque existem animais que não são cachorros. Em geral, as características que são individualmente necessárias e conjuntamente suficientes são chamadas de *características definidoras* (ou definicionais ou definitórias).

Em (MURPHY, 2002) também é discutido que as definições dos conceitos podem envolver múltiplas características que estão relacionadas de uma forma complexa, através de conectivos lógicos como *OU* e *E*. Assim, eventualmente as definições são descritas como *regras* de classificação, que estabelecem se um dado indivíduo é ou não membro de uma categoria.

A teoria clássica também assume que, dados dois conceitos  $C_1$  e  $C_2$ , representando respectivamente as categorias  $cat_1$  e  $cat_2$ , e se  $cat_2 \subseteq cat_1$ , então as características definidoras de  $C_2$  incluem as características definidoras de  $C_1$  (SMITH; MEDIN, 1981). Assim, por exemplo, as características definidoras do conceito de *Cachorro* devem incluir as características definidoras do conceito de *Animal*. Note que a relação de subconjunto entre as categorias tem como consequência uma relação de *subsunção* entre os conceitos que as representam. Assim, seguindo o exemplo anterior, dizemos que  $C_1$  subsume  $C_2$ , e que toda instância de  $C_2$  é também uma instância de  $C_1$ , pois satisfaz as condições necessárias e suficientes de ambos os conceitos. De acordo com (MURPHY, 2002), este é geralmente apontado como um ponto forte da teoria clássica, visto que a *ordenação hierárquica* dos conceitos tende a ser algo assumido intuitivamente quando pensamos em conceitos e a teoria clássica explica como os conceitos são hierarquicamente ordenados.

Além disso, outra suposição assumida pela teoria clássica é a de que toda entidade *é ou não é membro da categoria* representada por um dado conceito (MURPHY, 2002). Ou seja, não há meio-termo para o pertencimento de uma entidade a uma categoria.


Em (MURPHY, 2002; MARGOLIS; LAURENCE, 2014) é dito que entre as principais vantagens da teoria clássica destaca-se o fato dela oferecer uma explicação integrada para o processo de *categorização* e de *aquisição de conceitos*. O processo de categorização de um determinado item, de acordo com a teoria clássica, envolveria verificar a quais condições necessárias e suficientes o item atende.

Já a aquisição de conceitos pode ser compreendida na teoria clássica como um processo no qual novos conceitos complexos podem ser obtidos pela combinação de seus constituintes definicionais. Relacionada a este processo de aquisição de conceitos está a noção de *composicionalidade*. Em um sistema de representações composicionais, existem elementos simples (primitivos ou atômicos) e elementos complexos. Em tais sistemas, elementos complexos são construídos a partir dos elementos simples e o significado dos elementos complexos depende do significado dos elementos simples. A linguagem natural é um exemplo paradigmático de sistema composicional, onde as palavras podem ser combinadas para formar sentenças complexas. Conforme discutido em (MURPHY, 2002; SZABÓ, 2013), alguns autores consideram a teoria clássica uma teoria adequada para explicar a composicionalidade do pensamento, pois as representações assumidas por esta teoria são composicionais.

Segundo (SMITH; MEDIN, 1981; MURPHY, 2002), a teoria clássica é amplamente assumida, mesmo que implicitamente, pelo senso comum. Na Filosofia a teoria, clássica é comumente adotada de modo explícito, desde Aristóteles, pelo menos. Na Psicologia, a teoria clássica tem sido considerada de modo explícito para explicar a representação de conceitos desde 1920, pelo menos. No entanto, nas últimas décadas, a teoria clássica vem sofrendo muitas críticas. Uma série de estudos desenvolvidos pela pesquisadora Eleanor Rosch, na década de 70 (ROSCH, 1973; ROSCH; MERVIS, 1975; ROSCH, 1975b; ROSCH, 1975a; ROSCH; SIMPSON; MILLER, 1976; ROSCH, 1978; ROSCH, 1999), levantaram uma série argumentos teóricos e de dados difíceis de explicar dentro do arcabouço da teoria clássica, constituindo um duro golpe contra esta teoria.

Um dos problemas da teoria clássica, que hoje é amplamente reconhecido, é o fato de que é notoriamente difícil encontrar definições baseadas em condições necessárias e suficientes para a maioria dos conceitos que utilizamos diariamente (SMITH; MEDIN, 1981; MURPHY, 2002; GÄRDENFORS, 2004b). Este problema foi colocado de modo enfático pelo filósofo Wittgenstein (WITTGENSTEIN, 1953). Ele explorou a dificuldade de se encontrar condições necessárias e suficientes para o conceito de *jogo*. De acordo com o filósofo, em geral, não há conjuntos de características comuns a todas as instâncias de um dado conceito e que são suficientes para identificar uma dada entidade como uma instância de um conceito. Em vez disso, consideramos todas as instâncias de um conceito como sendo instâncias de um mesmo conceito porque todas as instâncias estão conectadas entre si por uma série de similaridades sobrepostas, estabelecendo o que Wittgenstein chamou de uma *semelhança de família* entre as instâncias do conceito. A expressão *semelhança de família* evoca o fato de que, em geral, em uma família, não há nenhuma característica comum a todos os membros, mas os membros compartilham entre si diferentes traços. Na Figura 2.1 ilustra-se o conceito de semelhança de família considerando-se 4 objetos dados, cada qual com 3 características. É possível perceber na Figura que qualquer par do conjunto de objetos compartilha 2 características, mas nenhum das características é comum a todos os objetos. Assim, seria esta rede de similaridades entre pares de objetos que manteria a coesão dos conceitos e não o fato de haver algum conjunto comum de condições necessárias e suficientes. Note que neste exemplo há um grau constante de semelhança entre quaisquer dois objetos do conjunto, mas em outros casos este grau pode não ser constante e mesmo assim a semelhança de família poderia se manifestar no conjunto.

Figura 2.1: Esquema ilustrando um caso de semelhança de família. Há uma semelhança de família entre os 4 objetos porque os objetos de qualquer par do conjunto compartilham 2 características em comum, mas nenhuma característica é comum a todos os objetos.



Fonte: Produzida pelo autor.

Autores como (SMITH; MEDIN, 1981; MURPHY, 2002) afirmam que o fato de ser difícil encontrar definições baseadas em condições necessárias e suficientes para os conceitos não significa que tais definições não existam. No entanto, apesar desta observação ser verdadeira, esta dificuldade sugere que não representamos mentalmente os conceitos através de definições deste tipo. E mesmo quando encontramos um conjunto de condições necessárias e suficientes para um dado conceito, é possível argumentar que estas condições são obtidas por um processo de racionalização realizado sobre o conceito e que este poderia ter se estabelecido originalmente por meio de semelhanças de família entre os membros da categoria. Por este motivo, a teoria clássica não seria uma teoria adequada para explicar a representação cognitiva dos conceitos.

Um outro ponto que geralmente é apontado como um problema da teoria clássica é a existência dos chamados *efeitos de tipicidade*, que é evidenciada em diversos estudos realizados pelas Ciências Cognitivas nas últimas décadas (ROSCH, 1975a; SMITH; MEDIN, 1981; GÄRDENFORS, 2004b; MURPHY, 2002), e que não são explicados pela teoria clássica. Os chamados efeitos de tipicidade são marcados pela aparente existência de instâncias *preferenciais*, que são exemplos mais representativos (ou *melhores*, em um sentido vago), do que outras instâncias de um determinado conceito. Por exemplo, em geral, quando pedimos para pessoas pensarem em uma *Ave*, em geral, elas pensam

em algum pássaro, do porte de um canário, capaz de voar, etc. Em geral, estes tipos de aves são considerados mais representativos da ideia de ave do que, por exemplo, emas e pinguins. Neste sentido, algumas instâncias de um conceito seriam consideradas mais *típicas*, enquanto outras seriam consideradas mais *atípicas*.

Em (MURPHY, 2002) são discutidas algumas fontes de evidências para os efeitos de tipicidade. Por exemplo, foi demonstrado que pessoas tendem a concordar entre si sobre quais são os membros mais típicos de uma categoria, pessoas tendem a classificar mais rapidamente instâncias mais típicas, pessoas concordam menos sobre a classificação de instâncias atípicas, pessoas aprendem antes os itens mais típicos em experimentos de aprendizagem de categorias artificiais, inferências realizadas sobre instâncias típicas são facilitadas, há diversas influências da tipicidade no aprendizado linguístico, etc. Em (ROSCH; MERVIS, 1975), os autores explicam os efeitos da tipicidade em função da noção de semelhança de família. Neste sentido, itens mais típicos teriam uma semelhança de família mais alta com os membros da sua categoria e teriam uma semelhança de família menor com os membros de outras categorias. Deste modo, membros mais típicos de uma categoria tendem a possuir atributos que ocorrem com mais frequência entre os membros da categoria e tende a não possuir atributos de membros de outras categorias. É importante notar que todas essas evidências não são bem explicadas pela teoria clássica. Devido a isso, os efeitos de tipicidade costumam ser considerados a principal razão pela qual a teoria clássica não pode ser considerada uma teoria adequada sobre a representação de conceitos.

Conforme (MEDIN; SMITH, 1984), se o pertencimento de um objeto a uma categoria é julgado de acordo com um conjunto de propriedades definicionais, os limites das categorias deveriam ser claros e precisos. No entanto, diversos experimentos demonstram diversos casos em que as pessoas não têm certeza a respeito do pertencimento de um dado objeto a uma categoria. Por exemplo, em relação à questão de se um tapete deve ser considerado como um exemplo de mobília, diferentes pessoas oferecem respostas diferentes, e a mesma pessoa pode oferecer respostas diferentes em diferentes contextos.

Outro problema da teoria clássica discutido em (MEDIN; SMITH, 1984) é o fato de que diversos estudos evidenciaram que a maioria das propriedades que as pessoas listam para os objetos não são comuns para todos os membros da categoria. Isto é, tais propriedades não seriam necessárias para o pertencimento à categoria. Tais estudos também sugerem que tais propriedades não necessárias também são utilizadas para realizar a categorização. Este fato contrastaria com a suposição assumida pela teoria clássica de que são as propriedades definicionais (necessárias e suficientes) que são utilizadas na categorização.

Nas Seções 2.1.2.2 e 2.1.2.3 serão apresentadas duas teorias alternativas à teoria clássica, que são bem-sucedidas em explicar algumas das evidências que são problemáticas para a teoria clássica.

### 2.1.2.2 Teoria do protótipo

A teoria do protótipo, na verdade é uma família de teorias, desenvolvidas a partir dos trabalhos da pesquisadora Eleanor Rosch, nos quais foram levantadas diversas evidências para a existência de efeitos de tipicidade (MEDIN; SMITH, 1984; MURPHY, 2002). Um dos principais pontos em comum entre estas diferentes teorias é o fato de que elas assumem que algumas instâncias são mais típicas (ou prototípicas) de um conceito do que outras. Neste sentido, as teorias baseadas em protótipos assumem como fundamental um efeito que a teoria clássica não é capaz de explicar.

Uma outra suposição que é assumida pela maior parte das teorias baseadas em protótipos é a de que conceitos são *abstrações* ou *representações compactas* da variabilidade de membros possíveis de um conceito. Além disso, ao contrário do que é assumido pela teoria clássica, as teorias baseadas em protótipos assumem que para uma característica (ou propriedade) ser incluída na representação de um conceito, ela não precisa ser necessariamente comum a todas as suas instâncias; basta que ela tenha uma probabilidade substancial de ocorrer em instâncias do conceito (MEDIN; SMITH, 1984).

Em geral, as teorias baseadas em protótipos assumem que os conceitos são representados por um *protótipo*, que seria uma espécie de instância *ideal* do conceito, que possuiria todas as características típicas entre os membros da classe representada pelo conceito (GÄRDENFORS, 2004a). Note que, devido a isto, o protótipo de um conceito não é necessariamente uma instância real. De acordo com (MEDIN; SMITH, 1984), em algumas formulações, o protótipo de um conceito não é exatamente uma instância (ideal ou real), mas uma lista das propriedades típicas, ou um modelo probabilístico que associa a cada característica a probabilidade de ela ocorrer entre os membros de categoria. Neste sentido, o conceito de *Cachorro* seria representado por uma representação compacta que incluiria as propriedades tipicamente encontradas em cachorros, mas que podem não ser necessárias, tampouco suficientes. Por exemplo, cachorros tipicamente têm pelos, têm 4 patas, têm uma cauda, latem, etc.

Para (MEDIN; SMITH, 1984), o fato de que as teorias baseadas em protótipos não assumem que conceitos são representados por definições também confere uma vantagem sobre a teoria clássica em relação ao fato de que é notoriamente difícil encontrar definições (baseadas em propriedades necessárias e suficientes) para conceitos. Deste modo, as teorias baseadas em protótipo não carregam o ônus de explicar esta dificuldade.

Uma vez que as teorias baseadas em protótipos não assumem que conceitos são representados por definições, o processo de categorização, de acordo com essas teorias, não envolve verificar se instâncias atendem aos critérios especificados pelas definições dos conceitos. Em vez disso, em geral a categorização é determinada em função da *similaridade* entre um objeto observado e os protótipos dos conceitos (MEDIN; SMITH, 1984). A similaridade pode ser utilizada de diversas formas. Por exemplo, pode-se as-



sumir que o conceito que categoriza um novo objeto é aquele cujo protótipo tem a maior similaridade com o objeto, dentre os conceitos considerados. Outra alternativa é assumir que basta que a similaridade entre o objeto e um protótipo possua um valor superior a um dado limiar, para classificar o objeto com o conceito associado ao protótipo.

O fato de a categorização ser realizada com base na similaridade também permite explicar a falta de concordância na classificação de certas instâncias (MEDIN; SMITH, 1984). Por exemplo, um objeto que possui um grau de similaridade próximo em relação aos protótipos de diferentes conceitos pode gerar dúvidas no processo de categorização.

A categorização baseada em similaridade também oferece uma base sólida para explicar os efeitos de typicalidade. Os membros mais típicos de um conceito seriam aqueles que possuem as características típicas dos membros da categoria. Tais membros seriam mais similares ao protótipo do conceito do que membros atípicos.

No entanto, apesar de oferecer diversas vantagens em relação à teoria clássica, há diversos estudos que também criticam a teoria dos protótipos. Uma das principais críticas está relacionada ao fato de que protótipos não suportam a composicionalidade, que seria um fenômeno bem explicado sob a perspectiva da teoria clássica, visto que as definições dos conceitos são composicionais. Jerry Fodor, um dos maiores críticos da teoria do protótipo, sustenta que, uma vez que conceitos são composicionais e que protótipos não são composicionais, logo, conceitos não podem ser protótipos (FODOR; LEPORE, 1996).

Uma outra crítica à teoria do protótipo, discutida em (MEDIN; SMITH, 1984) é a de que esta teoria não captura de modo adequado o conhecimento que as pessoas têm sobre os conceitos. Por exemplo, além das pessoas saberem quais são as propriedades típicas de um conceito, em geral, as pessoas também sabem qual é o intervalo de valores possíveis que uma dada propriedade pode assumir nos membros da categoria e também possuem conhecimento sobre a correlação entre as propriedades. Por exemplo, pessoas sabem que aves geralmente são pequenas e cantam, e também sabem que estas propriedades são correlacionadas, na medida em que aves grandes tipicamente não cantam. Há evidências de que a correlação entre propriedades é usada pelas pessoas durante o processo de categorização (SLOUTSKY, 2010). Este fato foi explorado em (CARBONERA; ABEL, 2014a; CARBONERA; ABEL, 2015a) para projetar um algoritmo de aprendizado não supervisionado.

Em (MEDIN; SMITH, 1984) a teoria do protótipo também é criticada por ser excessivamente vaga em diversos aspectos, de modo que ela pode se tornar tão flexível que perde a capacidade explanatória.

### 2.1.2.3 Teoria do exemplar

A teoria do exemplar também é uma família de teorias que, em geral, assumem que, *pelo menos em parte*, conceitos consistem em descrições separadas de *alguns* de seus *exemplares* (MEDIN; SMITH, 1984). Ou seja, em geral, não há uma representação unificada abstrata da categoria como um todo. Neste sentido, o conceito de *Cachorro* seria representado por um conjunto de cachorros que o sujeito lembra (ou o conjunto de experiências envolvendo cachorros que a pessoa lembra).

Segundo (MEDIN; SMITH, 1984), as teorias baseadas em exemplares também não assumem que conceitos possuem definições (baseadas em condições necessárias e suficientes). A ausência de definições também coloca a necessidade de a teoria do exemplar explicar de um modo alternativo como ocorre a categorização de objetos. Em geral, nas teorias baseadas em exemplares, o processo de categorização de um objeto é realizado com base em comparações (julgamentos de similaridade) entre o objeto e os exemplares da categoria. Deste modo, um determinado indivíduo *i* poderia ser categorizado pelo conceito cujos exemplares são mais similares a *i*.

A falta de acordo entre as pessoas em relação à categorização de certos objetos, que constitui um problema para a teoria clássica, é perfeitamente explicável pela teoria do exemplar. Objetos de classificação controversa seriam aqueles que são igualmente similares a exemplares de mais de uma categoria ou que não são suficientemente similares a exemplares de qualquer categoria (como o cavalo marinho) (MEDIN; SMITH, 1984).

Os efeitos de typicalidade também são explicados nas teorias baseadas em exemplares (MEDIN; SMITH, 1984). Por exemplo, tais efeitos podem ser o resultado do fato de que as pessoas tendem a representar apenas os exemplares mais típicos, ou simplesmente porque os exemplares mais típicos são mais similares a outros exemplares armazenados.

Além disso, as teorias baseadas em exemplar também possuem algumas vantagens em relação à teoria baseada em protótipos. Por exemplo, a representação de exemplares é capaz de capturar informação relacionada ao intervalo de valores possíveis que uma propriedade pode possuir entre os membros de uma categoria, além de informações relacionadas a correlações entre as propriedades dos membros da categoria (MEDIN; SMITH, 1984).

No entanto, de modo similar ao que ocorre com as teorias baseadas em protótipos, alguns autores também criticam as teorias baseadas em exemplares por serem excessivamente vagas. Por exemplo, há poucas restrições nestas teorias em relação ao que pode contar como uma propriedade. Em (MURPHY, 2002) discute-se que a própria noção de exemplar é vaga. Há poucas restrições na teoria sobre o que pode ser considerado como um exemplar e o que não deve ser considerado.

#### 2.1.2.4 Teorias híbridas e pluralistas

Conforme visto na Seções 2.1.2.1, 2.1.2.2 e 2.1.2.3, a noção de *conceito* é mobilizada para explicar uma ampla variedade de fenômenos cognitivos e, devido a isto, há uma variedade de caracterizações teóricas desta noção e de como ela é cognitivamente representada. No entanto, segundo (WEISKOPF, 2009; VICENTE; MANRIQUE, 2014), nenhuma das principais caracterizações teóricas propostas é capaz de explicar todos os fenômenos estudados e amplamente documentados pelas Ciências Cognitivas, embora cada uma delas seja bem-sucedida em explicar um subconjunto restrito de fenômenos. Por exemplo, diferentemente da teoria clássica, as teorias baseadas em protótipos e exemplares não oferecem boas explicações para o fato de que somos capazes de desenvolver definições para conceitos e raciocinar com base em tais definições (com base na lógica dedutiva); tampouco são capazes de oferecer uma boa base para a aparente natureza composicional dos conceitos. Por outro lado, a teoria clássica não oferece suporte para explicar os fenômenos relacionados à tipicidade, a existência de instâncias de classificação controversa e as evidências de que pessoas tendem a utilizar propriedades não definicionais durante a classificação. As teorias baseadas em protótipos, por outro lado, oferecem explicações para tais fenômenos, mas não afirmam nada a respeito do fato de que muitas vezes realizamos classificações com base em exemplares conhecidos de uma categoria e também não oferecem uma boa base para capturar o conhecimento dos domínios de valores que as propriedades de um conceito pode possuir.

Segundo (VICENTE; MANRIQUE, 2014), diante deste cenário, há duas posições possíveis: a posição *pluralista*, defendida em trabalhos como (PICCININI; SCOTT, 2006; WEISKOPF, 2009) ou a posição *hibridista*, defendida em (GONNERMAN; WEINBERG, 2010; KEIL, 2010; SCARANTINO, 2010). A posição pluralista assume que existem diversas representações cognitivas para uma determinada categoria e cada uma destas representações seria na verdade um conceito separado, representado e armazenado de forma independente, capaz de operar de forma independente e que seria usualmente utilizado em tarefas distintas. A posição hibridista, por outro lado, assume que as diferentes representações são, na verdade, constituintes de uma única representação do conceito de uma dada categoria. Todas estas representações seriam armazenadas na memória de longo prazo como uma totalidade funcional, e todas as representações poderiam em princípio atuar na mesma tarefa, pelo menos em algum grau. Por exemplo, a categoria dos cachorros poderia ser representada por um protótipo, um conjunto de exemplares, uma definição, etc. O que diferencia ambas as posições é que para um pluralista, cada uma dessas representações seria um conceito independente da categoria do cachorros, enquanto para um

hibridista, todas as representações seriam constituintes de uma representação do conceito de cachorro. É importante salientar que ambas as posições reconhecem a necessidade de múltiplas representações para acomodar as evidências empíricas levantadas nos estudos realizados pelas Ciências Cognitivas.

Nesta tese, consideramos que a visão conhecida como *core + identification procedure* (CIP), discutida em (MILLER; JOHNSON-LAIRD, 1976; OSHERSON; SMITH, 1981; SMITH; MEDIN, 1981), pode ser considerada como um exemplo de concepção híbrida dos conceitos. Esta concepção pode ser vista como uma extensão da teoria clássica, mas capaz de lidar com alguns dos fenômenos que esta teoria não é capaz de explicar originalmente. A ideia geral subjacente a esta visão, segundo (MEDIN; SMITH, 1984), é a de que conceitos possuem *núcleos e procedimentos de identificação*. Os núcleos dos conceitos representariam as propriedades necessárias (embora não necessariamente suficientes) para os membros da categoria e as relações que o conceito possui com outros conceitos. Os procedimentos de identificação, por outro lado, representariam propriedades, geralmente típicas, utilizadas para categorizar objetos. Assim, por exemplo, o conceito de *Cachorro* poderia representar a relação que este conceito possui com o conceito de *Animal* (ou *Canídeo*) em seu *núcleo*, enquanto o *procedimento de identificação* poderia incluir a caracterização típica de um cachorro, como *ter pelo, ter 4 patas, ter uma cauda, latir*, etc. Ou seja, esta teoria assume que é possível que um mesmo conceito possua um núcleo clássico (semelhante a uma definição) e protótipos (ou representações de propriedades típicas).

## 2.2 Representação de conhecimento e raciocínio na Ciência da Computação

De acordo com (BRACHMAN; LEVESQUE, 2004) a área de *representação de conhecimento e raciocínio* é uma subárea da inteligência artificial que se dedica a investigar como um agente usa o que ele conhece para decidir o que fazer. Em geral, nesta área adota-se uma perspectiva *top-down*, onde o conhecimento é explicitamente representado de uma forma processável por máquina e as tarefas são resolvidas por meio de mecanismos de raciocínio, que processam o conhecimento representado para realizar um processo de inferência, no qual novo conhecimento pode ser inferido.

Nesta área, em geral, assume-se que o conhecimento é uma entidade abstrata (como um conjunto de proposições) que é representada de modo concreto (como sentenças em uma linguagem), computacionalmente processável. De modo geral, as representações de conhecimento adotadas são também chamadas de *representações simbólicas*, visto que são constituídas por *símbolos*, os quais são entidades formais concretas. Deste modo, o raciocínio, em Inteligência Artificial, pode ser visto como um processo em que ocorre o processamento formal de símbolos, representando uma coleção de proposições

nas quais um agente acredita, para produzir representações de novas proposições. Neste contexto, segundo (BRACHMAN; LEVESQUE, 2004), um tipo de inferência particularmente importante na Inteligência Artificial é a *inferência lógica*, onde o conteúdo proposicional das representações geradas pela inferência, são conclusões lógicas do conteúdo proposicional das representações processadas na inferência.

Segundo (BRACHMAN; LEVESQUE, 2004), *sistemas baseados em conhecimento* são sistemas nos quais os comportamentos inteligentes são ancorados em representações simbólicas de conhecimento e constituem o resultado de processos de raciocínio realizados sobre a *base de conhecimento* do sistema. Neste contexto, a base de conhecimento de um sistema baseado em conhecimento seria o conjunto das representações simbólicas adotadas pelo sistema.

Historicamente, abordagens pioneiras para representação de conhecimento em IA buscaram considerar aspectos da cognição humana. Este é o caso, por exemplo, das *redes semânticas* (QUILLAN, 1963) e *frames* (MINSKY, 1975), que foram propostas como alternativas ao uso da lógica para representação de conhecimento e que permitiam a caracterização de conceitos com base em informações típicas (ou prototípicas). No entanto, tais abordagens careciam de uma semântica formal bem definida. Segundo (LIETO, 2012), a busca por fundamentos formais sólidos para as abordagens de representação de conhecimento revelou que este objetivo não seria facilmente conciliado com a necessidade de se representar informações típicas. Devido a isto, muitas abordagens desenvolvidas nas últimas décadas, incluindo as atuais lógicas de descrição, optaram por sacrificar a tipicidade, para preservar a composicionalidade e uma semântica formal bem definida.

De acordo com (SMITH; WELTY, 2001), por muitos anos, a pesquisa em IA focou-se em *formalismos de representação* e *mecanismos de raciocínio*, capazes de manipular o conhecimento representado por tais formalismos. Assim, até recentemente, o conteúdo das bases de conhecimento não era considerado digno de relevância científica. Deste modo, em geral, o conhecimento era arbitrariamente representado do modo mais adequado para a realização da tarefa. Este comportamento, comum aos projetistas de sistemas baseados em conhecimento, revelava elevados níveis de *promiscuidade ontológica* (GENESERETH; NILSSON, 1987), visto que não havia uma preocupação com os tipos de entidades com cuja existência o sistema se comprometia. Deste modo, segundo (GUARINO, 1997), neste período da IA, o principal critério de avaliação de uma base de conhecimento, era a *utilidade funcional*. Ou seja, o aspecto mais importante era que a base de conhecimento permitisse que o sistema realizasse a tarefa em mãos. Assim, a *fidelidade* da base de conhecimento a uma conceitualização era um aspecto secundário. No entanto, ao longo dos anos, parte da comunidade passou a investigar o próprio conteúdo das bases de conhecimento. Este movimento foi motivado por diversos fatores. Por exemplo, os formalismos de representação e mecanismos de raciocínio se tornaram mais estáveis (SMITH; WELTY, 2001). Além disso, agentes inteligentes artificiais passaram

a interagir entre si e com humanos em ambientes mais vastos e variados (como a web) (GUARINO, 1997). Neste caso, se tornou mais evidente a necessidade de se desenvolver bases de conhecimento que aproximassem uma conceitualização compartilhada da realidade e que pudesse ser adotada por múltiplos agentes, capazes de se comunicar e trocar informações. Note que, desta forma, a fidelidade da base de conhecimento a uma conceitualização da realidade passa a ganhar importância. Além disso, devido a questões de custo do desenvolvimento de bases de conhecimento, o reuso de conhecimento passou a ganhar mais importância. Este aspecto também favoreceu a criação de bases de conhecimento que refletissem uma conceitualização comum em uma área, pois uma base deste tipo teria um potencial de reuso maior do que uma base de conhecimento elaborada com o único propósito de satisfazer os requisitos de uma única aplicação específica. De acordo com (CHANDRASEKARAN; JOSEPHSON; BENJAMINS, 1999), atualmente grande parte da pesquisa em IA ainda é dedicada ao que ele chama de *teorias de mecanismos*, que é focada em formalismos de representação e mecanismos de raciocínio; mas há uma grande quantidade de pesquisa direcionado ao que ele chama de *teorias de conteúdo*, que é focada na investigação do próprio conteúdo das bases de conhecimento. Atualmente, esta linha de pesquisa em IA relacionada a teorias de conteúdo tem adotado a noção de *ontologia* como uma representação formal e explícita de uma conceitualização compartilhada (STUDER; BENJAMINS; FENSEL, 1998). Devido a isto, ontologias se tornaram uma forma de representação de conhecimento bastante importante na IA. E com a popularização da noção de ontologia, populariza-se também a OWL; uma família de linguagens projetadas para a representação de ontologias no contexto da Web Semântica.

Nas próximas seções serão discutidas abordagens recentes para representação de conhecimento oferecidas pela literatura da Ciência da Computação. Na Seção 2.2.1 serão discutidas as abordagens clássicas mais importantes em uso na IA atualmente. Na Seção 2.2.2 serão discutidos alguns trabalhos que propõem formalismos de representação que estendem algum dos formalismos que adotam a abordagem clássica, buscando transcender algumas das limitações destes formalismos. Já na Seção 2.2.3, serão discutidos trabalhos que propõem abordagens híbridas, que combinam abordagens clássicas com outras abordagens, também com o objetivo de superar algumas limitações das abordagens clássicas.

## 2.2.1 Abordagens clássicas para representação de conhecimento

Na computação, em geral, o paradigma clássico, discutido na Seção 2.1.2.1, é adotado em formalismos de representação amplamente utilizados atualmente, como a OWL e as lógicas de descrição. Tais formalismos constituem linguagens que podem ser utilizadas para expressar conhecimento formalmente, de tal modo que este conhecimento possa ser manipulado computacionalmente (por raciocinadores), viabilizando a inferência de novo conhecimento. Na Seção 2.2.1.1 será apresentada uma visão geral sobre lógicas de descrição, enquanto na Seção 2.2.1.2 será apresentada uma visão geral sobre OWL.

### 2.2.1.1 Lógica de descrição

De acordo com (BAADER; HORROCKS; SATTLER, 2009), as lógicas de descrição são uma família de linguagens de representação de conhecimento que podem ser utilizadas para representar o conhecimento de um domínio de aplicação de uma forma estruturada e formalmente bem compreendida. O nome *lógica de descrição* é motivado pelo fato de que as noções importantes do domínio são especificadas por *descrições de conceitos*, que são expressões construídas a partir de *conceitos* (que são predicados unários) e *papéis* (que são predicados binários). Além disso, as lógicas de descrição diferenciam-se das abordagens de representação de conhecimento propostas anteriormente, como *redes semânticas* (QUILLIAN, 1968) e *frames* (MINSKY, 1975), por possuírem uma *semântica formal* baseada em lógica.

De modo geral, existem diversas lógicas de descrição, tais como a *ALC* e a *SHIQ*. A maioria das lógicas de descrição é baseada em fragmentos decidíveis da *lógica de primeira ordem* (que não é decidível) (BAADER; HORROCKS; SATTLER, 2009). Assim, as lógicas de descrição costumam ser projetadas para manter um compromisso, entre *expressividade semântica* e *eficiência computacional*, sacrificando algumas capacidades de representação para proporcionar eficiência computacional. Deste modo, o raciocínio em lógicas com alta expressividade semântica tende a ser menos eficiente que o raciocínio em lógicas com expressividade semântica menor. É importante notar que os diversos tipos de lógica de descrição diferem entre si em termos de quais capacidades de representação são sacrificadas e quais são oferecidas, para manter a decidibilidade.

Uma base de conhecimento desenvolvida com uma lógica de descrição possui dois componentes distintos: o *componente terminológico* (*terminological box* ou *TBox*) e o *componente assertional* (*assertional box* ou *ABox*). O componente terminológico permite a descrição das noções estáveis do domínio, declarando propriedades de conceitos e papéis, bem como relações entre tais componentes. Este componente é análogo a um

*esquema* de banco de dados e, em geral, especifica a porção invariante do conhecimento de domínio. Neste componente, é possível definir novos conceitos nomeando uma descrição de conceito. No exemplo a seguir, define-se o conceito *HomemFeliz*, em função de outros conceitos e papéis.

$$\begin{aligned} \text{HomemFeliz} \equiv & \text{Pessoa} \sqcap \neg \text{Femea} \sqcap \exists \text{casadoCom.PessoaHonesta} \sqcap \\ & (\geq 5 \text{temFilho}) \sqcap \forall \text{temFilho.Professor} \end{aligned} \quad (2.1)$$

A descrição 2.1 define *HomemFeliz* como *Um homem que é casado com uma pessoa honesta, que tem pelo menos 5 filhos, dos quais todos são professores*. Esta descrição emprega os construtos booleanos de *conjunção* ( $\sqcap$ ), que é interpretado como *interseção de conjuntos*; e *negação* ( $\neg$ ), que é interpretado como *complemento de conjunto*. Ela também emprega o construto de *restrição existencial* ( $\exists R.C$ ), o construto de *restrição de valor* ( $\forall R.C$ ) e o construto de *restrição de número* ( $\geq nR$ ). Um indivíduo *João* pertence a  $\exists \text{casadoCom.PessoaRica}$  se existe um indivíduo que é casado com *João* (ou seja, está relacionado à *João* através do papel *casadoCom*) e que é uma pessoa honesta (ou seja, pertence ao conceito *PessoaHonesta*). Do mesmo modo, *João* pertence a  $(\geq 5 \text{temFilho})$  se ele tem pelo menos 5 filhos, e ele pertence a  $\forall \text{temFilho.Professor}$  se todos os seus filhos (indivíduos relacionados a *João* através do papel *temFilho*) forem professores (ou seja, se pertencerem ao conceito *Professor*).

O componente assercional de uma base de conhecimento, por outro lado, é utilizado para descrever situações específicas (ou *estados de coisas* específicos), declarando propriedades e relações entre indivíduos. O componente assercional é análogo aos dados em um banco de dados. A seguir, são apresentadas três asserções de um possível componente assercional de uma base de conhecimento:

$$\begin{aligned} & \text{HomemFeliz}(\text{Joao}) \\ & \text{temFilho}(\text{Joao}, \text{Mariana}) \\ & \neg \text{Engenheiro}(\text{Mariana}) \end{aligned} \quad (2.2)$$

Estas asserções representam, respectivamente que *João é um homem feliz*, *Mariana é filha de João* e *Mariana não é engenheira*.

Os sistemas de lógica de descrição modernos oferecem serviços de raciocínio capazes de deduzir conhecimento implícito a partir do conhecimento explicitamente representado na base de conhecimento. Idealmente, tais serviços de raciocínio sempre resultam em respostas corretas em um tempo finito. Estes serviços de raciocínio consideram ambos os componentes, o terminológico e o assercional. Tipicamente, os serviços de



raciocínio incluem *determinação de subsunção*, que computa as relações subconceito-superconceito; *determinação de instanciação* que determina de que conceitos cada indivíduo é instância; e *checagem de consistência*, que determina se uma base de conhecimento está livre de contradições.

As especificações formais da sintaxe e a semântica de algumas lógicas de descrição podem ser encontradas em (BAADER, 2003; BAADER IAN HORROCKS, 2008; BAADER; HORROCKS; SATTLER, 2009).

Apesar das lógicas de descrição oferecerem uma base bem fundamentada e com expressividade razoável para representação de conhecimento, proporcionando a *composicionalidade* dos conceitos, elas sofrem de todas as limitações de uma abordagem que segue o paradigma clássico de representação de conhecimento, discutido em 2.1.2.1. Por exemplo, as DL assumem que os conceitos são descritos em termos de *condições necessárias e suficientes*, e o processo de raciocínio para classificação de instâncias explora tais condições, para verificar quais conceitos possuem as suas condições atendidas para cada indivíduo. No entanto, constata-se que é notoriamente difícil determinar tais conjuntos de condições para a maior parte dos conceitos utilizados cotidianamente. Além disso, as DL convencionais não oferecem uma base para lidar com efeitos de tipicidade, visto que tais frameworks não preveem a existência de indivíduos mais ou menos típicos para um dado conceito.

#### 2.2.1.2 OWL

De acordo com (ANTONIOU; HARMELEN, 2009), a OWL (*Ontology Web Language*) é, na verdade, uma família de linguagens de representação de conhecimento especialmente projetadas para o desenvolvimento de ontologias. Além disso, conforme dito em (HORROCKS; PATEL-SCHNEIDER; HARMELEN, 2003), a OWL foi concebida para ser adotada no contexto da Web Semântica, onde ontologias desempenhariam o papel de estabelecer o significado do vocabulário utilizado para descrever o conteúdo e as funcionalidades de recursos na web, de tal modo que agentes artificiais pudessem interpretar o significado destes termos de modo não ambíguo. Deste modo, para permitir a especificação formal e explícita de conceitualizações a respeito de um domínio, a OWL foi projetada para satisfazer alguns requisitos, tais como: possuir uma sintaxe bem definida, possuir uma semântica bem definida, suportar raciocínio eficiente, possuir poder expressivo suficiente e ser fácil de usar para expressar conhecimento (HORROCKS; PATEL-SCHNEIDER; HARMELEN, 2003). Além disso, assim como ocorre com as lógicas de descrição, a OWL também possui *semântica formal* baseada em lógica, permi-

tindo interpretações precisas do conhecimento representado. Também é importante notar que a especificação formal da OWL foi influenciada pela lógica de descrição. Em relação à sintaxe, a OWL possui sintaxe concreta baseada em XML/RDF e uma sintaxe abstrata baseada em frames (HORROCKS; PATEL-SCHNEIDER; HARMELEN, 2003).

Segundo (HORROCKS; PATEL-SCHNEIDER; HARMELEN, 2003), a OWL combina a capacidade do *RDF* (KLYNE; CARROLL, 2006) de declarar fatos e a capacidade do *RDF Schema* (ou RDFS) (BRICKLEY; GUHA, 2004) de declarar classes e propriedades de objetos, e estende tais conjuntos de capacidades. Além de permitir a declaração de classes, a OWL também permite organizar estas classes em hierarquias de subsunção, assim como o RDFS. No entanto, em OWL, Classes, podem ser especificadas como combinações lógicas (interseções, uniões e complementos) de outras classes, ou como enumerações de objetos especificados. Além disso, em OWL também é possível especificar a disjunção entre classes. Tais capacidades transcendem as capacidades do RDFS. A OWL também oferece a capacidade de especificar propriedades, de organizá-las em hierarquias e de especificar domínios e contradomínios destas propriedades, assim como o RDFS. No entanto, o OWL transcende as capacidades do RDFS, ao permitir que se defina propriedades como transitivas, reflexivas, simétricas e/ou funcionais. Outra grande diferença entre a OWL e o RDFS é a possibilidade de se especificar restrições de cardinalidade em OWL.

Conforme foi discutido no contexto das lógicas de descrição, a complexidade computacional envolvida nos processos de raciocínio sobre o conhecimento representado com uma linguagem é diretamente proporcional ao poder expressivo da linguagem (HORROCKS; PATEL-SCHNEIDER; HARMELEN, 2003). No caso da OWL, os construtos de representação e tipos de axiomas possíveis foram cuidadosamente escolhidos, com base na experiência de anos de pesquisa em lógicas de descrição, para equilibrar requisitos de expressividade semântica de aplicações típicas e requisitos de eficiência computacional dos processos de raciocínio suportados.

Assim como ocorre com as lógicas de descrição, a OWL suporta diversos tipos de raciocínio, que incluem: classificação de indivíduos, determinação de equivalência de classes, verificação de consistência, etc.

Detalhes da OWL podem ser encontrados em (HORROCKS; PATEL-SCHNEIDER; HARMELEN, 2003; MCGUINNESS; HARMELEN et al., 2004; GRAU et al., 2008; ANTONIOU; HARMELEN, 2009; GROUP, 2009; MOTIK et al., 2009).

De forma análoga ao que ocorre com as lógicas de descrição, apesar da OWL oferecer uma base bem fundamentada e com expressividade razoável para representação de conhecimento, proporcionando a *composicionalidade* dos conceitos, ela sofre de todas as limitações de uma abordagem que segue o paradigma clássico de representação de conhecimento, discutido em 2.1.2.1.

## 2.2.2 Extensões de abordagens clássicas

Conforme discutido na Seção 2.2.1, as principais abordagens atuais desenvolvidas na IA seguem o paradigma clássico de representação, discutido na Seção 2.1.2.1. Assim, tais abordagens possuem limitações intrínsecas, no que diz respeito à capacidade de permitir uma manipulação flexível do conhecimento em processos de raciocínio. Algumas destas limitações são decorrentes principalmente do fato de que tais abordagens buscam representar os conceitos em termos de *condições necessárias e suficientes*, ignorando, por exemplo, o fenômeno da *tipicalidade* (GÄRDENFORS, 2004c). No entanto, atualmente existem abordagens que buscam estender alguns formalismos que adotam o paradigma clássico, para transcender algumas das limitações de tais abordagens, tais como a representação de predicados vagos (BOBILLO; STRACCIA, 2009), representação de conhecimento probabilístico (LUKASIEWICZ, 2008), a representação de conhecimento sobre o que é típico em um domínio, etc. Esta seção foca principalmente em extensões que buscam representar aspectos que são considerados por paradigmas de representação de conhecimento não clássicos (como os baseados em protótipos e exemplares), tais como conhecimento sobre o que é típico. Uma vez que existem diversos trabalhos na área, nesta seção serão discutidos apenas os mais relevantes para o trabalho, sobretudo os mais recentes ou mais representativos.

### 2.2.2.1 Integração entre lógica de descrição e lógica default

Em (BAADER; HOLLUNDER, 1995) discute-se formas de integrar a *lógica default* de Reiter a uma lógica de descrição. A lógica default de Reiter é uma lógica não monotônica que permite representar e raciocinar sobre suposições padrão (*defaults*). Ou seja, esta lógica pode representar conhecimento que é assumido como verdadeiro por padrão, mas que pode revelar-se falso em alguns casos. Esta lógica pode representar conhecimento sobre o que é típico, assumindo-o como verdadeiro por padrão. Por exemplo, é possível assumir que, por padrão, *Todas as aves voam*, uma vez que aves tipicamente voam. No entanto, isto é obviamente falso para o caso do *Pinguim*, por exemplo. De acordo com esta lógica, por exemplo, sabendo-se que *Polly é uma ave*, se não há nenhuma informação sobre a capacidade de *Polly* voar ou sobre *Polly* ser um *Pinguim* (ou outra ave que sabidamente não voa), pode-se concluir por padrão que *Polly voa*. Esta lógica é não monotônica porque, se for incluída alguma informação que nos permite inferir que *Polly não voa* ou que *Polly é um Pinguim* (ou outra ave que sabidamente não voa), esta conclusão deve ser revista.

Os autores apontaram dificuldades semânticas (conclusões não intuitivas) e computacionais (raciocínio indecidível) resultantes da integração de DL e lógica default. Devido a isto, os autores desenvolveram uma versão restrita da semântica, na qual as *regras default* são aplicadas apenas para indivíduos explicitamente representados na base de conhecimento.

Em (MOODLEY; MEYER; SATTLER, 2014), por outro lado, investiga-se a generalização da abordagem preferencial do raciocínio não monotônico para a lógica DL  $\mathcal{ALC}$ . Segundo os autores, esta generalização permite a representação intuitiva de afirmações revogáveis, bem como a inferência de conclusões revogáveis desejáveis. Além disso, tal abordagem também possui a vantagem de manter a complexidade computacional do raciocínio no pior caso equivalente à complexidade da  $\mathcal{ALC}$  clássica. A abordagem investigada pelos autores permite a interpretação de subsunções revogáveis, do tipo *As aves mais típicas são animais voadores* (ou no caso geral *Os C's mais típicos são D's*). Ou seja, esta abordagem também permite estabelecer raciocínios sobre o que é típico no domínio e tais conclusões podem ser revogadas, caso novas informações sejam consideradas.

É importante notar que as abordagens apresentadas em (BAADER; HOLLUNDER, 1995; MOODLEY; MEYER; SATTLER, 2014) não utilizam a informação de exemplares para fundamentar a classificação de novos indivíduos. Além disso, a tipicidade, conforme considerada nos estudos cognitivos, possui uma natureza *gradual* que não é capturada nestes formalismos. Finalmente, ambas as abordagens não oferecem um meio natural de suporte para raciocínio baseado em similaridade.

#### 2.2.2.2 Extensão de lógica de descrição com circunscrição

Em (BONATTI; LUTZ; WOLTER, 2006) é proposta uma lógica de descrição entendida com circunscrição. A circunscrição é uma abordagem desenvolvida por John McCarthy (MCCARTHY, 1980) para formalizar a suposição do senso comum de que as coisas são como esperadas, a menos que seja especificado o contrário. Deste modo, predicados circunscritos são predicados para os quais assume-se que apenas os indivíduos para os quais pode-se demonstrar que possuem tais predicados são todos os indivíduos que efetivamente possuem tais predicados. Deste modo, a circunscrição seria semelhante à *suposição de mundo fechado*, em função da qual assume-se como falsas as declarações que não são sabidamente verdadeiras. A ideia fundamental que permite representar o que é típico e o que é atípico é introduzir *predicados de anormalidade* para representar casos (ou indivíduos) que não satisfazem um critério de normalidade (ou tipicidade). Para capturar a ideia de que a anormalidade é excepcional, os predicados de anormalidade são circunscritos. Isto é, os indivíduos para os quais pode ser demonstrado que são anormais, são efetivamente todos os indivíduos anormais que há. Assim, por exemplo, é possível

representar que *mamíferos ou habitam a terra ou são mamíferos anormais* e que *baleias não habitam a terra*. Assumindo que o predicado de normalidade é circunscrito, pode-se inferir que *baleias são mamíferos anormais* e que *mamíferos anormais são mamíferos que não habitam a terra*.

Esta abordagem também não utiliza a informação de exemplares para fundamentar a classificação de novos indivíduos. Além disso, esta abordagem também não é capaz de capturar a natureza gradual da tipicidade e não oferece um meio natural de suporte para raciocínio baseado em similaridade.

### 2.2.2.3 Lógica de descrição com operador de tipicidade

Em (GIORDANO et al., 2013), é proposta uma extensão da lógica de descrição  $\mathcal{ALC}$ , que permite representar (e raciocinar sobre) conhecimento sobre o que é típico no domínio e herança com exceções. A lógica não monotônica resultante é obtida pela adição de um operador de tipicidade  $T$  à  $\mathcal{ALC}$ . Este operador é utilizado para representar as *instâncias mais típicas* (ou mais normais) de um conceito. Deste modo é possível representar relações de subsunção na forma de  $T(B) \sqsubseteq A$ , que expressa que *instâncias típicas de B são também instâncias de A*. Deste modo, seria possível representar que *tipicamente, aves são animais voadores* através de  $T(Ave) \sqsubseteq AnimalVoador$  e que *pinguins são aves que não voam* ( $Pinguim \sqsubseteq Ave \sqcap \neg AnimalVoador$ ). Com isso, sabendo-se que *Polly é uma ave* ( $Ave(Polly)$ ) é possível inferir que *Polly é um animal voador* ( $AnimalVoador(Polly)$ ), se estiver ausente qualquer informação que nos permita concluir que *Polly não é um animal voador*. No entanto, em um cenário em que novas informações incluídas na base de conhecimento permitissem a conclusão de que *Polly é um pinguim* ( $Pinguim(Polly)$ ), a conclusão anterior deveria poder ser substituída pela nova conclusão, de que *Polly não voa* ( $\neg AnimalVoador(Polly)$ ).

Os autores discutem que a lógica resultante possui limitações para lidar com herança múltipla. Nestes casos, as inferências resultantes podem ser bastante diferentes das esperadas. Além disso, esta abordagem também não utiliza a informação de exemplares para fundamentar a classificação de novos indivíduos. Esta abordagem também não é capaz de capturar a natureza gradual da tipicidade e não oferece um meio natural de suporte para raciocínio baseado em similaridade.

### 2.2.3 Abordagens híbridas

Nesta Seção, serão discutidas abordagens para representação de conhecimento que buscam superar algumas limitações relacionadas à adoção de formalismos clássicos (como a DL e a OWL), mas que não constituem extensões destes formalismos. Assim, nesta seção serão consideradas principalmente abordagens híbridas, que utilizam abordagens clássicas como apenas um dos componentes.

#### 2.2.3.1 Integração de abordagem clássica com protótipos

Em (FRANCONI; MAGNINI; STOCK, 1992) é proposta uma abordagem para representação de conhecimento e raciocínio que combina uma abordagem clássica com protótipos. Os protótipos são representados por coleções de pares atributo-valor que abstraem o conjunto de instâncias de um dado conceito.

O raciocínio de classificação proposto pela abordagem é guiado pelo componente *terminológico* (no qual os conceitos são descritos em termos de *condições necessárias*). Deste modo, considerando-se um determinado indivíduo  $i$  que deve ser classificado, em um primeiro passo, verifica-se quais conceitos têm suas condições necessárias atendidas por  $i$ . Este passo resulta em um conjunto de conceitos candidatos  $C$ . Para decidir quais conceitos em  $C$  classificam o indivíduo  $i$ , utiliza-se a informação relacionada aos protótipos destes conceitos e raciocínio baseado em similaridade. Assim, verifica-se a similaridade entre  $i$  e o protótipo de cada conceito em  $C$  e seleciona-se os conceitos para os quais a similaridade entre o protótipo e o indivíduo  $i$  for maior que um dado limiar  $l$ . Dentre os conceitos selecionados, o indivíduo é classificado em todos os conceitos não disjuntos e, no caso de grupos de conceitos disjuntos, seleciona-se o conceito cujo protótipo é mais similar a  $i$ .

Esta abordagem adota uma postura conservadora, assumindo que o conhecimento capturado no componente terminológico tem prioridade e é mais confiável do que as inferências baseadas em similaridade. É importante também notar que esta abordagem utiliza apenas definições e informações relativas a protótipos, de modo que não utiliza informações relativas a exemplares durante o raciocínio baseado em similaridade. Considerando que diversos trabalhos (HUANG et al., 2010; DING et al., 2013; DOHNÁLEK et al., 2014) apontam que abordagens computacionais de classificação que consideram exemplares (tais como o *K-nearest neighbors*) resultam em uma acurácia maior do que a acurácia resultante de abordagens baseadas em protótipos, assumimos como hipótese que esta abordagem poderia ser aperfeiçoada se considerasse também informações de exemplares.

### 2.2.3.2 Ontologias com múltiplos protótipos

Em (CAI; LEUNG; FU, 2008) é proposto o que os autores chamam de modelo cognitivo de ontologia. Neste modelo, os conceitos possuem *múltiplos protótipos* e é possível determinar a tipicidade de uma determinada instância de um dado conceito. O objetivo do modelo é permitir a classificação de novas instâncias de um modo que se aproxime da performance cognitiva humana.

A abordagem utiliza múltiplos protótipos porque representam melhor *conceitos disjuntivos*, que seriam conceitos definidos por disjunções (por exemplo, a necessidade de uma propriedade *A* ou de uma propriedade *B*, tal como o conceito de *objeto que é vermelho ou verde*) (COLMAN, 2015). Para obter os múltiplos protótipos de um conceito *c*, assume-se que as instâncias de *c* podem ser agrupadas em *n* diferentes grupos de objetos que são mais similares entre si, do que são similares a objetos de outros grupos. Deste modo, define-se um protótipo para cada um dos *n* grupos de *c*, onde cada protótipo é uma representação abstrata extraída de um dos grupos. Como resultado, cada conceito é representado por uma lista de *n* protótipos. Nesta abordagem, cada protótipo e cada objeto (instância) é definido por um vetor de propriedades e valores, onde cada valor varia de 0 a 1 e representa o grau com que o objeto possui a propriedade. Além disso, a abordagem estabelece a possibilidade de determinar a similaridade entre um objeto e um protótipo como uma função decrescente da distância entre os vetores. A dissimilaridade, por outro lado, é definida como o complemento da similaridade.

De acordo com a abordagem, há dois fatores que influenciam a tipicidade de um objeto em relação a um conceito: a *tendência central do objeto* em relação a um conceito e a *frequência de instanciação* de um grupo representado por um protótipo. A tendência central de um objeto é determinada por uma função da *similaridade interna* e da *dissimilaridade externa*. Neste contexto, a similaridade interna de um objeto *o* em relação a um conceito *c* é determinada pela similaridade entre *o* e o protótipo de *c* que é mais similar a *o*. Já a dissimilaridade externa é considerada como a média das dissimilaridades entre o objeto *o* e os protótipos mais próximos de *o* de cada conceito *c<sub>i</sub>* diferente de *c*. Já a frequência de instanciação é definida para cada protótipo *p* de cada conceito *c*, como a razão entre o número de instâncias do grupo abstraído por *p* e o número de instâncias total do conceito *c*. O objetivo deste fator é representar a saliência de um protótipo, assumindo que as pessoas considerariam mais típicas as instâncias de um conceito que seriam mais similares a um protótipo com alta saliência (representando um grupo com mais instâncias). Deste modo, a tipicidade de um objeto *a* para um conceito *c* é uma função da tendência central de *a* para o conceito *c* e da saliência (relacionada à frequência de instanciação) do protótipo de *c* mais similar a *a*. De modo que, quanto maior a tendência central de *a* em relação a *c* e quanto maior a saliência relacionada ao protótipo de *c* mais similar a *a*, maior é a tipicidade de *a* em relação a *c*.

O trabalho não esclarece como define-se o grau com que um objeto possui uma determinada propriedade. Além disso, também não está claro se e como a abordagem utiliza as definições dos conceitos durante os processos de raciocínio para classificação. Também não fica claro como a utilização das definições é combinada com a noção de tipicidade durante a classificação. Além disso, a quantidade de protótipos deve ser arbitrariamente selecionada. Apesar da flexibilidade que esta decisão proporciona, a seleção do número adequado de protótipos provavelmente varie para cada conceito, em cada aplicação. Deste modo, a seleção do número de protótipos pode ser uma tarefa não trivial. Também é importante salientar que esta abordagem faz um uso incipiente de informações sobre exemplares. A única informação sobre exemplares utilizada é a informação utilizada para determinar a frequência de instanciação. Deste modo, as propriedades dos exemplares não são consideradas.

### 2.2.3.3 Representação de tipicidade e significados vagos em ontologias

Em (YEUNG; LEUNG, 2006; YEUNG; LEUNG, 2008), discute-se uma abordagem para representação de conceitos com significados *vagos* e tipicidade em ontologias. Basicamente, os autores utilizam lógica nebulosa (*fuzzy*) para representar conceitos com significado vago e utilizam protótipos para representar a tipicidade de cada conceito da ontologia.

Nesta proposta, a cada conceito  $c$  da ontologia é associado um *vetor característico* de  $n$  valores entre 0 e 1, cada qual representando o grau de importância de cada uma das  $n$  propriedades de  $c$ . Além disso, a cada indivíduo é associado um *vetor de propriedades* de  $n$  valores entre 0 e 1, cada qual representando o grau com que o indivíduo possui a propriedade. O trabalho também propõe uma alternativa para determinar a subsumção entre dois conceitos  $c_1$  e  $c_2$ , em função dos seus vetores característicos. Assim,  $c_2$  seria subsumido por  $c_1$  se  $c_2$  tivesse em seu vetor característico, valores maiores que os valores do vetor característico de  $c_1$ .

Além disso, o trabalho também define *likeness* como sendo o grau de pertencimento de um indivíduo a um conceito, variando entre 0 e 1. A função proposta para medir o *likeness* de um indivíduo  $a$  para um conceito  $x$  segue alguns axiomas propostos pelos autores e é representada por  $\lambda_x(a) = \min l_i$ , onde

$$l_i = \begin{cases} p_{a,i} + (1 - c_{x,i}) \times (1 - p_{x,i}), & c_{x,i} > 0, p_{a,i} > 0 \\ 0, & c_{x,i} > 0, p_{a,i} = 0 \\ 1, & c_{x,i} = 0 \end{cases} \quad (2.3)$$

, considerando-se que  $p_{a,i}$  é o  $i$ -ésimo valor do vetor de propriedades do indivíduo  $a$  e  $c_{x,i}$  é  $i$ -ésimo valor do vetor característico do conceito  $c$ .



Já a typicalidade de um indivíduo  $a$  para um conceito  $c$  é determinada em função do protótipo de  $c$ . Os autores definem um *vetor de protótipo* para cada conceito  $c$  (definido como  $t_c$ ), como sendo um vetor com  $n$  valores entre 0 e 1, onde o  $i$ -ésimo valor é dado pela média dos  $i$ -ésimos valores dos vetores característicos dos conceitos que especializam  $c$ . Com isso, a typicalidade de um indivíduo  $a$  para um conceito  $c$  é dada por:

$$T_x(a) = \frac{p_a \cdot t_x}{\sum_{i=1}^n t_{x,i}} \quad (2.4)$$

No entanto, o trabalho não esclarece como é definido na prática o grau com que um objeto possui suas propriedades. Também não fica claro como a typicalidade e o *likeness* são utilizados efetivamente em processos de raciocínio. Além disso, apesar da abordagem assumir que a ontologia possui definições para os conceitos, não fica claro como as definições são efetivamente utilizadas pela abordagem e como elas interagem com a typicalidade e o *likeness* dos objetos durante os processos de raciocínio. Outro ponto que pode ser visto como uma desvantagem é o fato de que o trabalho não explora informações relacionadas a outros exemplares para auxiliar na classificação de novos exemplares. Além disso, a abordagem também limita os tipos de propriedades que podem ser atribuídas a conceitos e indivíduos a propriedades que os autores chamam de proposicionais, tais como *tem asas*, *tem cauda*, *voa*, etc. Assim, a abordagem não permite a representação de propriedades de outros tipos, como as propriedades numéricas ou categoriais.

#### 2.2.3.4 Integração de abordagem clássica, protótipos e exemplares

Em (LIETO et al., 2015), é proposta uma abordagem de representação de conhecimento e raciocínio que combina uma abordagem clássica com informações relativas a protótipos e informações relativas a exemplares em um processo de raciocínio de classificação baseado nas *teorias duais de raciocínio*, tais como as discutidas em (EVANS, 2006; EVANS, 2008; EVANS; FRANKISH, 2009). Assim, de acordo com esta abordagem, cada conceito teria uma definição clássica, um protótipo e todas as instâncias deste conceito seriam consideradas exemplares.

Neste modelo, para classificar um dado indivíduo  $i$ , primeiramente um *sistema de raciocínio heurístico* ( $S_1$ ) realiza um julgamento heurístico e determina qual conceito  $C$  é o mais adequado para classificar  $i$ . A seguir, um *sistema de raciocínio analítico* ( $S_2$ ) verifica se há inconsistências lógicas caso  $i$  seja considerado como instância do conceito  $C$  (determinado pelo sistema  $S_1$ ), considerando-se o conhecimento capturado em uma ontologia (que descreve os conceitos classicamente, em termos de definições). Caso não exista inconsistência, assume-se  $C$  como o conceito que classifica  $i$ . Caso seja detectada

uma inconsistência lógica, o sistema  $S_1$  avalia um conjunto fixo de  $n$  novos candidatos. Se todas as  $n$  classificações forem consideradas inconsistentes, o sistema  $S_2$  determina, utilizando raciocínio lógico, qual é o conceito  $C$  que classifica o indivíduo  $i$  de modo adequado, de modo consistente com a ontologia.

Os processos realizados pelo sistema  $S_2$  são analiticamente dirigidos e suportados por uma ontologia que define logicamente cada um dos conceitos em termos de condições necessárias e/ou suficientes. Já os processos realizados pelo componente  $S_1$  são suportados por julgamento de similaridade e utilizam informações relacionadas a protótipos e exemplares. Este componente determina a similaridade  $s$  entre o indivíduo  $i$  e o exemplar  $e$  mais similar na base de conhecimento. Se  $s > l$ , onde  $l$  é um limiar de similaridade, o conceito  $C$  representado pelo exemplar  $e$  é considerado um conceito candidato para classificar  $i$ . Caso contrário, o componente determina qual é o protótipo  $p$  mais similar a  $i$  na base de conhecimento e retorna o conceito  $C$  representado por  $p$ . É importante notar também que o componente  $S_1$  considera a lista  $L$  de conceitos candidatos que foram considerados inconsistentes enquanto classificações de  $i$ . Deste modo, ao analisar a similaridade de exemplares e protótipos em relação a  $i$ , ele recupera os exemplares e protótipos mais similares e cujos conceitos não estão em  $L$ .

A principal limitação desta abordagem está no fato de que ela só é capaz de classificar um dado indivíduo em um e somente um conceito. Isto constitui uma limitação porque, em geral, seres humanos são capazes de classificar a mesma instância em múltiplos conceitos e esta capacidade é desejável em sistemas que realizam classificação automática. Outra possível limitação da abordagem está no fato de adotar os *espaços conceituais* (GÄRDENFORS, 2004b) como forma de representar exemplares e protótipos. Isto pode ser uma limitação porque a representação em espaços conceituais requer um conjunto de dimensões, cujos valores devem ser parcialmente ordenados. Deste modo, representar atributos *categoriais* (ou nominais) torna-se um desafio, visto que não há qualquer ordem intrínseca entre valores deste tipo (ANDRITSOS; TSAPARAS, 2010). Também é possível notar que a informação relativa aos protótipos é utilizada apenas em último caso durante a classificação, de modo que ela pode ser subutilizada na maior parte dos casos. Além disso, é importante salientar que o julgamento de similaridade entre o objeto que se deseja classificar e cada um dos exemplares, é realizado individualmente. Ou seja, é adotado um procedimento de classificação equivalente ao *nearest neighbor classifier* (COVER; HART, 1967), que é bastante sensível ao ruído (AGGARWAL, 2014). Assim, a qualidade do resultado da abordagem como um todo pode ser comprometida caso a base de exemplares contenha ruído. Este problema poderia ser contornado pela adoção de procedimentos mais sofisticados, projetados para serem mais resistentes a ruído,

tais como os apresentados em (MITANI; HAMAMOTO, 2006; ZENG; YANG; ZHAO, 2009). Acrescenta-se também que, uma vez que a abordagem adota todo o conjunto de instâncias de um conceito como seus exemplares, ela pode se tornar difícil de ser aplicada em casos em que os conceitos possuem muitas instâncias.

### 2.3 Abordagens para seleção de instâncias

De acordo com (GARCÍA; LUENGO; HERRERA, 2015), a *seleção de instâncias* é uma tarefa que consiste em escolher um subconjunto do conjunto total de dados (instâncias) disponíveis para realizar o propósito original de uma dada aplicação (geralmente de mineração de dados ou aprendizado de máquina) de modo que a performance resultante seja igual ou próxima da performance obtida se fossem considerados todos os dados disponíveis. Em geral, esta tarefa é realizada por uma família de métodos que buscam selecionar o melhor subconjunto possível de exemplares dos dados originais, usando alguma heurística. Assim, o resultado ótimo da tarefa de seleção de instâncias seria selecionar o subconjunto mínimo de dados com o qual é possível realizar uma dada tarefa *sem perda de performance*. Deste modo, toda estratégia de seleção de instâncias deve manter um bom compromisso entre a *redução* do conjunto de dados e a qualidade da *performance* (CHOU; KUO; CHANG, 2006).

Em geral, a seleção de instâncias pode ser utilizada para reduzir o conjunto de dados original para um subconjunto menor e mais fácil de gerenciar, gerando uma redução dos recursos computacionais (em termos de tempo de processamento e espaço de armazenamento) que são necessários para realizar uma tarefa (LIU; MOTODA, 2002; LIN et al., 2015; LEYVA; GONZÁLEZ; PÉREZ, 2015; GARCÍA; LUENGO; HERRERA, 2015). Além disso, algoritmos de seleção de instâncias podem também ser aplicados para remover instâncias redundantes ou ruído, antes de utilizar os dados na tarefa em questão. Devido a isso, quando a seleção de instâncias é aplicada como um passo de pré-processamento em uma tarefa de aprendizado de máquina, a acurácia dos modelos aprendidos pode aumentar (LIU; MOTODA, 2002; GARCÍA; LUENGO; HERRERA, 2015).

Nesta Seção, serão discutidos alguns dos principais e mais recentes algoritmos de seleção de instâncias. Para a maioria dos algoritmos apresentados,  $T$  representará o conjunto original de instâncias e  $S$ , onde  $S \subseteq T$ , representará o conjunto reduzido de instâncias, resultante da aplicação de um algoritmo de seleção de instâncias.

Em (HART, 1968) é proposta uma abordagem chamada *Condensed Nearest Neighbor* (CNN). Esta abordagem seleciona aleatoriamente uma instância que pertence a cada classe de  $T$  e a adiciona em  $S$ . No próximo passo, cada instância em  $T$  é classificada usando apenas as instâncias em  $S$ . Se uma instância é classificada incorretamente, ela é

adicionada a  $S$ , para garantir que ela será classificada corretamente. Este processo é repetido até que nenhuma instância em  $T$  seja classificada de modo incorreto. É importante notar que esta abordagem pode incluir em  $S$  instâncias que constituem *ruído*, causando efeitos negativos na acurácia da classificação. Além disso, esta abordagem é dependente da ordem em que as instâncias são avaliadas. A complexidade temporal desta abordagem é  $O(|T|^2)$ , onde  $|T|$  é o tamanho do conjunto de dados original.

O algoritmo chamado *Reduced Nearest Neighbor* (RNN) (GATES, 1972), adiciona todas as instâncias de  $T$  em  $S$ , em um primeiro passo. A seguir remove-se cada instância de  $S$ , até que nenhuma instância em  $T$  seja classificada de modo incorreto pelas instâncias em  $S$ . O RNN produz subconjuntos  $S$  que são menores que os subconjuntos produzidos pelo algoritmo CNN. Além disso, o RNN é menos sensível a ruído do que o CNN. No entanto a complexidade temporal do RNN é  $O(|T|^3)$ , que é maior que a complexidade temporal do CNN.

Em (CHOU; KUO; CHANG, 2006), os autores propõem uma extensão do algoritmo CNN, chamado *Generalized Condensed Nearest Neighbor* (GCNN). Esta abordagem é bastante similar ao algoritmo CNN. No entanto, o algoritmo GCNN inclui apenas instâncias que satisfazem um *critério de absorção*. Considerando-se  $d_N(x)$  como a distância entre  $x$  e seu vizinho mais próximos, e  $d_E(x)$  como sendo a distância entre  $x$  seu inimigo mais próximo (uma instância que pertence a uma classe que é diferente da classe a que  $x$  pertence);  $x$  é incluído em  $S$  apenas se  $d_N(x) - d_E(x) > \rho$ , onde  $\rho$  é um limiar arbitrário. O algoritmo GCNN é capaz de produzir subconjuntos  $S$  que são menores que os conjuntos produzidos pelo algoritmo CNN. No entanto, determinar o valor de  $\rho$  não é uma tarefa trivial.

No algoritmo ENN (*Edited Nearest Neighbor*) (WILSON, 1972), todas as instâncias de  $T$  são incluídas em  $S$ , em um primeiro passo. Então, cada instância em  $S$  é removida se ela não concorda com o rótulo da maioria dos seus  $k$  vizinhos mais próximos. Este algoritmo é muito utilizado para remover de ruído e melhorar a performance em aplicações de aprendizado de máquina. Diferentemente de outros algoritmos de seleção de instâncias, o ENN mantém instâncias internas, enquanto remove instâncias das bordas. Deste modo, o ENN não é capaz de reduzir o conjunto de dados tanto quanto outros algoritmos disponíveis. A literatura também oferece algumas extensões ao ENN, tais como (TOMEK, 1976).

Em (WILSON; MARTINEZ, 2000), os autores propõem uma família de 5 abordagens, conhecidos como *Decremental Reduction Optimization Procedure* (DROP). Nestes algoritmos, para cada instância  $x$  são mantidos os  $k$  vizinhos mais próximos, e as instâncias que possuem  $x$  como um dos seus  $k$  vizinhos mais próximos são chamados de *associados* de  $x$ . Entre os algoritmos propostos, o DROP3 é o que possui o melhor com-

promisso entre redução do conjunto de dados e acurácia de classificação. No passo inicial, o DROP3 aplica um algoritmo para remoção de ruído, como o ENN. Então, ele remove uma instância  $x$  se os seus associados em  $T$  podem ser corretamente classificados sem  $x$ . O principal problema do DROP3 é a sua complexidade temporal elevada.

O algoritmo ICF (*Iterative Case Filtering algorithm*) (BRIGHTON; MELLISH, 2002) é baseado nas noções de *conjunto de cobertura* e *conjunto alcançável*. O conjunto de cobertura de uma instância  $x$  é o conjunto de instâncias em  $T$  cuja distância de  $x$  é menor que a distância entre  $x$  e seu inimigo mais próximo (instância que pertence a uma classe diferente). O conjunto alcançável de uma instância  $x$  é o conjunto de instâncias em  $T$  que possuem  $x$  em seus respectivos conjuntos de cobertura. Neste método, uma dada instância  $x$  é removida de  $S$  se  $|Alcançável(x)| > |Cobertura(x)|$ , isto é, quando o número de instâncias que conseguem classificar  $x$  corretamente é maior que o número de instâncias que  $x$  pode classificar corretamente.

Recentemente, em (LEYVA; GONZÁLEZ; PÉREZ, 2015), os autores propõem 3 métodos complementares para seleção de instâncias que são baseados na noção de *conjunto local*. Neste contexto, o conjunto local de uma dada instância  $x$  é o conjunto de instâncias contidas na maior hiperesfera centrada em  $x$ , de tal modo que ela não contenha nenhuma instância de qualquer outra classe diferente da classe a que  $x$  pertence. O LSSm (*local set-based smoother*) foi proposto para remover instâncias que são prejudiciais, isto é, instâncias que classificam incorretamente mais instâncias do que aquelas que elas classificam corretamente. Este algoritmo usa duas noções para guiar o processo de remoção: *utilidade* e *nocividade*. A utilidade  $u(x)$  de uma dada instância  $x$  é o número de instâncias que possuem  $x$  entre os membros do seu conjunto local, e a nocividade  $h(x)$  é o número de instâncias que possuem  $x$  como seu inimigo mais próximo. Para cada instância  $x$  em  $T$ , o algoritmo inclui  $x$  em  $S$  se  $u(x) \geq h(x)$ . A complexidade temporal de LSSm é  $O(|T|^2)$ . O segundo algoritmo, o LSCo (*Local Set-based Centroids Selector method*), primeiramente aplica o LSSm para remover ruído e então aplica um método de agrupamento (*clustering*) baseado em conjunto locais (CAISES et al., 2011) para identificar cluster em  $T$  sem *pontos invasivos* (instâncias que estão cercadas de instâncias de uma classe diferente). O algoritmo mantém em  $S$  apenas os centroides dos agrupamentos resultantes. Finalmente, o terceiro algoritmo, o LSBo (*Local Set Border Selector*), primeiramente aplica o algoritmo LSSm para remover ruído e, a seguir, ele computa os conjuntos locais de cada instância em  $T$ . Então, as instâncias em  $T$  são ordenadas de modo ascendente em relação à cardinalidade de seus conjuntos locais. No último passo, o LSBo verifica, para cada instância  $x$  in  $T$  se algum membro do seu conjunto local está contido em  $S$ , para garantir a classificação apropriada de  $x$ . Se este não for o caso,  $x$  é incluído em  $S$  para assegurar sua correta classificação. A complexidade temporal das três abordagens é proporcional a  $O(|T|^2)$ . Entre os três algoritmos, o LSBo apresenta o melhor equilíbrio entre redução e acurácia.

Outras abordagens são discutidas em trabalhos de revisão, tais como (HAMID-ZADEH; MONSEFI; YAZDI, 2015; LEYVA; GONZÁLEZ; PÉREZ, 2015; GARCÍA; LUENGO; HERRERA, 2015).

### 3 ABORDAGEM COGNITIVAMENTE INSPIRADA PARA REPRESENTAÇÃO DE CONHECIMENTO E RACIOCÍNIO

Neste capítulo são apresentadas as principais propostas desta tese. Na Seção 3.1 é apresentada uma visão geral da proposta deste trabalho. Na Seção 3.2 apresenta-se a formalização de um arcabouço híbrido para representação de conhecimento que combina as vantagens da teoria clássica, da teoria do protótipo e da teoria dos exemplares. A Seção 3.3 apresenta um procedimento que integra raciocínio lógico tradicional (que utiliza representações clássicas) com raciocínio baseado em similaridade (que utiliza informações a respeito de protótipos e exemplares), em um modelo híbrido de raciocínio para classificação. Além disso, como esta abordagem adota protótipos e exemplares como componentes de representação de conhecimento, na Seção 3.4 são apresentadas abordagens para extração de protótipos e seleção de exemplares.

#### 3.1 Visão geral da proposta

Os sistemas baseados em conhecimento (SBC) são atualmente uma tecnologia madura que vem sendo aplicada em diversos cenários. Em geral, os SBC são caracterizados por uma abordagem *top-down*, onde o conhecimento relevante para solução de uma classe de problemas é explicitamente representado de uma forma computacionalmente processável e o processo de resolução de problemas realizado pelo sistema é suportado por este conhecimento. Na área de representação de conhecimento e raciocínio (*KR*, de *Knowledge representation and reasoning*), que pode ser vista como uma subárea da Inteligência Artificial, são investigadas abordagens para representar o conhecimento incorporado em SBCs.

Muitos trabalhos na área de representação de conhecimento e raciocínio têm proposto linguagens formais baseadas em lógica, tais como as lógicas de descrição (*DL* de *Description logics*) e a *OWL* (*Web Ontology Language*), como linguagens para representar conhecimento. De acordo com (GÄRDENFORS, 2004c), tais abordagens adotam implicitamente a *teoria clássica* de representação de conceitos, na qual os conceitos são definidos em função de suas *condições necessárias e suficientes*. Apesar da popularização de tais abordagens de representação, é bem estabelecido tanto nas Ciências Cognitivas quanto na Ciência da Computação, que encontrar condições necessárias e suficientes para a maioria dos conceitos que utilizamos cotidianamente não é uma tarefa trivial (FRANCONI; MAGNINI; STOCK, 1992; GÄRDENFORS, 2004b; LIETO, 2012; PRESTES et al., 2013; LIETO et al., 2015). Devido a isto, em muitos casos, são utilizadas nas definições de conceitos apenas condições necessárias, que não são conjuntamente suficientes. Isto é, são especificadas apenas as condições que necessariamente devem ser atendidas

para um indivíduo  $i$  ser classificado em um dado conceito  $c$ , mas tais condições não são suficientes para estabelecer de modo unívoco que  $i$  é classificado por  $c$ . Por exemplo, em (PRESTES et al., 2013), os autores discutem as dificuldades de se estabelecer condições que sejam necessárias e suficientes para definir o que é um Robô. A abordagem adotada pelos autores foi estabelecer um conjunto de condições necessárias, mas que não são suficientes para considerar um dado indivíduo como um Robô.

Além desta dificuldade relacionada às abordagens clássicas, existem diversas fontes de evidências de que tais abordagens não são capazes de acomodar outras competências que são típicas da cognição humana. Isto pode ser uma desvantagem, considerando-se que a reprodução das habilidades cognitivas humanas costuma ser um objetivo subjacente ao uso de tais abordagens. Por exemplo, em (GÄRDENFORS, 2004c; GÄRDENFORS, 2004b) sugere-se que, em muitas tarefas de classificação, os seres humanos classificam objetos com base na *similaridade* com instâncias típicas (protótipos) ou exemplares de conceitos. De acordo com (GÄRDENFORS, 2004c), esta flexibilidade é uma característica importante que falta às abordagens clássicas, enquanto abordagens de representação de conhecimento, para que sejam capazes de suportar classificação de um modo mais flexível, e que se assemelhe à performance humana. Desta falta de flexibilidade decorrem algumas consequências que podem ser limitantes em certas aplicações. Uma destas limitações é a própria impossibilidade de se classificar indivíduos como instâncias de um determinado conceito, caso a definição do conceito não determine quais são as condições suficientes para um indivíduo ser considerado sua instância.

Além disso, em certos contextos, as descrições dos indivíduos que se deseja classificar são carentes de informação importante para suportar a classificação, seja por ignorância (no caso do valor de uma determinada propriedade não ser conhecido), seja por negligência de propriedades importantes no momento da descrição de um indivíduo. Nestes casos, caso seja adotada uma classificação clássica, baseada em condições necessárias e suficientes, a falta de alguma informação poderia afetar muito o resultado da classificação. Isto torna as abordagens baseadas no paradigma clássico pouco resilientes. Um modelo de classificação que considere a similaridade para suportar a decisão poderia fornecer classificações estimadas ainda que não fossem descritas todas as informações necessárias, desde que o indivíduo a ser classificado fosse suficientemente similar ao protótipo ou aos exemplares de um determinado conceito.

Estas limitações das abordagens de representação de conhecimento que seguem a concepção clássica (baseada em condições necessárias e suficientes) também foram discutidas pelas Ciências Cognitivas, que buscam teorias para explicar e prever a performance humana em diversas tarefas cognitivas. Nesta área, foram propostas teorias alternativas à teoria clássica, visando a superação de tais dificuldades e a consideração



de múltiplas fontes de evidências empíricas sobre como os humanos realmente realizam tarefas cognitivas como a classificação. Devido a isto, nesta tese buscamos inspiração em estudos das Ciências Cognitivas para desenvolver uma abordagem para representação de conhecimento capaz de lidar com essas dificuldades.

Nas ciências cognitivas, os *conceitos* são considerados entidades que participam de diversos processos cognitivos, tais como categorização, planejamento, raciocínio, etc. Segundo (MURPHY, 2002), apesar da teoria clássica ter sido praticamente abandonada como uma teoria geral sobre como os conceitos são representados na cognição humana, as principais teorias a respeito da natureza dos conceitos, até o momento, não foram capazes de explicar de modo satisfatório todos os aspectos relacionados aos conceitos. Conforme visto na Seção 2.1.2, a *teoria clássica* é capaz de explicar a *composicionalidade* dos conceitos e como os conceitos participam de *inferências lógicas dedutivas*, no entanto, falha em explicar os fenômenos de *tipicalidade*, por exemplo. Estes, por sua vez, são explicados de modo adequado pela *teoria do protótipo* e pela *teoria do exemplar*, que por outro lado, não são capazes de explicar a composicionalidade dos conceitos.

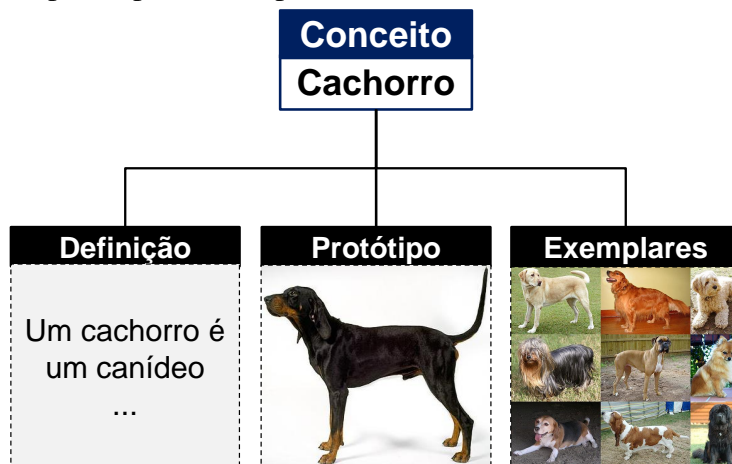
Diante deste panorama, nos últimos anos, trabalhos como (VICENTE; MANRIQUE, 2014) têm sugerido uma concepção *híbrida* dos conceitos. De acordo com estas concepções, os conceitos seriam corpos de conhecimento que integrariam diversos tipos de informações, tais como *definições*, *protótipos* e *exemplares*. Algumas destas abordagens, como as discutidas em (MILLER; JOHNSON-LAIRD, 1976; OSHERSON; SMITH, 1981; SMITH; MEDIN, 1981), assumem que o conceito é formado por um *núcleo* e um *procedimento de identificação*. Nesta visão, chamada de *core + identification procedure* (CIP), o núcleo incluiria um conjunto de *condições necessárias* e relações com outros conceitos, enquanto o procedimento de identificação incluiria a informação (típica) necessária para classificar instâncias do conceito. Por exemplo, segundo esta abordagem, o conceito de *Cachorro* seria representado por um núcleo que definiria que todo o *Cachorro* é necessariamente um *Canídeo* (com todas as suas propriedades necessárias), e que tipicamente possui 4 patas, possui uma cauda, late, etc. Note que, segundo estas formulações, o procedimento de identificação seria suportado por informações relativas ao protótipo, de modo que as informações relativas a exemplares não seriam consideradas.

Abordagens recentes, como a proposta em (LIETO, 2012; LIETO et al., 2015), também buscam estabelecer uma caracterização de conceitos que permita realizar computacionalmente a mesma gama de tarefas cognitivas que são realizadas por seres humanos. Estas abordagens diferenciam-se das abordagens CIP pelo fato de que, além de incluírem definições e protótipos, também buscam integrar informações relativas a exemplares na representação de conceitos.

Nesta tese, apresentamos uma abordagem híbrida para representação de conhecimento que é baseada nas teorias híbridas desenvolvidas nas Ciências Cognitivas. Esta abordagem combina as vantagens das abordagens que adotam a teoria clássica, como ontologias, com a possibilidade de representar características típicas dos conceitos (através de protótipos) bem como características que constituem exceções ao que é típico (através de exemplares). Assim, de acordo com a abordagem proposta, cada conceito pode incluir três tipos básicos de informações: informações clássicas, que incluem uma definição que estabelece um conjunto de condições necessárias (embora possa incluir condições suficientes), bem como relações com outros conceitos; um protótipo que define as características típicas de uma instância do conceito; e um conjunto de exemplares que representam a variabilidade de instâncias do conceito. Tal abordagem possui a vantagem de suportar *raciocínio lógico* e *raciocínio baseado em similaridade* em um mesmo arcabouço representacional integrado e permitir, simultaneamente, tanto a composicionalidade de conceitos quanto a consideração de efeitos de tipicidade.

É importante salientar também que, apesar de intuições sobre a combinação de definições, protótipos e exemplares serem discutidas na literatura das Ciências Cognitivas, a literatura em Ciência da Computação ainda carece de um arcabouço formal que permita a utilização destas informações para o desenvolvimento de sistemas computacionais. Deste modo, como proposta desta tese, na Seção 3.2, apresentamos a noção de *base de conhecimento estendida*, como um arcabouço formal híbrido para representação de conhecimento. A Figura 3.1 representa, de modo esquemático, a relação dos principais elementos da representação do conceito de *Cachorro*, de acordo com a abordagem aqui proposta. O conceito *Cachorro* é representado por uma definição parcial, que inclui apenas suas condições necessárias (e suficientes, se possível) e relações com outros conceitos; um protótipo, que representa as características típicas de um cachorro; e um conjunto de exemplares, que representam instâncias reais de cachorro que são representativas do conceito de cachorro.

Figura 3.1: Esquema ilustrando uma representação híbrida do conceito de cachorro, incluindo definição, protótipos e exemplares.

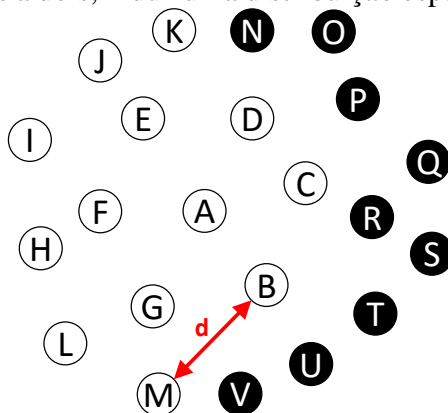


Fonte: Produzida pelo autor utilizando imagens disponibilizadas em <<https://en.wikipedia.org/wiki/Dog>>.

Uma vez que a abordagem proposta nesta tese utiliza protótipos e exemplares, é importante estabelecer como as noções de protótipo e exemplar são compreendidas neste contexto. Um exemplar de um dado conceito  $c$ , no contexto desta tese, é compreendido como um *indivíduo real*, que pertence à extensão de  $c$  e que é representativo de conjuntos de indivíduos que são instâncias de  $c$ . É importante notar que, para alguns conceitos, nem todas as suas instâncias serão necessariamente consideradas como exemplares. Já o protótipo de um conceito  $c$  é compreendido como sendo a *instância ideal* de  $c$ . Isto é, o protótipo de  $c$  pode não ser idêntico a qualquer indivíduo real. Além disso, assumindo-se que a *dissimilaridade* entre indivíduos pode ser vista como uma *distância* entre esses indivíduos (GÄRDENFORS, 2004b), o conjunto das distâncias entre os indivíduos resultantes do julgamento de similaridades/dissimilaridades entre eles nos permite conceber tais indivíduos como estando espacialmente distribuídos (conforme representado na Figura 3.2). Com isto em mente, neste trabalho, assumimos que o protótipo de  $c$  pode ser visto como o *centroide* do conjunto de indivíduos que formam a extensão de  $c$ . Esta caracterização do protótipo é adotada em diversos trabalhos, tais como (MURPHY, 2002; PALMERI; NOELLE, 2003; GÄRDENFORS, 2004b).

De acordo com (NEWELL, 1982), uma abordagem de representação de conhecimento só é útil se existir algum procedimento capaz de processá-la adequadamente. Deste modo, nesta tese também é proposta uma *abordagem de raciocínio híbrido*, que adota a abordagem de representação híbrida proposta nesta tese. O principal objetivo desta abordagem é permitir a classificação de novos indivíduos, com base nas informações combinadas de exemplares, protótipos e definições de conceitos. Este método de raciocínio é apresentado na Seção 3.3.

Figura 3.2: Exemplo de representação espacial de indivíduos. O grau de *dissimilaridade*  $d$  entre os indivíduos  $M$  e  $B$  pode ser interpretada como a *distância* entre tais indivíduos em um espaço abstrato. Assim, o conjunto das dissimilaridades entre todos os indivíduos de um conjunto, tomados dois a dois, induz uma distribuição espacial de todos os indivíduos.



Fonte: Produzida pelo autor.

Devido à adoção de protótipos e exemplares na abordagem de representação proposta nesta tese, neste trabalho também apresentamos propostas para extração de protótipos e seleção de exemplares a partir do conjunto de indivíduos representados pelo sistema. O método para extração de protótipos é uma consequência direta da definição de protótipo como sendo o centroide do conjunto de instâncias de um conceito. Além disso, como contribuição desta tese, também são propostas duas abordagens para seleção de exemplares: uma baseada em *seleção de instâncias limítrofes* e a outra baseada em *densidade local*. As abordagens propostas para extração de protótipos e seleção de exemplares são apresentadas na Seção 3.4.

Salienta-se que as abordagens para raciocínio híbrido, para extração de protótipos e para seleção de exemplares propostas nesta tese são completamente independentes. Deste modo, é possível adotar o processo de raciocínio, sem utilizar as abordagens para seleção de exemplares e extração de protótipos, por exemplo, desde que sejam fornecidos exemplares e protótipos adequados para a base de conhecimento estendida que suporta o processo de raciocínio híbrido. No entanto, as 3 abordagens podem também ser utilizadas em conjunto, conforme é ilustrado na Seção 4.2.

### 3.2 Arcabouço híbrido para representação de conhecimento

Uma das principais propostas desta tese é o desenvolvimento de um arcabouço híbrido para representação de conhecimento, que suporte a realização de raciocínio, combinando raciocínio lógico com raciocínio baseado em similaridade. Deste modo, para viabilizar a realização de raciocínio lógico, fundamentado em condições necessárias e suficientes, o arcabouço aqui proposto inclui um componente de representação de conhecimento baseado no paradigma clássico. Além deste componente clássico, o arcabouço

proposto também inclui representações baseadas em protótipos e baseadas em exemplares, bem como relações entre as representações clássicas e não clássicas. Com isto em mente, nesta tese definimos a noção de *base de conhecimento estendida* ( $\mathcal{KB}_\chi$ ), como um aperfeiçoamento das propostas discutidas em outros trabalhos do autor, tais como (CARBONERA; ABEL, 2015b; CARBONERA; ABEL, 2015c; CARBONERA; ABEL, 2015e).

**Definição 3.1.** Uma base de conhecimento estendida ( $\mathcal{KB}_\chi$ ) é uma tupla, tal que:

$$\mathcal{KB}_\chi = (\mathbb{C}, \leq, \mathbb{R}, \mathbb{P}, \hookrightarrow, \mathbb{D}, dom, \mathbb{A}, def, \mathbb{I}, val, p, ext, \mathcal{E}, ex, \mathcal{P}, prot) \quad (3.1)$$

, onde<sup>1</sup>:

- $\mathbb{C}$  é um conjunto  $\mathbb{C} = \{c_1, c_2, \dots, c_n\}$  de  $n$  símbolos que representam conceitos (ou classes), onde cada  $c_i$  é uma representação simbólica de um conceito específico.
- $\leq$  é uma *ordem parcial* sobre  $\mathbb{C}$ , isto é,  $\leq$  é uma relação binária  $\leq \subseteq \mathbb{C} \times \mathbb{C}$ , que é reflexiva, transitiva, e antisimétrica. Assim,  $\leq$  representa a relação de *subsunção* entre conceitos.
- $\mathbb{R}$  é um conjunto  $\mathbb{R} = \{r_1, r_2, \dots, r_m\}$  de  $m$  símbolos que representam relações, onde cada  $r_i$  é uma representação simbólica de uma dada relação.
- $\mathbb{P}$  é um conjunto  $\mathbb{P} = \{p_1, p_2, \dots, p_l\}$  de  $l$  símbolos que representam propriedades (ou atributos), onde cada  $p_i$  é uma representação simbólica de uma dada propriedade.
- $\hookrightarrow$  é uma relação binária que relaciona propriedades em  $\mathbb{P}$  a conceitos em  $\mathbb{C}$ , tal que  $\hookrightarrow \subseteq \mathbb{P} \times \mathbb{C}$ . Assim  $p_i \hookrightarrow c_j$  representa que  $p_i \in \mathbb{P}$  é uma propriedade do conceito  $c_j$ , no sentido de que  $p_i$  caracteriza  $c_j$ .
- $\mathbb{D}$  é o conjunto de todo valor possível de toda e qualquer propriedade  $p_i \in \mathbb{P}$ .
- $dom: \mathbb{P} \rightarrow 2^{\mathbb{D}}$  é uma função que mapeia uma dada propriedade  $a_i \in \mathbb{P}$  em um conjunto  $\mathbb{D}_{a_i} \subseteq \mathbb{D}$ , que é seu domínio de valores. Note que  $\mathbb{D} = \bigcup_{i=1}^l dom(p_i)$ .
- $\mathbb{A}$  é um conjunto de axiomas, expressos em alguma linguagem formal  $L$ .
- $def: \mathbb{C} \rightarrow 2^{\mathbb{A}}$  é uma função que mapeia um dado conceito  $c_i \in \mathbb{C}$  em um conjunto de axiomas  $\mathbb{A}'$ , tal que  $\mathbb{A}' \subseteq \mathbb{A}$ , que constituem uma *definição* para  $c_i$ . Isto é,  $\mathbb{A}'$  constitui um conjunto de condições necessárias e/ou suficientes para um dado indivíduo  $i \in \mathbb{I}$  ser membro de  $ext(c_i)$ .
- $\mathbb{I}$  é um conjunto  $\mathbb{I} = \{i_1, i_2, \dots, i_p\}$  de  $p$  símbolos que representam indivíduos, onde cada  $i_j$  representa um dado indivíduo.

<sup>1</sup>Note que  $2^S$  representa o *powerset* do conjunto  $S$ , isto é, o conjunto de todos os subconjuntos do conjunto  $S$  (incluindo o conjunto vazio e o próprio conjunto  $S$ ).

- $val: \mathbb{I} \times \mathbb{P} \rightarrow \mathbb{D}$  é uma função que mapeia um dado indivíduo  $i_j \in \mathbb{I}$  e uma dada propriedade  $a_i \in \mathbb{P}$  para o valor específico  $val \in \mathbb{D}$  que a propriedade  $a_i$  assume em  $i_j$ .
- $p: \mathbb{C} \rightarrow 2^{\mathbb{P}}$  é uma função que mapeia um dado conceito  $c_j \in \mathbb{C}$  em um conjunto  $\mathbb{P}_{c_j} \subseteq \mathbb{P}$ , que representa o conjunto das propriedades que caracterizam o conceito  $c_j$ , isto é  $p(c_j) = \{\forall x \in \mathbb{P} | x \leftrightarrow c_j\}$ .
- $ext: \mathbb{C} \rightarrow 2^{\mathbb{I}}$  é uma função que mapeia um dado conceito  $c_i \in \mathbb{C}$  em um conjunto  $\mathbb{I}_{c_i} \subseteq \mathbb{I}$ , que representa sua *extensão* (o conjunto de indivíduos classificado pelo conceito).
- $\mathcal{E}$  é um conjunto  $\mathcal{E} = \{e_1, e_2, \dots, e_n\}$  de  $n$  conjuntos de indivíduos, onde cada  $e_i \in \mathcal{E}$  representa o conjunto de *exemplares* de um dado conceito  $c_i \in \mathbb{C}$ . Note que  $\mathcal{E} \subseteq 2^{\mathbb{I}}$ .
- $ex: \mathbb{C} \rightarrow \mathcal{E}$  é uma função que mapeia um conceito  $c_i \in \mathbb{C}$  em seu conjunto de exemplares  $e_i \in \mathcal{E}$ .
- $\mathcal{P}$  é um conjunto  $\mathcal{P} = \{p_1, p_2, \dots, p_n\}$  de  $n$  protótipos, onde cada  $p_i \in \mathcal{P}$  representa o protótipo de um dado conceito  $c_i \in \mathbb{C}$ .
- $prot: \mathbb{C} \rightarrow \mathcal{P}$  é uma função que mapeia um dado conceito  $c_i \in \mathbb{C}$  em seu protótipo  $p_i \in \mathcal{P}$ .

Além disso, em uma  $\mathcal{KB}_\chi$ , todo protótipo deve necessariamente ser o protótipo de um conceito. Isto é:

$$\forall x (x \in \mathcal{P}) \rightarrow \exists c (c \in \mathbb{C} \wedge prot(c) = x) \quad (3.2)$$

Do mesmo modo, em uma  $\mathcal{KB}_\chi$ , todos os conjuntos de exemplares devem ser conjuntos de exemplares de algum conceito. Isto é:

$$\forall e (e \in \mathcal{E}) \rightarrow \exists c (c \in \mathbb{C} \wedge ex(c) = e) \quad (3.3)$$

Também assume-se que, em uma  $\mathcal{KB}_\chi$ , todo o exemplar de um conceito  $c$  deve necessariamente ser instância deste conceito  $c$ .

$$\forall c (c \in \mathbb{C}) \rightarrow (\forall e (e \in ex(c)) \rightarrow e \in ext(c)) \quad (3.4)$$

Uma versão mais forte da teoria apresentada nesta tese poderia se comprometer com outros dois axiomas. O primeiro deles estabelece que, em uma  $\mathcal{KB}_\chi$ , todo o conceito deve necessariamente possuir um protótipo. Isto é:

$$\forall c (c \in \mathbb{C}) \rightarrow \exists x (x \in \mathcal{P} \wedge prot(c) = x) \quad (3.5)$$

O segundo, estabelece que, em uma  $\mathcal{KB}_\chi$ , todo o conceito deve necessariamente possuir um conjunto de exemplares. Isto é:

$$\forall c (c \in \mathbb{C}) \rightarrow \exists e (e \in \mathcal{E} \wedge ex(c) = e) \quad (3.6)$$

No entanto, a proposta desta tese não se compromete com os axiomas 3.5 e 3.6, assumindo uma posição mais flexível em relação a estes aspectos. Esta posição é justificada do ponto de vista pragmático, pois um dos objetivos desta tese é desenvolver um arcabouço que permita o desenvolvimento de aplicações computacionais e, do ponto de vista de aplicação, em alguns domínios, é possível que não exista a necessidade de se considerar protótipos e exemplares para todos os conceitos. Além disso, esta liberdade facilita a integração e reuso de bases de conhecimento clássicas (que não incluem protótipos e exemplares), como partes de uma base de conhecimento estendida.

Os elementos  $\mathbb{C}$ ,  $\leq$ ,  $\mathbb{R}$ ,  $\mathbb{P}$  e  $\mathbb{A}$  geralmente são considerados como constituintes de definições formais de uma ontologia, conforme pode ser visto em trabalhos como (KALFOGLOU; SCHORLEMMER, 2002; XU; ZHANG; DONG, 2006; LOZANO et al., 2014). Neste sentido, conforme discutido em (CARBONERA; ABEL, 2015e), a noção de representação de conhecimento estendida proposta nesta tese, pode ser vista como uma extensão da abordagem representacional adotada tradicionalmente em ontologias.

Também é importante destacar que a abordagem proposta nesta tese não se compromete com a existência de qualquer relação direta explícita entre protótipos de conceitos relacionados por relações de subsunção. Assim, por exemplo, considerando que o conceito de *Cachorro* é subsumido pelo conceito de *Mamífero*, nesta tese, não é assumida a existência de nenhuma relação explícita direta entre os protótipo ou exemplares de ambos os conceitos. Deste modo, no contexto da concepção defendida por esta tese, não é possível afirmar, por exemplo, que o protótipo do conceito de *Cachorro* é idêntico ao protótipo do conceito de *Mamífero*. No entanto, uma vez que o protótipo de um conceito  $C$  pode ser compreendido como o centroide da extensão de  $C$ , que abstrai as informações das instâncias possíveis de  $C$ , é possível afirmar que há uma relação indireta entre os protótipos de conceitos relacionados por uma relação de subsunção, no sentido de que o protótipo do conceito mais geral necessariamente deve considerar as informações abstraídas pelo protótipo do conceito mais específico, uma vez que ele abstrai as informações de um conjunto de instâncias que inclui o conjunto de instâncias possíveis do conceito mais específico. Assim, indiretamente, o protótipo do conceito de *Mamífero* considera as informações abstraídas pelo protótipo do conceito de *Cachorro*. No caso dos exemplares, esta tese assume que não é possível afirmar que um exemplar de um conceito mais específico (como *Cachorro*) deve necessariamente ser considerado um exemplar do conceito mais geral (como *Mamífero*). Conforme discutido na Seção 3.4.2, esta tese apenas assume que o exemplar de um conceito deve ser uma instância real representativa do conceito, mas

não se compromete com uma teoria específica que estabelece quais das instâncias de um conceito devem ser considerados seus exemplares. Ou seja, a proposta aqui elaborada permite acomodar diferentes teorias sobre quais instâncias de um conceito deveriam ser considerados seus exemplares. Deste modo, a existência de uma relação direta entre os exemplares de conceitos relacionados através de uma relação de subsunção depende da teoria que estabelece quais exemplares representam cada conceito.

### 3.3 Estratégia de raciocínio híbrido para classificação

Nesta seção, é discutida a proposta de uma estratégia de raciocínio híbrido para classificação, que utiliza, de modo combinado, informações relativas aos protótipos, exemplares e definições de cada conceito. Em relação a estes objetivos, a abordagem proposta nesta seção combina aspectos das abordagens propostas em trabalhos como (FRANCONI; MAGNINI; STOCK, 1992; LIETO et al., 2015), e busca evitar deficiências de ambas.

De modo geral, a estratégia geral adotada nesta abordagem é semelhante à estratégia proposta por (FRANCONI; MAGNINI; STOCK, 1992). A principal diferença da abordagem proposta nesta tese, em relação ao trabalho em questão, reside na estratégia adotada para determinar classificações mais específicas, nas situações em que o raciocínio clássico não é suficiente. Em (FRANCONI; MAGNINI; STOCK, 1992), quando o raciocínio clássico não é suficiente para determinar classificações mais específicas, utiliza-se apenas uma medida de distância simples entre  $i$  e o protótipo de um conceito  $c$ , assumindo-se como classificação para  $i$  o conceito  $c$  cujo protótipo possui a menor distância em relação a  $i$  (uma abordagem semelhante à adotada pelo *Nearest prototype classifier*). Na abordagem discutida nesta tese, por outro lado, utiliza-se a noção de *medida de adequação conceitual* (formalizada no Algoritmo 1) para avaliar quando um indivíduo  $i$  deve ser incluído na extensão de um determinado conceito  $c$ , com base nas informações a respeito de protótipos e exemplares, considerados de modo integrado. Esta proposta assume a hipótese de que a consideração de informações relativas a exemplares melhora a acurácia em tarefas de classificação. Esta hipótese é suportada por diferentes linhas de evidência, como os trabalhos que comparam a performance do *Nearest prototype classifier* e do *K-nearest neighbors* (HUANG et al., 2010; DING et al., 2013; DOHNÁLEK et al., 2014) e trabalhos na área das Ciências Cognitivas, tais como (MEDIN; SCHAFFER, 1978; SMITH, 2014), que sugerem que seres humanos utilizam a informação combinada de protótipos e exemplares para suportar a classificação de objetos.

Por outro lado, a principal diferença da proposta desta tese em relação à abordagem apresentada em (LIETO et al., 2015) reside no fato de que a abordagem aqui apresentada foi projetada para lidar com a necessidade de se classificar indivíduos em *múltiplos conceitos* distintos. Além disso, neste trabalho, não assumimos nenhuma res-



trição específica em relação à possibilidade de se representar atributos categoriais (com valores qualitativos). A única restrição assumida é a de que a função<sup>2</sup> de similaridade ou dissimilaridade (ou distância) entre objetos deve ser capaz de lidar com os tipos de atributos incluídos na representação. A abordagem aqui apresentada também se diferencia da abordagem de Lieto, na medida em que neste trabalho, informações de protótipos e exemplares são considerados de modo integrado para determinar o grau com que um determinado conceito é adequado para classificar um determinado objeto. A abordagem proposta nesta tese também se diferencia da abordagem proposta por Lieto por buscar mitigar os efeitos do ruído na classificação. Isto é realizado através da inclusão de informações de vizinhança (conforme apresentado na Seção 3.3.1). Ou seja, em vez de considerar apenas o exemplar mais próximo do indivíduo que se deseja classificar, na abordagem aqui apresentada considera-se um número variável (parametrizável) de exemplares.

A abordagem híbrida de raciocínio apresentada nesta tese, conforme já mencionado, combina raciocínio lógico com raciocínio baseado em similaridade. Assim como ocorre em (FRANCONI; MAGNINI; STOCK, 1992; LIETO et al., 2015), neste trabalho assume-se que as informações representadas no componente clássico (através de axiomas) possuem prioridade mais elevada em relação às informações capturadas por protótipos e exemplares. Do ponto de vista computacional, esta posição é justificada na medida em que o conhecimento capturado pelo componente clássico geralmente é resultante de um processo sistemático de engenharia, que visa eliciar, modelar e representar o conhecimento de especialistas na área de interesse. Por isso, este componente, em geral, torna explícitas diversas restrições *gerais* do domínio, sob o ponto de vista de um especialista. As informações capturadas por protótipos e exemplares, por outro lado, capturam manifestações *individuais* ou *típicas* de características de interesse do domínio, sem atentar para as restrições gerais do domínio. Por este motivo, nesta abordagem, assumimos que uma inferência estabelecida com base nas informações relativas a protótipos e exemplares não pode contradizer o que é estabelecido pelo componente clássico.

Devido a esta precedência do componente clássico, o processo de raciocínio proposto aqui é guiado pelo componente clássico do conhecimento representado. O conhecimento representado neste componente clássico é manipulado por processos de raciocínio lógico. As informações relativas a protótipos e exemplares, por sua vez, são utilizadas apenas quando o raciocínio lógico não é capaz de oferecer classificações detalhadas (ou mais informativas). Neste caso, realiza-se um processo de raciocínio baseado em similaridade, onde o indivíduo que se deseja classificar é comparado com os protótipos e exemplares de conceitos mais específicos, visando a inferência de classificações mais específicas (ou detalhadas) do que as alcançadas pelo raciocínio lógico. Deste modo, abre-se

---

<sup>2</sup>O Apêndice A apresenta um exemplo de função de distância capaz de acomodar atributos quantitativos e qualitativos. Uma revisão extensa sobre funções de distância pode ser encontrada em (DEZA; DEZA, 2009).

mão da segurança conferida pelo conhecimento representado no componente clássico e pelo raciocínio lógico, e assume-se o risco de se realizar inferências baseadas em similaridade, visando o estabelecimento de uma classificação mais informativa. No entanto, nesta abordagem, as classificações sugeridas pelo raciocínio baseado em similaridade não são automaticamente consideradas como conclusões válidas. Antes disso, verifica-se se há alguma contradição entre as classificações obtidas e os axiomas representados pelo componente clássico. Caso não exista nenhuma contradição, o processo de raciocínio híbrido assume como válidas as conclusões obtidas.

Conforme já mencionado, o processo de raciocínio híbrido utiliza julgamento de similaridade entre o indivíduo que se quer classificar e protótipos e exemplares de conceitos candidatos, durante o processo de refinamento da classificação obtida através do raciocínio lógico. Neste trabalho, em vez de adotarmos um cálculo de similaridade simples, como o adotado em trabalhos como (FRANCONI; MAGNINI; STOCK, 1992; LIETO et al., 2015), adotou-se a noção de *medida de ajustamento conceitual* (MAC), que *mede o grau com que um dado conceito  $c$  é adequado para classificar um dado indivíduo  $i$* . Esta medida integra informações relativas à similaridade entre  $i$  e o protótipo de  $c$ , bem como informações relativas às similaridades entre  $i$  e os exemplares de  $c$ .

Como a noção de MAC é adotada em nossa abordagem híbrida para raciocínio, na Seção 3.3.1 apresentaremos em detalhes como a MAC é determinada. A seguir, na Seção 3.3.2, será apresentada em detalhes a estratégia híbrida para raciocínio para classificação.

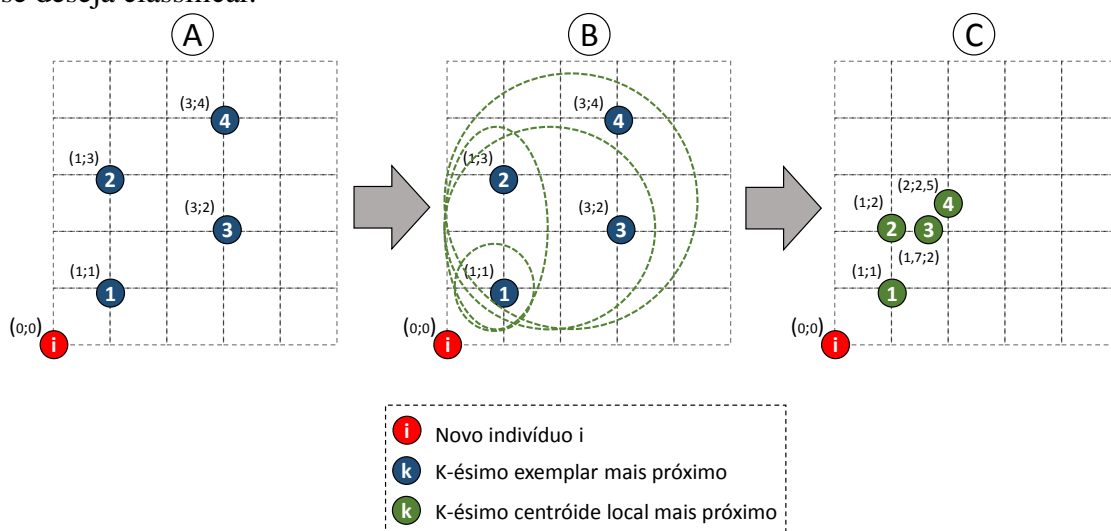
### 3.3.1 Medida de ajustamento conceitual

A *medida de ajustamento conceitual* (MAC) é adotada nesta tese para *medir o grau com que um dado conceito  $c$  é adequado para classificar um dado indivíduo  $i$* . Esta medida integra informações relativas à similaridade entre  $i$  e o *protótipo* de  $c$ , bem como informações relativas às similaridades entre  $i$  e os *exemplares* de  $c$ .

Para determinar a MAC, utilizamos a noção de *centroide local*, proposta por (MITANI; HAMAMOTO, 2006). Um *centroide local*, neste contexto, consiste em uma *abstração* de um conjunto de exemplares. Dizemos que ele é *local*, porque, assumindo que queremos classificar um novo indivíduo  $i$ , a abstração é extraída a partir do conjunto de exemplares (de um dado conceito candidato) mais próximos de  $i$  e não de *todos* os exemplares do conceito. Caso a abstração fosse extraída a partir de todos os exemplares de um conceito, o resultado seria o *protótipo* do conceito. Em (MITANI; HAMAMOTO, 2006), para determinar o peso de cada conceito em um processo de classificação, em vez de se utilizar os exemplares, são utilizados os centroides locais. Com isto, elimina-se a influência de instâncias que constituem ruído e que podem prejudicar a classificação.

Na abordagem aqui proposta, a partir dos  $n$  exemplares mais próximos de um novo indivíduo  $i$  que se deseja classificar, são gerados  $n$  agrupamentos destes exemplares, de modo que cada agrupamento inclua os  $j$  exemplares mais próximos de  $i$ , onde  $1 \leq j \leq n$ . A partir de cada um destes agrupamentos, é extraído um centroide local, de modo que o  $j$ -ésimo centroide local abstrai informações dos  $j$  exemplares mais próximos de  $i$ . A Figura 3.3 ilustra o processo de extração de centroides locais a partir do conjunto de  $n$  exemplares (de um dado conceito candidato) mais próximos de um dado indivíduo  $i$ . Em  $A$  ilustra-se o conjunto inicial dos  $n$  exemplares mais próximos do novo indivíduo  $i$ . Em  $B$ , são apresentados diferentes agrupamentos destes exemplares, onde cada agrupamento inclui os  $j$  exemplares mais próximos de  $i$ . Em  $C$ , são apresentados os  $n$  centroides locais extraídos, cada qual de um dos agrupamentos apresentados em  $B$ .

Figura 3.3: Exemplo que ilustra a extração de 4 centroides locais a partir do conjunto de 4 exemplares (de um dado conceito candidato) mais próximos de um dado indivíduo  $i$  que se deseja classificar.



Fonte: Produzida pelo autor.

Com a noção de centroide local em mente, podemos formalizar a determinação da MAC através do algoritmo 1. O algoritmo recebe como entradas um dado conceito  $c \in \mathbb{C}$ , um dado indivíduo  $i \in \mathbb{I}$  que deve ser classificado e um valor  $n \in \mathbb{N}_I$ , que determina o tamanho da vizinhança de  $i$  que é avaliada (quantos exemplares em  $c$ , mais próximos de  $i$ , serão considerados); e retorna um valor  $mac \in \mathbb{R}$  que indica o quanto o conceito  $c$  é adequado para classificar o indivíduo  $i$ .

Inicialmente, o algoritmo inicializa  $mac$  e  $soma$  e  $totalDistProt$  com zero, enquanto o conjunto  $selecionados$  é inicializado como um conjunto vazio. No próximo passo, determina-se o conjunto  $vizinhos$ , dos  $n$  exemplares de  $c$  mais próximos de  $i$ , ordenados de modo ascendente, em função das distância em relação a  $i$ , de modo que cada  $vizinhos_i \in vizinhos$  representa o  $i$ -ésimo exemplar mais próximo de  $i$ . A seguir, no primeiro laço, com  $j$  variando de 1 a  $n$ , em cada passo, inclui-se o  $j$ -ésimo exemplar mais

próximo de  $i$  em *selecionados*; determina-se o  $j$ -ésimo centroide local ( $cl_j$ ) utilizando-se o Algoritmo 4 aplicado sobre o conjunto *selecionados* (que inclui os  $j$  exemplares mais próximos de  $i$ ); calcula-se a distância  $distProt_j$  entre  $cl_j$  e o protótipo de  $c$  ( $prot(c)$ ); e acumula-se  $distProt_j$  em  $totalDistProt$ . Note que neste laço são criados os  $n$  centroides locais mais próximos, seguindo a estratégia representada na Figura 3.3. Este passo utiliza a função *extraiCentroide*, definida no Algoritmo 4 para extrair centroides de conjuntos de indivíduos. No segundo laço, o principal objetivo é determinar a contribuição parcial ( $cp$ ) de cada centroide local para o  $MAC$ , onde  $cp$  é basicamente a distância entre  $i$  e um dado centroide local  $cl_j$ , multiplicada por um peso  $p$ . O peso  $p$  é determinado como a média de dois pesos  $p_1$  e  $p_2$ . O peso  $p_1$ , proposto em (ZENG; YANG; ZHAO, 2009) é basicamente um fator que visa penalizar menos as distâncias dos centroides locais mais distantes no  $MAC$ , para que os centroides locais mais distantes influenciem menos a tomada de decisão do que os mais próximos. Deste modo, define-se  $p_1 = 1/j$ , onde  $j$  é a posição de um dado centroide local  $cl_j$  no conjunto *vizinhos*, em termos de distância de  $i$ . Ou seja,  $cl_1$  representa o primeiro centroide local mais próximo,  $cl_2$  o segundo e  $cl_j$  o  $j$ -ésimo. Já o peso  $p_2$ , proposto nesta tese, visa penalizar menos as distâncias dos centroides mais próximos do protótipo do conceito, pois é assumido que tais centroides tendem a representar informação mais típica do conceito. Assim, define-se  $p_2 = distProt_j/totalDistProt$ , quando  $totalDistProt > 0$  e  $p_2 = 1$ , quando  $totalDistProt = 0$ . Nota-se também que, no segundo laço, *soma* acumula a soma das contribuições parciais de cada centroide local. Considerando-se que cada contribuição parcial é uma medida de distância (ponderada por um peso) entre um centroide local e  $i$ , constata-se que *soma* representa um valor de *inadequação* do conceito  $c$  para classificar  $i$ , pois quanto maior o valor de *soma*, maiores são as medidas de dissimilaridade (representada pela distância) entre os centroides locais e  $i$ . A  $MAC$ , por outro lado, é uma medida de *adequação* e, por conta disso, ela é definida como o inverso de  $soma + 1$ , quando  $soma > 0$ ; ou seja,  $mac = 1/(soma + 1)$ . Por outro lado, quando  $soma = 0$ , assumimos  $mac = 1$  (o valor máximo possível). Note que, quando  $soma > 0$  a constante 1 é adicionada à *soma*, para garantir que  $mac \in [0, 1]$ . Sem a adição da constante, em casos em que  $0 < soma < 1$ , o inverso de *soma* resultaria em um número superior a 1.

De uma perspectiva geral, pode-se compreender o  $MAC$  de um conceito  $c \in \mathbb{C}$ , considerando-se um indivíduo  $i \in \mathbb{I}$  e um valor de vizinhança  $n \in \mathbb{N}_I$  como o inverso da soma ponderada das distâncias entre  $i$  e os  $n$  centroides locais mais próximos de  $i$ .

Uma vez que a determinação da  $MAC$  de um conceito envolve identificar os exemplares (do conceito) mais próximos da instância avaliada, naturalmente pode-se levantar questões relacionadas à eficiência do procedimento que calcula a  $MAC$ . Neste sentido, a identificação das instâncias mais próximas poderia ser suportada por estruturas de índices, tais como a proposta em (JAGADISH et al., 2005), que permitem realizar esta tarefa de forma bastante eficiente.

---

**Algoritmo 1: MAC (Medida de ajustamento conceitual)**


---

**Input:** Um dado conceito  $c \in \mathbb{C}$ , um dado indivíduo  $i \in \mathbb{I}$  que deve ser classificado e um valor  $n \in \mathbb{N}_1$ , que determina o tamanho da vizinhança de  $i$  que é avaliada.

**Output:** Um valor  $mac \in \mathbb{R}$  que indica o quanto o conceito  $c$  é adequado para classificar o indivíduo  $i$ .

**begin**

$mac \leftarrow 0;$

$soma \leftarrow 0;$

$totalDistProt \leftarrow 0;$

$selecionados \leftarrow \emptyset;$

$vizinhos \leftarrow$  sequência dos  $n$  exemplares em  $ex(c)$  mais próximos de  $i$ , ordenados de modo ascendente, em função da distância com  $i$ , onde cada  $vizinhos_i \in vizinhos$  representa o  $i$ -ésimo exemplar mais próximo de  $i$ ;

**for**  $j \leftarrow 1$  **to**  $n$  **do**

$selecionados \leftarrow selecionados \cup \{vizinhos_j\};$

$cl_j \leftarrow extraiCentroide(selecionados, p(c));$

$distProt_j \leftarrow d(cl_j, prot(c));$

$totalDistProt \leftarrow totalDistProt + distProt_j;$

**for**  $j \leftarrow 1$  **to**  $n$  **do**

$p_1 \leftarrow \frac{1}{j};$

$p_2 \leftarrow \begin{cases} 1, & totalDistProt = 0 \\ \frac{distProt_j}{totalDistProt}, & totalDistProt > 0 \end{cases};$

$p \leftarrow \frac{(p_1 + p_2)}{2};$

$dist \leftarrow d(i, cl_j)$ , onde  $cl_j$  é o  $j$ -ésimo centroide local;

$cp = dist \times p;$

$soma \leftarrow soma + cp;$

$mac \leftarrow \begin{cases} 1, & soma = 0 \\ \frac{1}{soma+1}, & soma > 0 \end{cases};$

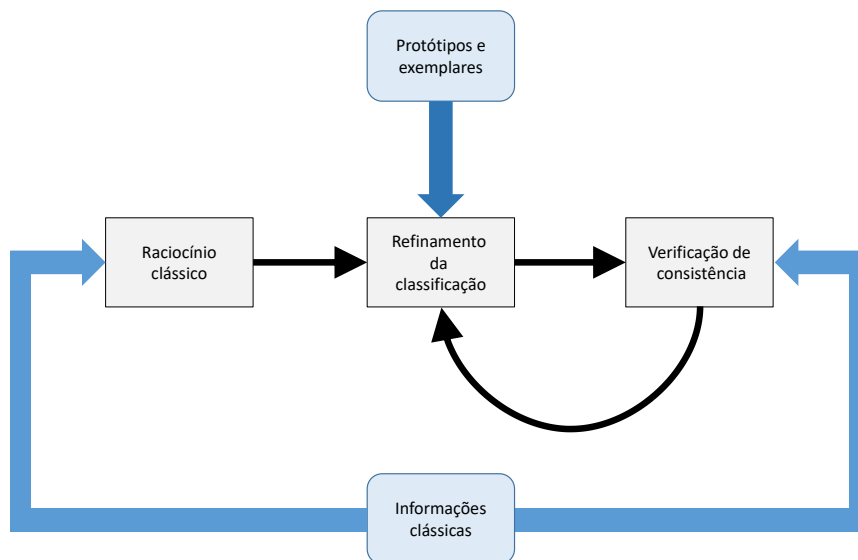
**return**  $mac;$

---

### 3.3.2 Combinando informações clássicas, protótipos e exemplares

O método de raciocínio híbrido proposto nesta tese é formalizado pelo Algoritmo 2. Ele aperfeiçoa a abordagem discutida pelo autor em trabalhos como (CARBONERA; ABEL, 2015e; CARBONERA; ABEL, 2015c; CARBONERA; ABEL, 2015b). Segundo a abordagem aqui proposta, o processo de raciocínio é suportado por uma combinação de informações clássicas, protótipos e exemplares. Em uma visão geral, durante o processo, inicialmente é realizada uma etapa de raciocínio clássico, que determina uma classificação logicamente suportada para o indivíduo que se deseja classificar. Esta etapa utiliza informações relativas às definições clássicas dos conceitos. A seguir, caso a classificação resultante do raciocínio clássico não seja a mais específica possível, é realizado um processo cíclico de refinamento da classificação e checagem de consistência da classificação refinada. O refinamento da classificação é realizado em função da similaridade entre o indivíduo que se deseja classificar e os exemplares e protótipos de conceitos candidatos. O processo finaliza quando não é mais possível realizar refinamentos. Esta visão geral do processo está representada na Figura 3.4.

Figura 3.4: Visão geral do processo de raciocínio. Os retângulos cinzas representam as grandes etapas realizadas durante o processo de raciocínio. As figuras geométricas azuis com cantos arredondados representam tipos de informações utilizadas em cada etapa do processo. As setas pretas indicam a sequência das etapas realizadas durante o processo de raciocínio. As setas azuis indicam quais informações são utilizadas em cada etapa do processo.



Fonte: Produzida pelo autor.

O Algoritmo 2 recebe como entrada um indivíduo  $i$  que se deseja classificar; uma base de conhecimento estendida  $\mathcal{KB}_\chi$ ; um conjunto de conceitos que definem uma classificação padrão inicial para o indivíduo  $i$ ; um valor  $n \in \mathbb{N}_1$ , que determina o tamanho da vizinhança considerado na avaliação da  $MAC$  de cada conceito; e um valor  $limiar \in \mathbb{R}$ ,

que define o valor limiar da *MAC*, utilizado para definir se um determinado conceito classifica um indivíduo de modo adequado. O algoritmo busca encontrar uma classificação adequada dos indivíduos em  $\mathbb{I}$ . É importante salientar que a classificação resultante é sempre um conjunto de um ou mais conceitos, uma vez que o indivíduo  $i$  pode ser classificado em mais de um conceito da base de conhecimento.

O Algoritmo 2 inicialmente inclui o indivíduo  $i$  que se quer classificar na base de conhecimento estendida  $\mathcal{KB}_\chi$ , nas respectivas extensões dos conceitos em  $CP$ , que definem uma classificação inicial padrão para  $i$ . A seguir, é realizado um processo de raciocínio clássico sobre a base de conhecimento  $\mathcal{KB}_\chi$  para determinar uma *classificação* logicamente suportada de  $i$ , considerando-se os axiomas em  $\mathbb{A}$ . Esta classificação é basicamente um *conjunto de conceitos*, cujas condições necessárias e suficientes foram satisfeitas por  $i$ . Se este conjunto for vazio, isto significa que foi detectada alguma inconsistência lógica na base de conhecimento. Caso contrário, o algoritmo tenta refinar a classificação determinada via raciocínio lógico, chamando a função *refinaClassificacao*, formalizada no Algoritmo 3.

---

#### Algoritmo 2: Classificador Híbrido

---

**Input:** Um indivíduo  $i$  que se deseja classificar, uma base de conhecimento estendida  $\mathcal{KB}_\chi$ , um conjunto de conceitos  $CP \subseteq \mathbb{C}$  que representam uma classificação padrão para  $i$ , um valor  $n \in \mathbb{N}_1$  e um valor *limiar*  $\in [0, 1]$ .

**Output:** Um conjunto *classificacao*  $\subseteq \mathbb{C}$  de conceitos que classificam  $i$

**begin**

- Inclui-se  $i$  em  $\mathcal{KB}_\chi$ , como instância de cada conceito em  $CP$ ;
- classificacao*  $\leftarrow$  conceitos que classificam  $i$ , como resultado da aplicação de raciocínio clássico;
- if** *classificacao*  $\neq \emptyset$  **then**
  - classificacao*  $\leftarrow$  *refinaClassificacao*( $i$ , *classificacao*, *limiar*,  $n$ );
- return** *classificacao*;

---

O Algoritmo 3, por sua vez, consiste em um algoritmo recursivo que busca refinar sistematicamente uma dada classificação (dada por um conjunto de conceitos) para um dado indivíduo  $i$ . O algoritmo tem como entrada um indivíduo  $i$  que se deseja classificar, uma representação estendida  $\mathcal{KB}_\chi$ , um conjunto de conceitos  $ci \subseteq \mathbb{C}$  que representa uma *classificação inicial* para  $i$ , um valor  $n \in \mathbb{N}_1$  e um valor *limiar*  $\in \mathbb{R}$ ; e tem como saída um conjunto de conceitos  $cf \subseteq \mathbb{C}$  que representa uma *classificação final* (refinada) de  $i$ .

Inicialmente, o Algoritmo 3 inicializa  $cf$  como um conjunto vazio. A seguir, verifica se todos os conceitos em  $ci$  são folhas na hierarquia de conceitos. Se esta condição for verdadeira, atribui  $ci$  a  $cf$ , uma vez que não é possível realizar refinamentos adicionais. Caso contrário, o algoritmo tenta refinar a classificação em  $ci$ . Neste caso, inicialmente, determina-se um conjunto de conceitos *candidatos* que sejam mais específicos que os conceitos em  $ci$  e que podem classificar  $i$ . Para isso, inicialmente inicializa-se *candidatos* como um conjunto vazio. A seguir, para cada conceito  $c$  em  $ci$  recupera-se um conjunto de conceitos *filhos* de  $c$ , que são conceitos imediatamente subsumidos por  $c$ . A seguir, para

cada conceito  $f$  em filhos, verifica-se se a sua  $MAC$  é superior ao *limiar* considerado. Caso esta condição seja verdadeira,  $f$  é incluído no conjunto de *candidatos*. Caso o conjunto *candidatos* permaneça vazio, isto significa que não foi possível determinar nenhum candidato adequado. Neste caso, atribui-se  $ci$  à  $cf$ , indicando que não foi possível refinar a classificação inicial, de modo que a classificação final permanece idêntica à inicial. Por outro lado, se o conjunto *candidatos* não estiver vazio, o algoritmo tenta determinar qual subconjunto de conceitos no conjunto de *candidatos* é o mais adequado para classificar o indivíduo  $i$ . Para isso, inicialmente  $classCand_{set}$  é inicializado como um conjunto vazio. É importante notar que  $classCand_{set}$  é um *conjunto de conjuntos*, onde cada um dos seus elementos é um subconjunto particular do conjunto de *candidatos*, constituído por *conceitos não disjuntos entre si*. Para determinar o conjunto  $classCand_{set}$ , analisa-se cada conceito  $c$  em *candidatos*. Para cada conceito  $c$  é criado um novo conjunto *cand* (candidatos) que inclui  $c$  e cada conceito  $x$  em *candidatos* que não é disjunto de  $c$ . A seguir, determina-se o conjunto  $cc$  (classificações candidatas) como o *conjunto potência* (conjunto de todos os subconjuntos) de *cand*. A seguir, para cada classificação candidata em  $cc$ , verifica-se se ela já pertence ao conjunto  $classCand_{set}$ . Caso ela não pertença, a classificação candidata é incluída em  $classCand_{set}$ . A seguir, o conjunto  $classCand_{set}$  é ordenado, em ordem decrescente, de acordo com a  $MAC$  total de cada um de seus elementos. Sendo cada  $cc$  um conjunto de conceitos, onde cada conceito possui uma  $MAC$  associada, a  $MAC$  total de cada  $cc$  é dada pela soma da  $MAC$  de cada  $x \in cc$ . Assim, considera-se que a  $MAC$  total de um conjunto de conceitos é capaz de medir o grau *global* com que tais conceitos são adequados para classificar conjuntamente o indivíduo  $i$ . A seguir, percorre-se o conjunto  $classCand_{set}$  (observando-se a ordenação do passo anterior), analisando cada um dos seus elementos. Para cada conjunto  $cc$  em  $classCand_{set}$ , atribui-se o indivíduo  $i$  à extensão de cada conceito em  $cc$  e verifica-se a consistência lógica da base de conhecimento estendida. Caso seja detectada alguma inconsistência lógica, a base de conhecimento é revertida ao seu estado anterior e executa-se a próxima iteração do laço. Por outro lado, se a base de conhecimento permanecer consistente, assume-se a classificação como válida. A seguir, verifica-se se todos os conceitos em  $cc$  são folhas na hierarquia de conceitos. Se este for o caso, isto significa que não é possível refinar ainda mais a classificação e, neste caso, atribui-se  $cc$  à  $cf$  e o processo de análise de classificações candidatas em  $classCand_{set}$  é interrompido. Caso exista algum conceito que não é folha em  $cc$ , o algoritmo tenta realizar refinamentos adicionais desta classificação, realizando uma chamada recursiva a si mesmo, adotando-se  $cc$  como a classificação inicial. O resultado deste processo é atribuído ao conjunto  $cf$  e o processo de análise das classificações candidatas em  $classRefinada$  é interrompido. Ao fim do laço, caso nenhuma classificação de interesse tenha sido encontrada ainda, atribui-se  $ci$  à  $cf$ . Neste caso, não é possível refinar a classificação inicial. Finalmente, o conjunto  $cf$ , contendo a classificação final (refinada), é retornado.



É importante notar que o conjunto  $cc$  é definido como o conjunto potência do conjunto  $cand$  para garantir que, caso algum dos conceitos em  $cand$  seja inconsistente com  $i$ , os demais conceitos em  $cand$  não sejam descartados. É possível que apenas subconjuntos de  $cand$  sejam classificações consistentes com  $i$ .

A Figura 3.5 apresenta um exemplo esquemático abstrato (focando nos aspectos gerais, sem considerar os detalhes) do processo realizado durante o raciocínio híbrido para classificar um determinado indivíduo. Neste exemplo, assume-se que os indivíduos pertencem ao domínio da Biologia. O primeiro passo do processo consiste na realização do raciocínio lógico que é realizado com base na taxonomia adotada (e assumida como um componente clássico da representação). Neste exemplo, constata-se que o indivíduo foi classicamente classificado como *Cachorro*. Nota-se que, de acordo com a hierarquia de conceitos assumida, *Cachorro* não é a classificação mais específica possível. Esta classificação genérica poderia resultar do fato de que as subclasses de *Cachorro* não possuem definições completas, em termos de condições necessárias e suficientes, ou devido a deficiências relacionadas à correta descrição do indivíduo que se quer classificar. Devido a isto, no passo seguinte são identificadas classificações candidatas mais específicas (conceitos imediatamente subsumidos por *Cachorro*, neste caso): *Beagle*, *Bulldog americano*, etc. A seguir, é realizada a análise da *medida de adequação conceitual* (MAC) para cada classificação e verifica-se qual dos candidatos resulta na maior MAC. Note que, uma vez que todas as hipóteses são conceitos disjuntos, apenas um dos conceitos será selecionado em cada classificação candidata. Neste cenário, o conceito mais adequado para classificar o indivíduo poderia ser *Beagle*, por exemplo. No entanto, não é possível assumir este conceito como sendo uma classificação válida, até que seja realizada uma verificação de consistência. Se for logicamente consistente assumir *Beagle* como sendo a classe do indivíduo testado, então este conceito é efetivamente considerado como a classificação final do indivíduo.

É importante notar que o Algoritmo 2 sempre resulta em classificações *consistentes* para o indivíduo  $i$ , ou uma classificação vazia (que não contém nenhum conceito). Isso pode ser constatado, verificando-se inicialmente que o Algoritmo 2 faz uma chamada do Algoritmo 3 apenas quando o conjunto *classificacao* não for vazio, indicando que existe um conjunto de conceitos que classificam o indivíduo  $i$  de modo consistente. O Algoritmo 3, por sua vez opera sobre uma classificação logicamente consistente até o laço de repetição em que são testadas as classificações alternativas elaboradas pelo algoritmo. Este laço repete até que seja encontrada uma classificação consistente (ou até que todas as classificações tenham sido testadas). Neste laço existe a possibilidade de uma inconsistência ocorrer. No entanto, antes de entrar no laço de repetição referido, a base de conhecimento está consistente. Ao entrar no laço, verifica-se se a classificação testada

---

**Algoritmo 3: Refina classificação**


---

**Input:** Um indivíduo  $i$  que se deseja classificar, uma representação estendida  $\mathcal{KB}_\chi$ , um conjunto de conceitos  $ci \subseteq \mathbb{C}$  que representa uma classificação inicial para  $i$ , um valor  $n \in \mathbb{N}_1$  e um valor  $limiar \in [0, 1]$ .

**Output:** Um conjunto de conceitos  $cf \subseteq \mathbb{C}$  que representa uma classificação refinada de  $i$

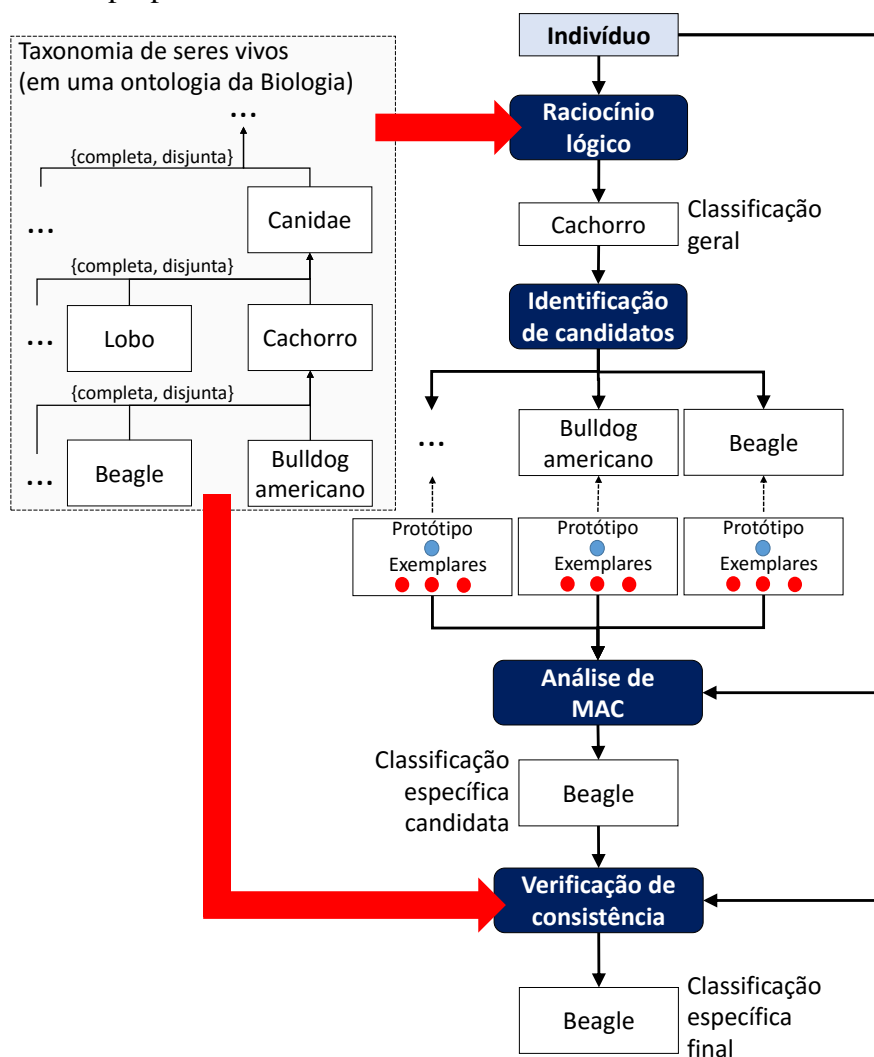
```

begin
   $cf \leftarrow \emptyset$ ;
  if Todos os conceitos em  $ci$  são folhas then
    |  $cf \leftarrow ci$ ;
  else
     $candidatos \leftarrow \emptyset$ ;
    foreach  $c \in ci$  do
      |  $filhos \leftarrow$  filhos (subclasses) diretos de  $c$ ;
      | foreach  $f \in filhos$  do
        | |  $MAC \leftarrow MAC(i, f, n)$ ;
        | | if  $MAC \geq limiar$  then
        | | |  $candidatos \leftarrow candidatos \cup \{f\}$ ;
    if  $candidatos \neq \emptyset$  then
      |  $classCand_{set} \leftarrow \emptyset$ ;
      | foreach  $c \in candidatos$  do
        | |  $cand \leftarrow \{c\} \cup \{\forall x \in candidatos | x \text{ e } c \text{ não são disjuntos}\}$ ;
        | |  $cc \leftarrow$  o conjunto potência de  $cand$ ;
        | | foreach  $classCand \in cc$  do
        | | | if  $classCand$  não pertence a  $classCand_{set}$  then
        | | | |  $classCand_{set} \leftarrow classCand_{set} \cup \{cc\}$ ;
      | Ordena-se o conjunto  $classCand_{set}$ , em ordem decrescente, pela  $MAC$  total
      | de cada  $cc \in classCand_{set}$ . Sendo cada  $cc$  um conjunto de conceitos, cada
      | qual com uma  $MAC$  associada, a  $MAC$  total de cada  $cc$  é dada pela soma da
      |  $MAC$  de cada  $x \in cc$ ;
      |  $intEncontrada \leftarrow falso$ ;
      |  $j \leftarrow 0$ ;
      | while  $intEncontrada = falso$  e  $j < |classCand_{set}|$  do
        | |  $cc \leftarrow$   $j$ -ésimo elemento de  $classCand_{set}$ ;
        | | Atribui-se o indivíduo  $i$  à extensão de cada conceito em  $cc$ ;
        | | if  $\mathcal{KB}_\chi$  é logicamente consistente then
        | | |  $intEncontrada = verdadeiro$ ;
        | | | if Todos os conceitos em  $cc$  são folhas then
        | | | |  $cf \leftarrow cc$ ;
        | | | else
        | | | |  $cf \leftarrow refinaClassificacao(i, \mathcal{KB}_\chi, cc, n, limiar)$ ;
        | | else
        | | | Reverte-se  $\mathcal{KB}_\chi$  ao estado anterior à atribuição de  $i$  à extensão de
        | | | cada conceito em  $cc$ ;
        | |  $j \leftarrow j + 1$ ;
      | if  $intEncontrada = falso$  then
      | |  $cf \leftarrow ci$ ;
    else
      |  $cf \leftarrow ci$ ;
  return  $cf$ ;

```

---

Figura 3.5: Exemplo que ilustra a classificação de um dado indivíduo, de acordo com a estratégia híbrida proposta nesta tese.



Fonte: Produzida pelo autor.

é consistente, caso não seja, a base de conhecimento é revertida ao estado anterior, eliminando a possibilidade de inconsistências serem propagadas. Deste modo, ao sair do laço, o algoritmo mantém a consistência da base. Assim, garante-se que a abordagem nunca gere uma classificação inconsistente.

Em relação à performance do Algoritmo 2, é importante salientar que a cada etapa de refinamento, o algoritmo apenas considera novos candidatos que especializam a classificação atual e que possuem *MAC* superior ao *limiar*. Deste modo, em geral, o algoritmo é capaz de podar ramos inteiros de possibilidades. Assim, o algoritmo percorre a hierarquia de classes, considerando apenas os ramos mais promissores e ignorando os demais. Com isso, evita-se a ocorrência de uma *explosão combinatória*.

Os parâmetros  $n$  e *limiar* desempenham papéis importantes no Algoritmo 3. O parâmetro  $n$  estabelece quantos dos exemplares mais próximos do indivíduo  $i$  (que se quer classificar) serão considerados para realizar a determinação da MAC de um determinado conceito  $c \in \mathbb{C}$  em relação a  $i$ . Quanto maior o valor  $n$ , maior será a quantidade de exemplares e, conseqüentemente, maior será a quantidade de informação da vizinhança de  $i$  que será considerada para determinar a MAC. Deste modo, espera-se que um mesmo valor para  $n$  possa ter resultados diferentes, dependendo da distribuição dos exemplares dos conceitos. O parâmetro *limiar*, por outro lado, determina o valor mínimo de MAC que um determinado conceito  $c \in \mathbb{C}$  deve possuir, em relação ao indivíduo  $i$ , para ser considerado uma classificação candidata de  $i$ . Ou seja, quanto maior o valor de *limiar*, maior é o valor mínimo de MAC necessário para um conceito ser considerado uma classificação candidata de  $i$ . Deste modo, quanto menor o valor de *limiar*, menor é o valor mínimo de MAC necessário para um conceito ser considerado uma classificação candidata e, devido a isso, mais arriscadas são as classificações resultantes.

A principal vantagem da estratégia proposta nesta seção é permitir a classificação de indivíduos em contextos nos quais não é possível especificar todo o conjunto de condições necessárias e suficientes para todos os conceitos, mas é possível extrair informações das instâncias de tais conceitos. Nestes casos, para um dado indivíduo  $i$  que se quer classificar, através de um processo de raciocínio lógico, seria possível determinar uma primeira classificação que pode ser pouco específica, mas que atende aos axiomas definidos no componente clássico de representação dos conceitos e, a partir desta classificação, seria possível determinar classificações mais refinadas, com base no MAC de cada conceito.

Uma outra vantagem consiste na possibilidade de utilizar a abordagem em casos nos quais nem todos os conceitos possuem definições. Uma vez que a definição dos conceitos depende de processos de aquisição de conhecimento, que são notoriamente caros, demorados e propensos a erros, é possível que uma parte dos conceitos possa não ser devidamente definida por diversos motivos. Isto é, devido a problemas ou restrições na condução do processo de aquisição de conhecimento, algumas das condições necessárias e/ou suficientes para alguns dos conceitos podem ser negligenciadas. Além disso, a abordagem também pode ser utilizada em cenários nos quais é preciso ampliar a quantidade de conceitos com os quais um dado sistema lida, mas não é possível realizar prontamente a aquisição de conhecimento para determinar as definições dos novos conceitos. Nestes casos, se existirem instâncias destes conceitos, a abordagem aqui proposta pode sugerir classificações mesmo com insuficiência ou total ausência de informações relativas a definições de conceitos. Sob esta perspectiva, pode-se ver a abordagem aqui proposta como uma integração de abordagens *top-down*, dirigidas por conhecimento explícito, e

abordagens *botton-up*, dirigidas por dados. Com isso, por exemplo, é possível combinar a confiança do conhecimento especialista explicitamente representado, com a flexibilidade permitida pelo raciocínio baseado em similaridade, que pode ser usado quando o conhecimento explícito não é suficiente.

É importante ter em mente que a noção de base de conhecimento estendida é relativamente independente da abordagem de raciocínio desenvolvida nesta seção. Ou seja, esta abordagem de raciocínio constitui apenas uma das possibilidades de raciocínio sobre bases de conhecimento estendidas. Outras abordagens podem ser investigadas em trabalhos futuros.

### **3.4 Abordagens para extração de protótipos e seleção de exemplares**

Conforme dito na Seção 3.2, a abordagem de *representação de conhecimento estendida*, proposta nesta tese, combina descrições de conceitos, protótipos e exemplares. As descrições conceituais, que constituem a representação, podem ser *explicitamente* atribuídas aos respectivos conceitos, como resultado de um processo que inclui a consulta de especialistas do domínio, utilizando-se técnicas convencionalmente empregadas na área de *Engenharia do Conhecimento*, tais como as apresentadas em (SCHREIBER et al., 1999), e na área de *Engenharia de Ontologias*, tais como as discutidas em (GÓMES-PÉREZ; FERNÁNDEZ-LÓPEZ; CORCHO, 2004). Assume-se também que é possível atribuir *explicitamente* aos conceitos protótipos e exemplares definidos com o auxílio de especialistas de domínio. No entanto, também assumimos que é possível estimar automaticamente o protótipo e os exemplares de cada conceito. Deste modo, nesta tese também são propostas abordagens para extração automática de protótipos e seleção automática de conjuntos de exemplares dos conceitos.

Na subseção 3.4.1 apresenta-se uma abordagem simples para extração de protótipos a partir de instâncias de conceitos. Na subseção 3.4.2 são apresentadas duas abordagens para seleção de exemplares.

#### **3.4.1 Abordagem para extração de protótipos**

Conforme discutido na Seção 2.1, em geral, nos estudos realizados pelas Ciências Cognitivas, tais como os discutidos em (MURPHY, 2002), foram levantadas diversas evidências de que os conceitos apresentam *efeito de tipicidade*. Ou seja, existem diferentes fontes de evidências que sugerem que algumas instâncias dos conceitos são consideradas mais *típicas* que outras, de modo que os conceitos apresentariam um gradiente de tipicidade, das instâncias mais típicas para as mais atípicas. Em geral, a *instância ideal* mais típica do conceito é chamada de *protótipo* do conceito. É importante salientar que o

protótipo não é necessariamente uma instância real, previamente percebida e memorizada por um sujeito. De acordo com (MURPHY, 2002) o protótipo pode ser uma espécie de *média* das instâncias do conceito ou uma *instância ideal* que as pessoas abstraem do conjunto de instâncias da categoria que elas conhecem. Devido a isto, diversos trabalhos, tais como (MURPHY, 2002; PALMERI; NOELLE, 2003), costumam caracterizar o protótipo como a *tendência central no gradiente de tipicidade* do conceito, ou como *centroide* (ou *baricentro*) do conceito, em um espaço psicológico (GÄRDENFORS, 2004b).

Em geral, a literatura apresenta variações no modo de representar os protótipos de um conceito. Uma forma muito comum de representar protótipos, conforme discutido em (LIETO, 2012), é através de uma simples lista de pares *atributo-valor* que especificam, para cada atributo considerado, qual é o valor típico que ele assume entre as instâncias do conceito. Neste trabalho, nós adotamos esta mesma visão a respeito da natureza dos protótipos e de como eles são extraídos a partir das instâncias particulares de cada conceito. Com base nesta visão, neste trabalho adotamos um procedimento simples que extrai centroides de um conjunto de indivíduos  $\mathbb{I}' \subseteq \mathbb{I}$ , considerando um conjunto de propriedades  $\mathbb{P}' \subseteq \mathbb{P}$ . O centroide resultante é uma  $q$ -upla com os valores típicos de cada propriedade  $p_i \in \mathbb{P}'$ , onde  $q = |\mathbb{P}'|$ . Esta estratégia é representada pelo Algoritmo 4.

---

#### Algoritmo 4: extraiCentroide

---

**Input:** Um conjunto de indivíduos  $\mathbb{I}' \subseteq \mathbb{I}$  e um conjunto  $\mathbb{P}' \subseteq \mathbb{P}$  de propriedades que descrevem os indivíduos  $\mathbb{I}'$ .

**Output:** Uma  $q$ -upla de valores, representando o centroide de  $\mathbb{I}'$ , onde  $q = |\mathbb{P}'|$ .

**begin**

    Inicializar  $prot$  como uma  $q$ -tupla, onde  $q = |p(c)|$ , tal que  $prot = (prot_0, \dots, prot_i)$ , onde  $prot_i$  representa o valor da  $i$ -ésima propriedade de  $prot$  e que é inicializado com 0, caso o atributo seja *quantitativo* e com *null*, caso o atributo seja *qualitativo*;

**foreach**  $p_i \in p(c)$  **do**

        Determinar o valor típico  $val$  da propriedade  $p_i$  das instâncias em  $ext(c)$ , e atribuir  $val$  para  $prot_i$  (o valor relativo à propriedade  $p_i$  em  $prot$ ). Se o atributo for *qualitativo*, o valor típico será considerado o *mais frequente* (a *moda*). Se o atributo for *numérico*, o valor típico será considerado a *média*;

**return**  $prot$ ;

---

Basicamente, o Algoritmo 4 determina o centroide de um determinado conjunto de indivíduos de uma forma similar à maneira como os centroides de *agrupamentos* são determinados por algoritmos como o *K-Means* (MACQUEEN et al., 1967) ou o *k-Modes* (HUANG, 1997a).

Note que a extração do protótipo de um determinado conceito  $c \in \mathbb{C}$  pode ser realizada através do Algoritmo 4, com  $extraiCentroide(ext(c), p(c))$ , de modo que o protótipo de  $c$  será o centroide da extensão de  $c$  representado como uma tupla de valores típicos para cada propriedade em  $p(c)$ .

### 3.4.2 Abordagens para seleção de exemplares

Conforme discutido no capítulo 2.1.2.3, uma das teorias propostas para explicar a natureza dos conceitos é a *teoria do exemplar*. O principal postulado desta teoria é que os conceitos são constituídos por descrições individuais de algumas de suas instâncias (MEDIN; SMITH, 1984).

Há diferentes modelos cognitivos de categorização que seguem esta teoria, e que adotam diferentes visões a respeito de quais das instâncias do conceito seriam consideradas como representativas (MURPHY, 2002; GOLDSTONE; KERSTEN, 2003). Conforme discutido em (SMITH; MINDA, 2002), alguns modelos assumem que *todas* as instâncias conhecidas pelo agente são adotadas como exemplares dos seus respectivos conceitos. No entanto, esta suposição não se ajusta ao *princípio da economia cognitiva*, que estabelece que os processos cognitivos tendem a minimizar esforços de processamento e recursos (COLMAN, 2015), uma vez que a representação explícita de informações de todas as instâncias já encontradas por um sujeito seria muito dispendiosa, considerando os recursos cognitivos limitados que seres humanos possuem. Além disso, uma vez que, segundo a teoria do exemplar, a categorização de uma nova instância é realizada comparando-a com os exemplares do conceito, a inclusão de toda instância conhecida por um determinado sujeito como um exemplar também levaria a um aumento nos esforços cognitivos necessários no processo de categorização.

É importante notar que, mesmo do ponto de vista puramente computacional, também é preferível adotar um conjunto reduzido de instâncias como exemplares representativos de cada conceito. Além da redução de instâncias implicar em uma redução na quantidade de memória necessária para representá-los, também implica em uma redução de tempo de processamento, visto que é necessário um número menor de comparações para categorizar uma nova instância. A literatura da área de Ciência da Computação (com ênfase em Aprendizado de Máquina e Mineração de Dados) busca sanar exatamente estas necessidades com trabalhos que investigam abordagens para *seleção de instâncias*, tais como (WILSON, 1972; WILSON; MARTINEZ, 2000; BRIGHTON; MELLISH, 2002; NIKOLAIDIS; GOULERMAS; WU, 2011; LIN et al., 2015; LEYVA; GONZÁLEZ; PÉREZ, 2015; CARBONERA; ABEL, 2015d). Basicamente, segundo (GARCÍA; LUENGO; HERRERA, 2015), o resultado ótimo de uma abordagem de seleção de instâncias seria um subconjunto mínimo do conjunto de dados original que permita a realização da tarefa em foco, sem que ocorra degeneração da performance.

A concepção teórica desenvolvida nesta tese é neutra a respeito de quais instâncias de um conceito devem ser consideradas como exemplares. Deste modo, a teoria é capaz de acomodar diferentes concepções a respeito de quais exemplares devem ser selecionados, incluindo a visão que considera que todas as instâncias são exemplares dos seus

respectivos conceitos. Esta liberdade é desejável do ponto de vista de desenvolvimento de sistemas, uma vez que dependendo dos recursos computacionais à disposição, e dependendo das características da tarefa, diferentes restrições podem ser adotadas a respeito de quais instâncias serão consideradas como exemplares.

Por outro lado, uma vez que o conjunto de exemplares adotado pode impactar na eficiência do processamento de uma *base de conhecimento estendida*, nesta tese também foram propostas duas abordagens para seleção de exemplares a partir das extensões dos conceitos. Na seção 3.4.2.1, é apresentada uma abordagem que assume que os exemplares de um conceito são suas instâncias limítrofes, isto é, *instâncias atípicas* do conceito e que representam a informação necessária para diferenciá-lo de conceitos similares. Na Seção 3.4.2.2, é apresentada uma abordagem que assume que os exemplares de um conceito são as instâncias que representam a informação de uma grande quantidade de instâncias similares. De modo geral, ambas as abordagens assumem que os indivíduos de um conceito que devem ser selecionados como seus exemplares são os que, sozinhos, conseguem garantir uma boa performance na classificação de novas instâncias, quando se adota uma classificação baseada em similaridade.

#### 3.4.2.1 Abordagem para identificação de instâncias limítrofes

A abordagem apresentada nesta seção assume que as instâncias limítrofes dos conceitos incorporam informação suficiente sobre o conceito para permitir a classificação de novas instâncias, pois tais instâncias representam as bordas de seus conceitos e demarcam a separação de conceitos semelhantes. Este mesmo critério de seleção é adotado por outras abordagens de seleção de instâncias, tais como a apresentada em (LEYVA; GONZÁLEZ; PÉREZ, 2015). A abordagem aqui apresentada diferencia-se das demais abordagens que também selecionam instâncias limítrofes devido a adoção de critérios adicionais que tais instâncias devem obedecer para serem selecionadas e pela estratégia adotada para realizar a seleção.


A abordagem aqui proposta, é baseada no conceito de *conjunto local* (CL), proposto por (BRIGHTON; MELLISH, 2002).

**Definição 3.2.** O *conjunto local* de uma instância  $i \in \mathbb{I}$ , denotado por  $CL(i)$ , é o conjunto de todas as instâncias contidas na maior hiperesfera centrada na instância  $i$ , de tal modo que apenas instâncias da mesma classe que  $i$  sejam incluídas na hiperesfera. Ou seja, sendo  $x \in \mathbb{I}$  o indivíduo mais próxima de  $i$  e que não pertence à extensão do mesmo conceito que  $i$ , então  $CL(i) = \{y | d(i, y) < d(i, x)\}$ , onde  $d$  é uma dada *função de distância*.



A Figura 3.6 ilustra a noção de conjunto local. Neste exemplo, estão representadas duas classes: círculos vazados e círculos escuros. O conjunto local da instância  $A$  é dado por  $CL(A) = \{A, B, C, D, E, F, G\}$ . Note que as instâncias  $I, J, K, L$  e  $M$  não podem ser incluídas devido às restrições impostas pela instância  $R$  no tamanho máximo da hiperesfera (representada como um círculo tracejado). Se a hiperesfera fosse maior, ela incluiria a instância  $R$ , que é de uma classe diferente da instância  $A$ .

Figura 3.6: Representação do conceito de *conjunto local*. O conjunto local da instância  $A$  é tal que  $CL(A) = \{A, B, C, D, E, F, G\}$ .



Fonte: Produzida pelo autor.

A noção de conjunto local nos permite definir diretamente a noção de *internalidade*, que também é importante para a abordagem aqui proposta.

**Definição 3.3.** A *internalidade* de um indivíduo  $i \in \mathbb{I}$ , denotada por  $internalidade(i)$ , é igual à cardinalidade do conjunto local de  $i$ . Isto é  $Internalidade(i) = |CL(i)|$ .

Note que quanto mais próximo das bordas de um conceito um indivíduo está, menor tende a ser a sua distância em relação a indivíduos de outras classes e, consequentemente, menor tende a ser a cardinalidade do seu conjunto local. Assim, a internalidade de um indivíduo pode ser utilizada para estimar o quão próximo das bordas de um conceito ele se encontra, de modo que quanto menor a internalidade de um indivíduo, mais próximo das bordas do conceito ele está localizado.


A Figura 3.7 ilustra a noção de internalidade de um indivíduo. Neste exemplo, estão representadas as mesmas duas classes representadas na Figura 3.6. Neste cenário, a internalidade de  $A$  é 7, pois  $internalidade(A) = |CL(A)| = |\{A, B, C, D, E, F, G\}| = 7$ . Já a internalidade de  $C$  é 1, pois  $internalidade(C) = |CL(C)| = |\{C\}| = 1$ .

Além destas noções, também adotamos o conceito de *nível de ruído potencial* (NRP) de uma instância.

**Definição 3.4.** O *nível de ruído potencial* de uma instância  $i \in \mathbb{I}$ , dado por  $NRP(i)$ , é o número de instâncias em  $\mathbb{I}$  de conceitos diferentes do conceito de  $i$ , para as quais  $i$  é a instância mais próxima de uma instância de outro conceito.

A Figura 3.7 também pode ser utilizada para ilustrar a noção de nível de ruído potencial. Neste exemplo, nota-se que  $NRP(R) = 2$ , porque existem duas instâncias ( $A$  e  $C$ ) em  $\mathbb{I}$  para as quais  $R$  é a instância mais próxima, de um conceito diferente. É importante notar que assumimos que quanto maior o  $NRP(i)$ , maiores são as chances de que a instância  $i$  represente ruído e seja prejudicial para a classificação de novas instâncias da sua classe.

Figura 3.7: Representação do conceito de *internalidade* e de *nível de ruído potencial*. A internalidade de  $A$  é 7, pois  $internalidade(A) = |CL(A)| = |\{A, B, C, D, E, F, G\}| = 7$ . Já a internalidade de  $C$  é 1, pois  $internalidade(C) = |CL(C)| = |\{C\}| = 1$ . Note também que  $NRP(R) = |\{A, C\}| = 2$ .



Fonte: Produzida pelo autor.

Além disso, outras noções importantes para esta abordagem são as de *coerência* e de *seletividade*.

**Definição 3.5.** A *coerência* de uma instância  $i \in \mathbb{I}$  é dada por  $coerencia(i) = |\{x | x \in \mathbb{I} \wedge i \in CL(x)\}|$ . A coerência de um indivíduo  $i$  é basicamente uma medida da frequência com que este indivíduo é incluído nos conjuntos locais de outros indivíduos. Ela pode ser considerada como uma medida indireta do quanto um determinado indivíduo é coerente com a informação abstraída pela sua classe.

**Definição 3.6.** A *seletividade* de uma instância  $i \in \mathbb{I}$  é dada por:

$$seletividade(i) = \frac{coerencia(i)}{internalidade(i)} \quad (3.7)$$

Neste contexto, quanto maior o valor de  $seletividade(i)$ , mais elevada é a prioridade com que o indivíduo  $i$  deve ser considerado como candidato no processo de seleção de exemplares.

Note que, de acordo com esta formulação da *seletividade*, são priorizados os indivíduos que possuem uma *alta coerência* e *baixa internalidade*. Deste modo, esta heurística tende a atribuir valores mais altos para os *indivíduos limítrofes* (que estão nas bordas do conceito), pois eles possuem baixa internalidade. E dentre os indivíduos limítrofes, são priorizados os que são mais coerentes com a classe, por representarem melhor a informação interna da classe.

Com base nestes conceitos, o Algoritmo 5 formaliza a *abordagem para seleção de instância limítrofes* (ASBI, do inglês *Approach for selection of border instances*). O algoritmo recebe como parâmetro um conjunto  $\mathbb{C}' \subseteq \mathbb{C}$ , em uma dada representação estendida  $\mathcal{KB}_\chi$  e retorna um conjunto  $E$  de conjuntos de indivíduos, onde cada conjunto  $e_i \in E$  representa o conjunto de exemplares do conceito  $c_i \in \mathbb{C}'$ . No primeiro passo do algoritmo, cria-se um conjunto  $\mathbb{I}'$  que inclui todas as instâncias de cada um dos conceitos em  $\mathbb{C}'$ . A seguir, aplica-se um algoritmo de remoção de ruído sobre o conjunto  $\mathbb{I}'$ , gerando o conjunto  $\mathbb{I}^-$ . Nesta abordagem, adotamos o algoritmo LSSm (*LocalSet-based Smoother*) (LEYVA; GONZÁLEZ; PÉREZ, 2015), devido à sua boa performance e facilidade de implementação. A seguir, para cada instância  $A$  em  $\mathbb{I}^-$ , verifica-se se a internalidade de  $A$  é maior que seu nível de ruído potencial. Se este for o caso,  $A$  é incluído na lista de *candidatos*. Se  $A$  não cumprir esta condição, isto significa que o indivíduo é limítrofe, mas a sua capacidade de representar informação de indivíduos vizinhos é inferior ao seu nível de ruído potencial. Por esta razão, o indivíduo é considerado potencialmente prejudicial para classificação de novas instâncias e é descartado. Esse passo pode ser visto como um passo adicional de filtragem de candidatos, onde são pré-selecionados os indivíduos que são mais típicos da sua classe, e com baixo potencial de prejudicar a classificação. A seguir, ordena-se o conjunto *candidatos*, de forma decedente, em função da *seletividade* de cada instância. A seguir, inicializa-se a variável *Resultante* como um conjunto vazio. Esta variável é utilizada para armazenar o conjunto de instâncias em  $\mathbb{I}^-$ , que efetivamente representam os indivíduos limítrofes selecionados e que, por isso, serão consideradas como os exemplares dos conceitos em  $\mathbb{C}$ . No próximo passo, para cada instância  $A$  em *candidatos*, verifica-se se já foi incluída em *Resultantes* alguma instância do conjunto local de  $I$  (verificando-se se a interseção entre *Resultante* e  $CL(A)$ ) é vazia). Caso a interseção seja vazia, a instância  $A$  é incluída em *Resultantes*, para garantir que  $A$  e instâncias próximas de  $A$  sejam corretamente classificadas. A seguir, cria-se um conjunto  $E$ , com  $|\mathbb{C}'|$  conjuntos vazios, onde cada  $e_i \in E$  representa os exemplares do conceito  $c_i \in \mathbb{C}'$ . No passo final, atribui-se para cada  $e_i \in E$ , todas as instâncias em *Resultantes* que são instâncias do conceito  $c_i$ .

Nota-se que a seletividade desempenha um papel importante na ordem da avaliação de quais instâncias devem ser conservadas como exemplares e quais devem ser descartadas. A abordagem aqui apresentada avalia preferencialmente as instâncias com maior coerência e menor internalidade. Isso tem como efeito o aumento das chances de se selecionar indivíduos próximos das bordas (indivíduos de baixa internalidade), mas que sejam capazes de representar mais informação de indivíduos vizinhos (indivíduos com alta coerência), descartando instâncias potencialmente mais ruidosas e menos representativas da classe.

---

**Algoritmo 5: ASBI (Approach for selection of border instances)**


---

**Input:** Um conjunto  $\mathbb{C}' \subseteq \mathbb{C}$  em uma dada  $\mathcal{KB}_\chi$ .

**Output:** Um conjunto  $E$  de conjuntos de indivíduos, onde cada conjunto  $e_i \in E$  representa os exemplares do conceito  $c_i \in \mathbb{C}'$ .

**begin**

$\mathbb{I}' \leftarrow \bigcup_{c \in \mathbb{C}'} ext(c)$ ;

$\mathbb{I}^- \leftarrow$  Resultado da aplicação de LSSm sobre  $\mathbb{I}'$ ;

$candidateos \leftarrow \emptyset$ ;

**foreach**  $A \in \mathbb{I}^-$  **do**

**if**  $internalidade(A) > NRP(A)$  **then**

$candidateos \leftarrow candidateos \cup \{A\}$ ;

Ordenar indivíduos em  $candidateos$ , de forma descendente, em função da sua *seletividade*;

$Resultantes \leftarrow \emptyset$ ;

**foreach**  $A \in candidateos$  **do**

**if**  $CL(A) \cap Resultantes = \emptyset$  **then**

$Resultantes \leftarrow Resultantes \cup \{A\}$ ;

$E \leftarrow \{e_1, \dots, e_{|\mathbb{C}'|}\}$ , onde cada  $e_i \leftarrow \emptyset$ ;

**foreach**  $c_i \in \mathbb{C}'$  **do**

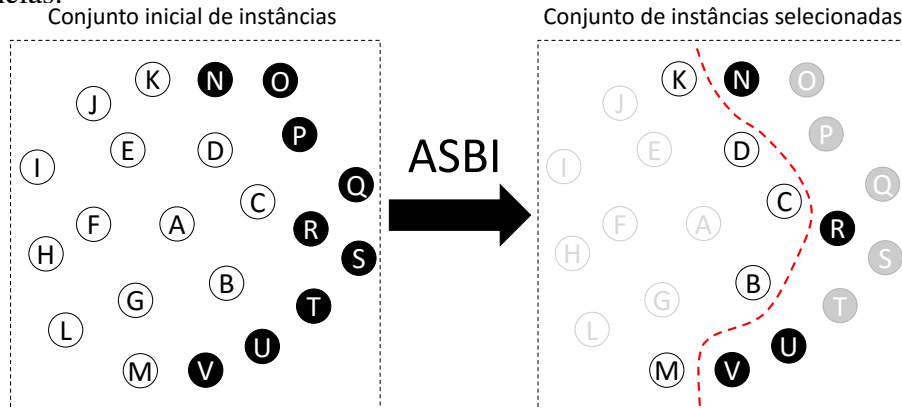
$e_i \leftarrow \{\forall A \in Resultantes | A \in ext(c_i)\}$ ;

**return**  $E$ ;

---

Na Figura 3.8 apresenta-se um exemplo de aplicação do algoritmo ASBI em um dado conjunto de instâncias, separadas em duas categorias: círculos vazados e círculos escuros. Nota-se que apenas as instâncias que demarcam os limites das duas categorias são selecionadas pelo algoritmo.

Figura 3.8: Exemplo ilustrativo de aplicação do algoritmo ASBI em um conjunto artificial de instâncias.



Fonte: Produzida pelo autor.

Analisando o Algoritmo 5, é possível notar que os seus passos mais custosos são a aplicação do algoritmo para remoção de ruído (LSSm) e o processo de se determinar os conjuntos locais. O algoritmo LSSm tem complexidade temporal de  $O(|\mathbb{I}'|^2)$ . A determinação dos conjuntos locais também pode ser realizada com uma complexidade temporal

$O(|\mathbb{I}^-|^2)$ . Neste sentido, podemos assumir que a complexidade temporal do algoritmo ASBI é proporcional a  $O(|\mathbb{I}'|^2)$ . Esta complexidade é equivalente à complexidade de outros algoritmos de seleção de instâncias disponíveis na literatura, tais como (BRIGHTON; MELLISH, 2002; LEYVA; GONZÁLEZ; PÉREZ, 2015).

É importante notar também que o algoritmo ASBI é projetado para selecionar as *instâncias limítrofes* entre *conceitos diferentes*, cujas extensões não possuam sobreposições, assumindo que cada indivíduo é classificado por um único conceito. Devido a isto, é necessário que o conjunto  $\mathbb{C}' \subseteq \mathbb{C}$ , que ele recebe como parâmetro, contenha apenas conceitos cujas extensões sejam *disjuntas*. Esta característica pode ser vista como uma limitação fundamental da estratégia adotada pelo algoritmo, visto que, como consequência, o algoritmo não é adequado para ser aplicado para selecionar exemplares em contextos nos quais existem relações hierárquicas entre conceitos. No entanto, este algoritmo é perfeitamente aplicável aos problemas típicos de seleção de instâncias como os tratados em (WILSON, 1972; WILSON; MARTINEZ, 2000; BRIGHTON; MELLISH, 2002; NIKOLAIDIS; GOULERMAS; WU, 2011; LIN et al., 2015; LEYVA; GONZÁLEZ; PÉREZ, 2015; CARBONERA; ABEL, 2015d), apresentando uma performance comparável ou superior aos algoritmos no estado da arte (como pode ser visto no Apêndice A).

#### 3.4.2.2 Abordagem baseada em densidade local para identificação de instâncias representativas

Na Seção 3.4.2.1 apresentou-se uma abordagem para seleção de exemplares que adota como estratégia básica a seleção de instâncias limítrofes dos conceitos. Esta mesma estratégia é adotada por grande parte das abordagens de seleção de instâncias disponíveis na literatura, tais como (BRIGHTON; MELLISH, 2002; LEYVA; GONZÁLEZ; PÉREZ, 2015). No entanto, apesar da seleção de instâncias de borda geralmente resultar em conjuntos de instâncias que suportam classificação com *grande acurácia*, esta estratégia costuma acarretar um *alto custo computacional*. Isto se deve ao fato de que, em geral, estas estratégias precisam realizar uma *busca global* pelas instâncias de borda. Neste processo de busca é necessário realizar comparações entre todos os pares de instâncias em  $\mathbb{I}$ . O resultado é uma *complexidade temporal* proporcional a  $O(|\mathbb{I}|^2)$ .

Nesta Seção, apresenta-se uma abordagem que adota uma estratégia diferente para selecionar instâncias. Em vez de identificar instâncias de borda, esta abordagem identifica instâncias que possuem uma *alta concentração* de instâncias em sua vizinhança, similares a ela. Esta estratégia assume que tais instâncias conseguiriam representar mais informações da vizinhança do que suas instâncias vizinhas e, por isso, seriam mais representativas. Além disso, em vez de buscar estas instâncias em todo o conjunto  $\mathbb{I}$ , esta nova abordagem busca as instâncias representativas dentro da extensão de cada conceito em  $\mathbb{C}$ , separadamente. A adoção desta estratégia de *busca local* garante tempos de execução

menores que os tempos de execução das abordagens que identificam bordas (que envolve realizar comparações de todas as instâncias com todas as instâncias). A abordagem aqui proposta, resultante de adoção desta estratégia, chama-se de *seleção de instâncias baseada em densidade local* (LDIS, do inglês *Local density-based instance selection*). Esta abordagem foi previamente apresentada pelo autor em (CARBONERA; ABEL, 2015d) e aperfeiçoa a abordagem discutida pelo autor em (CARBONERA; ABEL, 2015e; CARBONERA; ABEL, 2015c; CARBONERA; ABEL, 2015b).

Conforme dito anteriormente, a abordagem proposta estabelece que instâncias representativas são aquelas que possuem uma alta concentração de outras instâncias em sua vizinhança próxima. Para medir esta concentração, utilizamos a noção de *densidade*, adaptada de (BAI et al., 2012; CARBONERA; ABEL, 2015b; CARBONERA; ABEL, 2015c; CARBONERA; ABEL, 2015e), que pode ser formalizada pela função *Dens*:

$$Dens(x, P) = -\frac{1}{|P|} \sum_{y \in P} d(x, y) \quad (3.8)$$

, onde  $x$  é uma dada instância,  $P = \{x_0, x_1, \dots, x_q\}$  é um conjunto de  $q$  instâncias,  $x \in P$ , e  $d$  é uma dada função de distância. É importante notar que  $Dens(x, P)$  mede a densidade de uma instância  $x$ , em relação ao conjunto  $P$  de instâncias. Desta forma, quando  $P$  é apenas um subconjunto de  $\mathbb{I}$ ,  $Dens(x, P)$  representa a *densidade local* de  $x$ , considerando  $P$ .

A abordagem aqui proposta também adota a noção de *k-vizinhança parcial*, inicialmente apresentada em (CARBONERA; ABEL, 2015d):

**Definição 3.7.** A *k-vizinhança parcial* de uma dada instância  $x \in ext(c)$ , tal que  $c \in \mathbb{C}$ , considerando um dado  $k \in \mathbb{N}_1$ , é o conjunto de  $k$  instâncias mais próximas de  $x$  e que também pertencem à  $ext(c)$  (excetuando-se o próprio  $x$ ). A noção de *k-vizinhança parcial* é dada pela função  $pkn: \mathbb{I} \times \mathbb{N}_1 \rightarrow 2^{\mathbb{I}}$ , que mapeia uma dada instância  $x_i \in \mathbb{I}$  e um dado  $k \in \mathbb{N}_1$  ( $k \geq 1$ ) para um dado conjunto  $S$ , tal que  $S \subseteq C$ , onde  $x \in ext(C)$ .

O algoritmo LDIS assume que a densidade,  $Dens(x, P)$ , de uma determinada instância  $x$  em um conjunto  $P$ , onde  $c_i \in \mathbb{C}$  e  $P = ext(c_i)$ , é proporcional à *representatividade* de  $x$  para  $c_i$  e, logo, proporcional à *utilidade* de  $x$  para classificar novas instâncias de  $c_i$ . Esta suposição é baseada no fato de que a instância localmente mais densa em uma dada vizinhança representa mais informação desta vizinhança do que as instâncias menos densas. Considerando isto, para cada  $c_i \in \mathbb{C}$ , o algoritmo LDIS verifica, para cada  $x \in ext(c_i)$ , se há alguma instância  $y \in pkn(x, k)$  (onde  $k$  é arbitrariamente definido), tal que  $Dens(y, ext(c_i)) > Dens(x, ext(c_i))$ . Caso não exista nenhuma instância  $y$  que satisfaça tais requisitos, isso significa que  $x$  é a instância *localmente mais densa* na sua *k-vizinhança parcial* e, devido a isso,  $x$  deve ser incluída no conjunto final de instâncias exemplares. O Algoritmo 6 formaliza esta estratégia.

Assim como ocorre com o algoritmo ASBI, o algoritmo LDIS também recebe como parâmetro um conjunto  $\mathbb{C}' \subseteq \mathbb{C}$ , em uma dada representação estendida  $\mathcal{KB}_\chi$  e um dado valor  $k \in \mathbb{N}_1$ , usado para determinar o tamanho da *k-vizinhança parcial*; e também retorna um conjunto  $E$  de conjuntos de indivíduos, onde cada conjunto  $e_i \in E$  representa os exemplares do conceito  $c_i \in \mathbb{C}'$ . Salienta-se também que quando  $|ext(c)| \leq k$ , é necessário considerar  $k = |ext(c)| - 1$  para calcular a *k-vizinhança parcial* de  $x$ .

---

**Algoritmo 6:** LDIS (Local Density-based Instance Selection)

---

**Input:** Um conjunto  $\mathbb{C}' \subseteq \mathbb{C}$  em uma dada  $\mathcal{KB}_\chi$  e um valor  $k \in \mathbb{N}_1$  usado para definir o tamanho da *k-vizinhança parcial*.

**Output:** Um conjunto  $E$  de conjuntos de indivíduos, onde cada conjunto  $e_i \in E$  representa o conjunto dos exemplares do conceito  $c_i \in \mathbb{C}'$ .

```

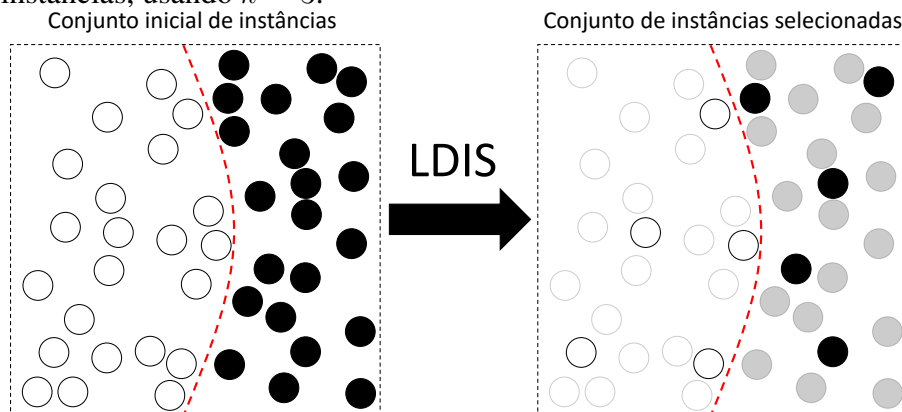
begin
   $E \leftarrow \{e_1, \dots, e_{|\mathbb{C}'|}\}$ , onde cada  $e_i \leftarrow \emptyset$ ;
  foreach  $c_i \in \mathbb{C}'$  do
    foreach  $x \in ext(c_i)$  do
       $maisDensidadeEncontrado \leftarrow false$ ;
      foreach  $vizinho \in pkn(x, k)$  do
        if  $Dens(x, ext(c_i)) < Dens(vizinho, ext(c_i))$  then
           $maisDensidadeEncontrado \leftarrow true$ ;
      if  $\neg maisDensidadeEncontrado$  then
         $e_i \leftarrow e_i \cup \{x\}$ ;
  return  $E$ ;

```

---

Na Figura 3.9 apresenta-se um exemplo de aplicação do algoritmo LDIS, usando  $k = 3$ , em um dado conjunto de instâncias, separadas em duas categorias: círculos vazados e círculos escuros. Basicamente, as instâncias selecionadas são as que possuem densidade mais alta que suas vizinhas na *k-vizinhança parcial* estabelecida.

Figura 3.9: Exemplo ilustrativo de aplicação do algoritmo LDIS em um conjunto de artificial de instâncias, usando  $k = 3$ .



Fonte: Produzida pelo autor.

Nota-se que os passos de maior custo computacional do algoritmo LDIS são os que envolvem determinar a *densidade parcial* e a *k-vizinhança parcial* de cada instância de um dado conceito  $c_i \in \mathbb{C}$ . Determinar a *densidade parcial* de cada instância de um conceito  $c_i$  é um processo cuja complexidade temporal é proporcional a  $O(|ext(c_i)|^2)$ . A com-

plexidade temporal do processo de determinar a *k-vizinhança parcial* é equivalente. Uma implementação eficiente<sup>3</sup> do algoritmo 6 poderia calcular a *k-vizinhança parcial* e a *densidade parcial* de cada instância de cada conceito apenas uma vez, como um primeiro passo dentro do laço principal, e usar esta informação para os cálculos adicionais. Considerando isto, a complexidade temporal do LDIS seria proporcional a  $O(\sum_{c_i \in \mathbb{C}'} |ext(c_i)|^2)$ . Esta complexidade temporal é mais vantajosa que a complexidade temporal do algoritmo ASBI ( $O(|\mathbb{I}'|^2)$ ).

É importante notar que, diferentemente do que ocorre com o algoritmo ASBI, o algoritmo LDIS não assume que o conjunto de conceitos em  $\mathbb{C}' \subseteq \mathbb{C}$  deve ser disjunto. Deste modo, o LDIS constitui uma alternativa viável para selecionar exemplares em contextos nos quais os conceitos considerados possuem relações hierárquicas entre si. Além disso, assim como ocorre com o ASBI, o algoritmo LDIS é perfeitamente aplicável aos problemas típicos de seleção de instâncias como os tratados em (WILSON, 1972; WILSON; MARTINEZ, 2000; BRIGHTON; MELLISH, 2002; NIKOLAIDIS; GOU-LERMAS; WU, 2011; LIN et al., 2015; LEYVA; GONZÁLEZ; PÉREZ, 2015; CARBONERA; ABEL, 2015d), apresentando uma performance comparável ou superior aos algoritmos no estado da arte (como pode ser visto no Apêndice A).

---

<sup>3</sup>Uma implementação eficiente do algoritmo LDIS pode ser encontrada em <[http://www.inf.ufrgs.br/~jlcarbonera/?page\\_id=122](http://www.inf.ufrgs.br/~jlcarbonera/?page_id=122)>.



## 4 APLICAÇÃO DA ABORDAGEM PROPOSTA

Nesta Seção será descrita uma aplicação das abordagens propostas no capítulo 3 à tarefa de *interpretação de processos deposicionais*, que é desempenhada por especialistas no domínio da *Estratigrafia Sedimentar*; uma subárea da Geologia. A tarefa de interpretação de processos deposicionais é de fundamental importância para determinar as condições de geração e atual distribuição espacial de depósitos minerais, especialmente os de origem orgânica como carvão e petróleo.

Antes de descrever como a abordagem proposta nesta tese foi aplicada à tarefa de interpretação de processos deposicionais, na Seção 4.1 será apresentada uma visão geral do domínio da Estratigrafia Sedimentar, em que serão evidenciados os principais conceitos, objetivos do domínio, bem como a tarefa específica que constitui o foco de aplicação da abordagem aqui proposta.

### 4.1 Visão geral da Estratigrafia Sedimentar

A Estratigrafia Sedimentar, consiste em uma subárea da Geologia que, em sua concepção tradicional, é voltada à descrição, correlação e classificação dos estratos de rochas sedimentares (PRESS et al., 2004). Esta visão é totalmente centrada na rocha, que é compreendida como um registro de eventos do passado. Deste modo, este domínio investiga as exposições rochosas, que podem ser *afloramentos* ou *testemunhos de sondagem*, buscando explicar os processos de formação de sucessões sedimentares, geradas pela desagregação, transporte e deposição de sedimentos originados de outras rochas. As Figuras 4.1 e 4.2 apresentam um exemplo de afloramento rochoso e um exemplo de testemunho de sondagem, respectivamente.

Figura 4.1: Exemplo de afloramento de rocha.



Fonte: Wikipedia<sup>1</sup>.

Figura 4.2: Exemplo de testemunho de sondagem.



Fonte: (CASTRO; PERINOTTO; CASTRO, 1999).


Os resultados alcançados através das investigações realizadas pela Estratigrafia Sedimentar são cruciais para a compreensão de ocorrências de reservas de recursos naturais, tais como o petróleo. É através de informações levantadas neste domínio que se pode inferir a localização das acumulações de certos recursos naturais ao longo da extensão (em superfície ou subsuperfície) do planeta, bem como determinar a possível geometria de reservatórios subterrâneos destes recursos, determinar a possível quantidade de recursos armazenados nestes reservatórios e, conseqüentemente, permitir a realização de estudos de viabilidade econômica de extração destes recursos, bem como conduzir este processo de extração de uma maneira informada.

Os conceitos de *fácies sedimentar*, *estrutura sedimentar*, de *processo deposicional* e *ambiente sedimentar* são fundamentais para as atividades do domínio. Um ambiente sedimentar corresponde a uma área da superfície terrestre com características físicas, químicas e biológicas que a distinguem das áreas adjacentes. Os ambientes sedimentares são classificados de acordo com a predominância dos processos que ocorrem neles. Neste sentido, ambientes sedimentares podem ser: (a) *erosivos*, quando predominam processos erosivos; (b) *neutros*, quando a região apresenta processos erosivos e deposicionais pouco significativos; ou (c) *deposicionais*, quando predominam processos de acumulação (deposição) de sedimentos. Os ambientes sedimentares também são conhecidos como ambientes de sedimentação ou ambientes deposicionais, e são caracterizados e classificados em função dos diversos processos deposicionais que ocorrem neles. As características físicas dos ambientes englobam as variações de velocidade e sentido do meio de transporte, que pode ser vento, onda ou água corrente; bem como características climáticas de diversos tipos. As propriedades químicas abrangem a composição da água nos ambientes

subaquáticos e a geoquímica das rochas. As propriedades biológicas estão ligadas às associações de flora e fauna, uma vez que animais e vegetais influenciam as taxas de erosão e deposição ou as propriedades físico-químicas dos sedimentos já depositados (SUGUIO, 2003).

Os ambientes sedimentares são agrupados de acordo com sua localização e condições ambientais. Sua localização pode ser nos continentes, nas regiões costeiras ou nos oceanos. As condições ambientais incluem o tipo e quantidade de água (oceano, lago, rio e terra árida), o relevo (terras baixas, montanhas, planícies costeiras e oceano raso ou profundo) e a atividade biológica (PRESS et al., 2004). A Figura 4.3 apresenta um esquema em que são representados os diversos ambientes sedimentares e suas localizações.

Figura 4.3: Esquema em que são representados os diversos ambientes sedimentares e suas localizações.




Fonte: (PRESS et al., 2004).

O ambiente sedimentar constitui o objeto final de estudo da Estratigrafia Sedimentar. Ou seja, todo processo de interpretação conduzido no domínio tem como objetivo interpretar o ambiente sedimentar no qual os registros analisados se formaram.

Fácies Sedimentar (do latim *facies*, que significa face) corresponde à menor unidade que compõe um pacote de rochas sedimentares e corresponde ao conjunto de aspectos litológicos e paleontológicos de um depósito sedimentar (FÁVERA, 2001). Assim, é possível compreender a fácies sedimentar como uma determinada porção de rocha que apresenta certo grau de homogeneidade em seu aspecto, e que se distingue das porções de rocha adjacentes a ela em um mesmo corpo de rochas, em função da identificação de heterogeneidades significativas em um ou mais dos seus atributos (PROTHERO, 1991).

Assume-se que cada fácies constitui o resultado direto da ocorrência de um processo deposicional, de modo que facies sedimentares registram e permitem a reconstrução interpretativa do seu processo deposicional formador. Na Figura 4.4 apresenta-se um testemunho de sondagem em escala, com duas fácies destacadas.

Figura 4.4: Exemplo de testemunho de sondagem, em escala, com duas fácies destacadas.



Fonte: (LORENZATTI, 2009).

As estruturas sedimentares correspondem a padrões geométricos externamente visíveis que indicam padrões de arranjos espaciais de grãos de uma fácies. As estruturas são organizadas em uma taxonomia com diversos tipos que correspondem a abstrações de padrões geométricos registrados nas rochas, de modo recorrente no domínio. Neste sentido, estas entidades são ricas em informações visuais e são de difícil caracterização, de modo que existem dificuldades intrínsecas em explicitar através de símbolos linguísticos uma caracterização completa de uma estrutura. Estas dificuldades foram relatadas em (CARBONERA, 2012). Existem diversos tipos de estruturas sedimentares, tais como: biogênicas, químicas e diagenéticas, de deformação, de topo e base de camada, e deposicionais. O arranjo espacial dos grãos que caracteriza o aspecto visual de uma estrutura sedimentar registra diretamente a dinâmica da ocorrência do processo deposicional que a gerou. Nas Figuras 4.5, 4.6 e 4.7 são apresentados exemplos de estruturas sedimentares.

*Processos deposicionais* são os processos responsáveis por transportar partículas clásticas (fragmentos de outras rochas) até o local de sedimentação. Estes processos correspondem a interações complexas entre diversas forças físicas e sedimentos em um dado ambiente, e são considerados os responsáveis diretos pela organização espacial das partículas clásticas transportadas e depositadas, gerando os padrões visuais que definem estruturas sedimentares. Assim, processos deposicionais correspondem a dinâmicas que ocorrem no ambiente, responsáveis pelo transporte e deposição de sedimentos que, ao longo do tempo, consolidam-se em rochas, originando fácies sedimentares. Neste sentido, assume-se no domínio que cada fácies sedimentar corresponde ao resultado direto

Figura 4.5: Exemplo da estrutura sedimentar.



Fonte: (COLLINSON, 2005).

Figura 4.6: Exemplo de estrutura sedimentar.



Fonte: (COLLINSON, 2005).

da ocorrência de um único processo deposicional. Os processos deposicionais podem ser de diversos tipos com características próprias. Cada tipo de processo deposicional descreve diferentes maneiras gerais de transporte e deposição de sedimentos, que ocorrem em função de diferentes condições ambientais e forças físicas atuando.

A tarefa específica do domínio que constitui o foco deste trabalho é a *interpretação de processos deposicionais* a partir da inspeção visual de fácies sedimentares. Os objetivos finais das investigações estratigráficas são a interpretação do ambiente sedimentar e a elaboração de uma narrativa histórica coerente, onde os registros observados (exposições rochosas) são explicados como sendo resultados da sucessão de ocorrências de processos deposicionais nas condições ambientais que propiciaram esta ocorrência. Assim, a tarefa de interpretação de processos deposicionais insere-se neste contexto, como uma etapa a ser cumprida para alcançar este objetivo. Por exemplo, um ambiente deposicional fluvial (associado à existência de um ou mais rios) terá como principal processo deposicional as *correntes trativas*, onde a água é o meio que transporta os sedimentos por arrasto. Deste modo, a constatação da ocorrência de um processo de correntes trativas pode ser utilizada para evidenciar um ambiente fluvial. O presente trabalho restringe-se apenas à tarefa de

Figura 4.7: Exemplo de estrutura sedimentar.



Fonte: (COLLINSON, 2005).

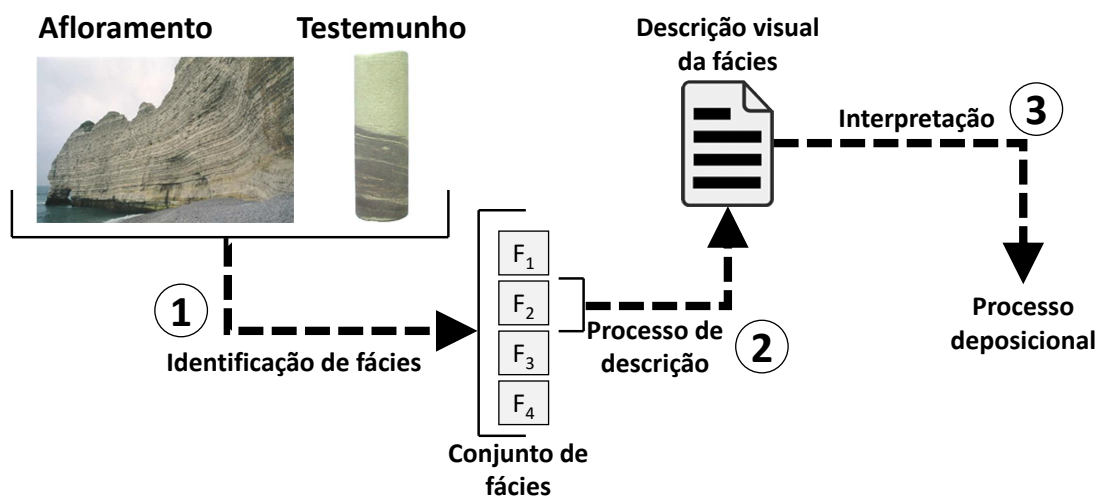
interpretação de processos deposicionais, de modo que a interpretação de ambientes deposicionais não será abordada. No entanto, espera-se que a abordagem proposta neste trabalho possa ser considerada como um passo inicial para um tratamento computacional da interpretação de ambientes sedimentares.

A investigação estratigráfica inicia com a observação dos *registros*, que neste caso podem ser *corpos de rocha* de dois tipos: *afloramentos* ou *testemunhos de sondagem*. Estes corpos de rocha, por sua vez, são segmentados em unidades que correspondem a fácies sedimentares. Esta segmentação é realizada através da constatação de discontinuidades significativas nos atributos descritivos ao longo do corpo de rochas observado. Uma vez determinado o conjunto de fácies, o geólogo as descreve uma a uma, atribuindo valores específicos para cada um dos seus atributos descritivos. Finalmente, a partir da descrição de cada fácies, o geólogo interpreta o possível processo deposicional responsável pela sua formação. O processo deposicional interpretado deve explicar as feições visuais observadas na fácies. Assim, o geólogo assume que as características visuais da fácies sedimentar registram as características dos seus respectivos processos deposicionais geradores. Cada tipo de processo deposicional é relacionado a um conjunto de propriedades diagnósticas que estão presentes nas fácies sedimentares resultantes. Deste modo, a interpretação do processo deposicional responsável por gerar uma determinada fácies envolve a verificação da presença de um conjunto de propriedades diagnósticas na fácies.

A Figura 4.8 ilustra esquematicamente o processo de interpretação, apresentando o fluxo de tarefas realizadas bem como as informações produzidas em cada tarefa, partindo do corpo de rocha analisado pelo geólogo e resultando na interpretação do processo deposicional de cada uma das fácies identificadas neste corpo de rocha.

Embora a Estratigrafia Sedimentar inclua a descrição de rochas siliciclásticas, químicas, biológicas e, eventualmente, vulcânicas, este trabalho restringe o escopo, considerando apenas o estudo das rochas siliciclásticas, com a hipótese de que as contribuições realizadas possam ser estendidas às demais classes de rochas.

Figura 4.8: Esquema do processo de interpretação de processos deposicionais.



Fonte: Produzida pelo autor.

## 4.2 Uma abordagem para interpretação de processos deposicionais

Nesta Seção, será discutido como a abordagem apresentada no Capítulo 3 pode ser aplicada à tarefa de interpretação automática de processos deposicionais. A aplicação discutida nesta Seção permite a descrição de instâncias individuais de fácies sedimentares utilizando conceitos, relações e propriedades utilizadas pelos geólogos. Para cada fácies sedimentar específica descrita, a aplicação é capaz de fornecer uma interpretação do tipo do processo deposicional responsável pela sua geração. É importante notar que esta Seção não descreve um sistema completo, mas simplesmente uma aplicação da abordagem proposta, que tem como objetivo demonstrar o uso da abordagem desenvolvida em uma tarefa prática.

A tarefa de interpretação de processos deposicionais já foi abordada em trabalhos prévios do autor, tais como (CARBONERA et al., 2011; CARBONERA, 2012; CARBONERA et al., 2013; CARBONERA; ABEL; SCHERER, 2015). Tais trabalhos adotam uma abordagem de interpretação totalmente guiada por ontologias e realizada através de um processo de raciocínio baseado em regras. A aplicação desenvolvida nesta Seção diferencia-se da abordagem utilizada anteriormente, uma vez que adota a noção de *base de conhecimento estendida* e um processo de *raciocínio híbrido* para realizar a interpretação. Ou seja, na aplicação aqui apresentada, os conceitos relevantes do domínio são representados por um componente clássico (definições, em termos de condições necessárias e suficientes, e relações entre conceitos), protótipos e exemplares. A o processo de interpretação de processos deposicionais foi modelado como um problema de classificação, passível de ser resolvido pela estratégia de raciocínio híbrido proposta nesta tese.

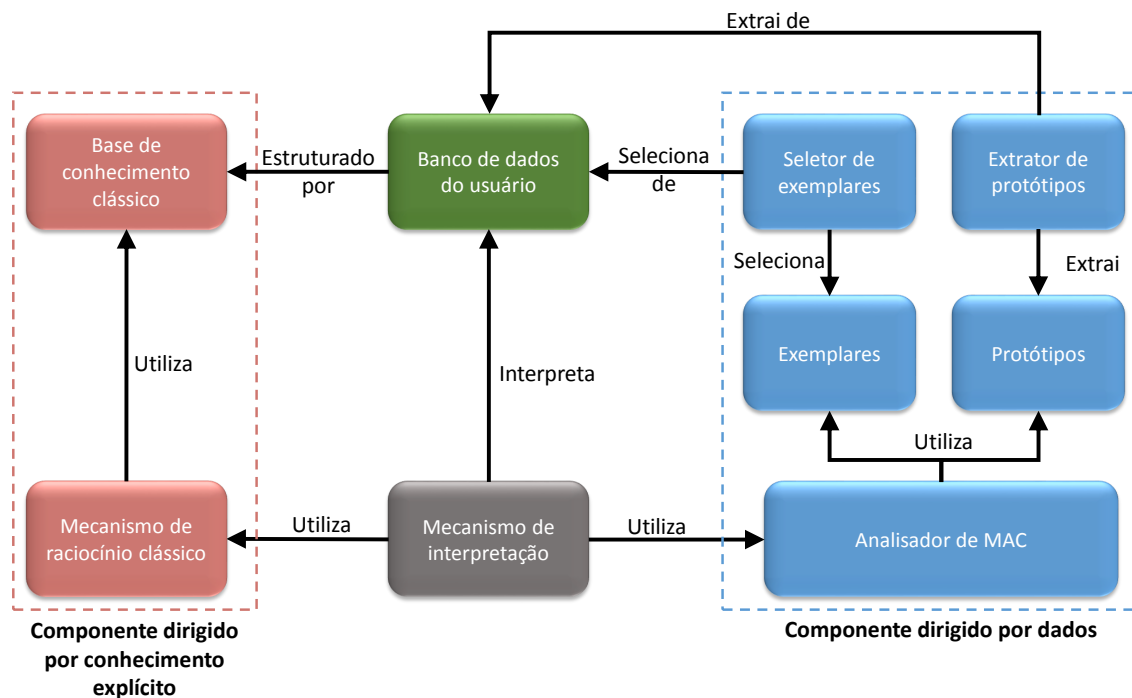
Na Figura 4.9 é apresentado um esquema abstrato da arquitetura de componentes que constituem a aplicação para interpretação automática de processos deposicionais, utilizando a proposta de representação de conhecimento e raciocínio propostos nesta tese. Nesta arquitetura nota-se a existência de 4 componentes principais: o *banco de dados do usuário*, o *componente dirigido por conhecimento explícito*, o *componente dirigido por dados* e o *mecanismo de interpretação*.

- O *banco de dados do usuário* armazena instâncias de *fácies sedimentares* (interpretadas e não interpretadas) descritas pelo usuário.
- O *componente dirigido por conhecimento explícito* (à esquerda) inclui uma base de conhecimento clássico, que descreve conceitos em termos de axiomas. Esta base de conhecimento clássico também estabelece a estrutura da base de dados do usuário. Além disso, o componente dirigido por conhecimento explícito também inclui um *mecanismo de raciocínio clássico*, que realiza um processo de raciocínio baseado em lógica para processar o conhecimento clássico e estabelecer conclusões.
- O *componente dirigido por dados* (à direita) inclui diversos subcomponentes necessários para permitir a utilização de protótipos e exemplares extraídos e selecionados da base de dados do usuário. Além de um conjunto de *exemplares* e de um conjunto de *protótipos*, este componente também inclui o *extrator de protótipos* (que implementa o Algoritmo 4, apresentado na Seção 3.4.1), o seletor de exemplares (que implementa as abordagens discutidas na Seção 3.4.2), bem como o *analisador de MAC* (que implementa o Algoritmo 1 discutido na Seção 3.3.1). Além disso, conforme indicado na Figura, o analisador de MAC utiliza protótipos e exemplares para determinar a medida de adequação conceitual de um dado conceito para classificar um dado indivíduo.
- O *mecanismo de interpretação* (que implementa o Algoritmo 2, discutido na Seção 2), utiliza o *mecanismo de raciocínio lógico* bem como o *analisador de MAC* para realizar interpretações de cada uma das *fácies sedimentares* armazenadas no banco de dados do usuário.

É importante notar que o esquema apresentado na Figura 4.9 representa de modo abstrato a *arquitetura* dos componentes de software da aplicação. Deste modo, os elementos de uma base de conhecimento estendida, discutidos na Seção 3.2 não possuem representação direta neste esquema, visto que não constituem necessariamente componentes de software no sentido aqui compreendido. No entanto, os elementos de uma base de conhecimento estendida estão representados de maneira distribuída ao longo dos componentes da arquitetura apresentada na Figura 4.9. Assim, por exemplo, a base de conhecimento clássico representa os componentes clássicos dos conceitos, tais como definições (representadas através de axiomas), relações, propriedades, etc. Por outro lado, o conjunto de exemplares e o conjunto de protótipos representam respectivamente os ele-



Figura 4.9: Representação esquemática da arquitetura do sistema para interpretação de processos deposicionais.



Fonte: Produzida pelo autor.

mentos  $\mathcal{E}$  e  $\mathcal{P}$ , que constituem uma base de conhecimento estendida. As relações entre cada conceito representado na base de conhecimento estendida e sua definição e seus exemplares e protótipos são representadas por meio de índices identificadores que são manipulados pela aplicação.

Nesta aplicação, a *base de conhecimento clássico* é basicamente um modelo de conhecimento implementado em *OWL 2*. A *OWL* foi adotada principalmente devido à ampla aceitação da linguagem na comunidade, devido às suas propriedades bem conhecida e à disponibilidade de mecanismos de raciocínio eficientes. Como consequência da adoção da *OWL*, a base de dados do usuário, nesta aplicação, é basicamente uma *base de instâncias OWL*. Deste modo, cada fácies sedimentar descrita pelo usuário é representada como uma instância *OWL* descrita por meio dos conceitos, relações e propriedades definidos no modelo *OWL* que constitui a *base de conhecimento clássico*. Também é importante notar que a adoção da *OWL* também possibilitou a adoção de um mecanismo de raciocínio *OWL* como *mecanismo de raciocínio clássico*. Na versão atual da aplicação adotou-se o mecanismo de raciocínio Hermit<sup>2</sup>, devido à sua eficiência (SHEARER; MOTIK; HORROCKS, 2008).


<sup>2</sup><<http://www.hermit-reasoner.com/>>

O modelo de conhecimento que constitui a base de conhecimento clássico da aplicação incorpora e estende a ontologia de domínio para Estratigrafia Sedimentar proposta inicialmente em (LORENZATTI, 2009) e aperfeiçoada em (CARBONERA, 2012). Tal modelo é apresentado em detalhes no Apêndice B. Conforme visto na Seção 4.1, o conceito mais importante do domínio da Estratigrafia e que integra este modelo de conhecimento é o conceito de *Fácies Sedimentar*. A aplicação permite a descrição e a interpretação de instâncias deste conceito, buscando determinar o tipo do processo deposicional responsável por formar cada uma delas. Cada instância de fácies sedimentar é descrita através de 11 atributos, os quais são: *granulometria, esfericidade, seleção, arredondamento, cor, gradação de lâmina, gradação de camada, ocorrência de grãos específicos, orientação de fábrica, suporte de fábrica e litologia*. Além disso, durante a descrição de uma fácies sedimentar, também são descritas as diferentes *estruturas sedimentares* que ela pode possuir. Na aplicação, as estruturas sedimentares de uma instância  $f$  de Fácies Sedimentar são representadas por instâncias de especializações do conceito *Estrutura Sedimentar* (cada qual representando um tipo específico de estrutura sedimentar), devidamente relacionadas a  $f$  por uma relação *tem estrutura sedimentar*. É importante também notar que o modelo de conhecimento clássico utilizado pela aplicação incorpora uma taxonomia de tipos de estruturas sedimentares. Além disso, uma vez que a aplicação busca interpretar o tipo do *Processo Depositional* responsável pela gênese de cada fácies sedimentar, o modelo de conhecimento adotado também inclui uma taxonomia de processos deposicionais. O modelo também assume que existe uma relação entre *Fácies Sedimentar* e *Processo Depositional*, chamada *gerada por*, que relaciona uma instância da fácies sedimentar  $f$  e uma instância de processo deposicional  $p$ , indicando que  $f$  foi gerada por  $p$ .

A Figura 4.10 representa o núcleo do modelo de conhecimento clássico adotado na aplicação proposta. A Figura 4.12 representa a taxonomia de tipos de Estruturas Sedimentares. A Figura 4.11 representa a taxonomia de tipos de processos deposicionais considerados no modelo de conhecimento clássico adotado. Atualmente, esta taxonomia detalha apenas os tipos de *correntes trativas subaquosas*, mas inclui categorias gerais de *correntes trativas subaéreas, fluxos gravitacionais, processos oscilatórios e processos suspensivos*. No futuro, tais categorias gerais também podem ser detalhadas, através da inclusão de novos subtipos. Ambas as taxonomias constituem extensões das taxonomias propostas em (CARBONERA, 2012; CARBONERA et al., 2013; CARBONERA; ABEL; SCHERER, 2015).

Uma vez que a abordagem de raciocínio híbrido proposta nesta tese (e apresentada na Seção 3.3) foi concebida para lidar com a tarefa de classificação, a aplicação desta abordagem na tarefa de interpretação de processos deposicionais envolve caracterizar esta tarefa (ou ao menos parte dela) como uma tarefa de classificação. Deste modo, na aplicação proposta, a interpretação do processo deposicional responsável por gerar uma

Figura 4.10: Diagrama de classes UML que representa o núcleo do modelo de conhecimento clássico adotado na aplicação para interpretação de processos deposicionais. Os três principais conceitos deste modelo são *Fácies Sedimentar*, *Estrutura Sedimentar* e *Processo Depositional*. A relação *tem estrutura sedimentar*, mantida entre uma instância  $f$  de *Fácies sedimentar* e uma instância  $e$  de *Estrutura Sedimentar*, indica que  $e$  é parte de  $f$ . A relação *gerada por*, mantida entre uma instância  $f$  de *Fácies Sedimentar* e uma instância  $p$  de *processo deposicional*, indica que  $f$  foi gerada por  $p$ .



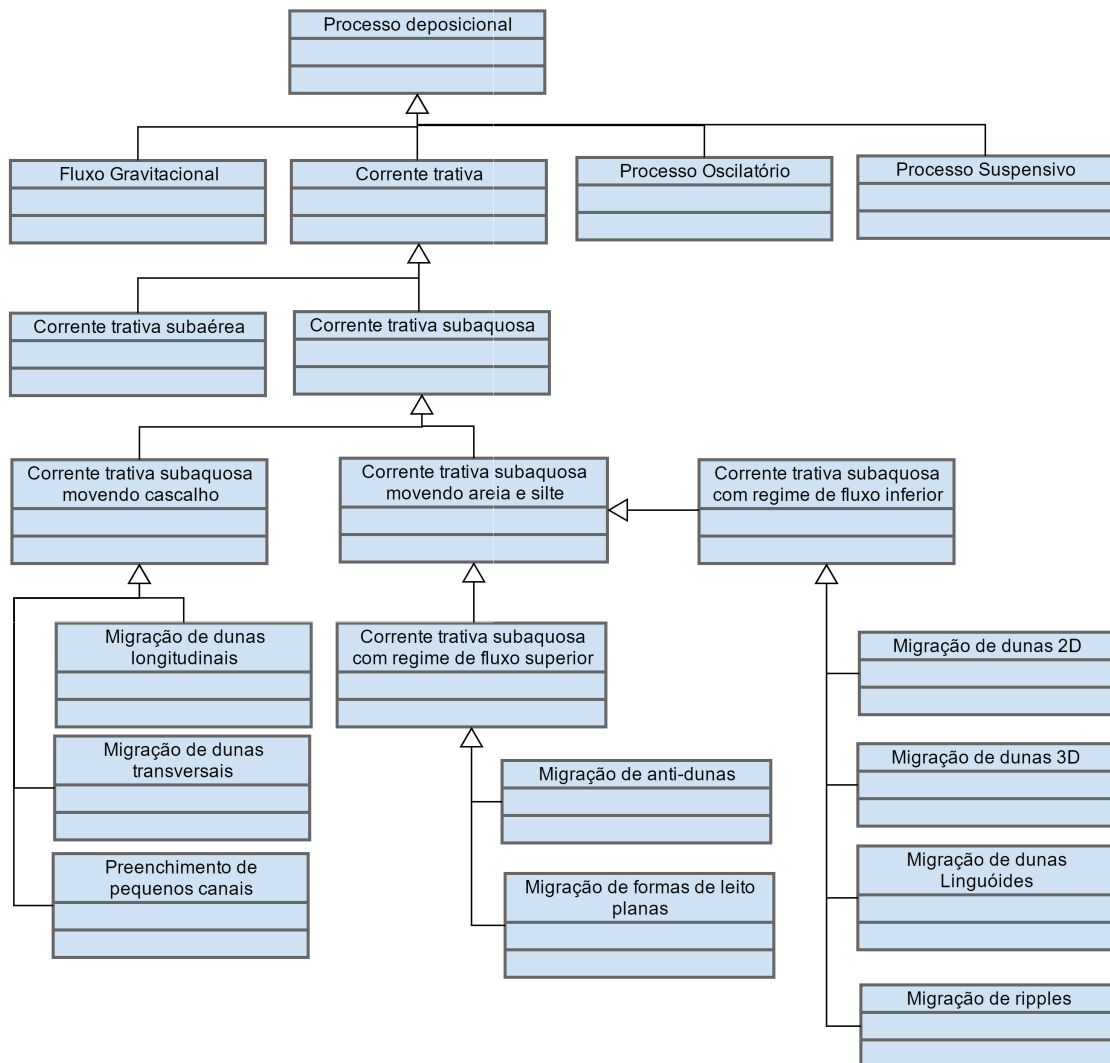
Fonte: Produzida pelo autor.

fácies envolve classificar uma determinada instância de fácies em uma classe que indica o seu processo deposicional gerador. Por esta razão, além das taxonomias apresentadas nas Figuras 4.11 e 4.12, o modelo de conhecimento clássico adotado pela aplicação também inclui uma taxonomia de *Fácies Sedimentares*. Cada tipo de processo deposicional na taxonomia de processos deposicionais possui uma subclasse de *Fácies Sedimentar* correspondente, de modo que as estruturas das duas taxonomias são equivalentes. A taxonomia de *Fácies Sedimentar* inclui conceitos como *Fácies Gerada Por Corrente Trativa*, *Fácies Gerada por Migração de Dunas 3D*, etc. Além disso, cada um desses conceitos é definido em termos de condições necessárias e suficientes para uma fácies ser considerada como sua instância. Estas definições são formuladas para atender aos critérios utilizados pelos especialistas para realizar a interpretação de processos deposicionais. Uma vez que estes critérios são baseados nas características visuais das fácies, as definições destas subclasses de *Fácies Sedimentares* são formuladas em termos dos 11 atributos de fácies sedimentares mencionados anteriormente e pela presença de certas estruturas deposicionais. Deste modo, a abordagem de raciocínio híbrido proposta nesta tese pode ser aplicada para classificar uma dada fácies sedimentar em uma das subclasses do conceito de *Fácies Sedimentar*.

Também é importante salientar que o modelo de conhecimento clássico adotado na aplicação também inclui regras que estabelecem relações entre cada subclasse de *Fácies Sedimentar* e o tipo de *Processo Depositional* correspondente, estabelecendo que uma fácies classificada em uma determinada subclasse de *Fácies Sedimentar* foi gerada por um processo deposicional de um determinado tipo. Por exemplo, uma destas regras é:

$$\forall f \forall p \text{ FaciesGeradaPorMigracaoDeDunas3D}(f) \wedge \text{geradaPor}(f, p) \rightarrow \text{MigracaoDeDunas3D}(p) \quad (4.1)$$

Figura 4.11: Representação da taxonomia de Processos Depositionais incluída no modelo de conhecimento clássico adotado na aplicação para interpretação de processos deposicionais.

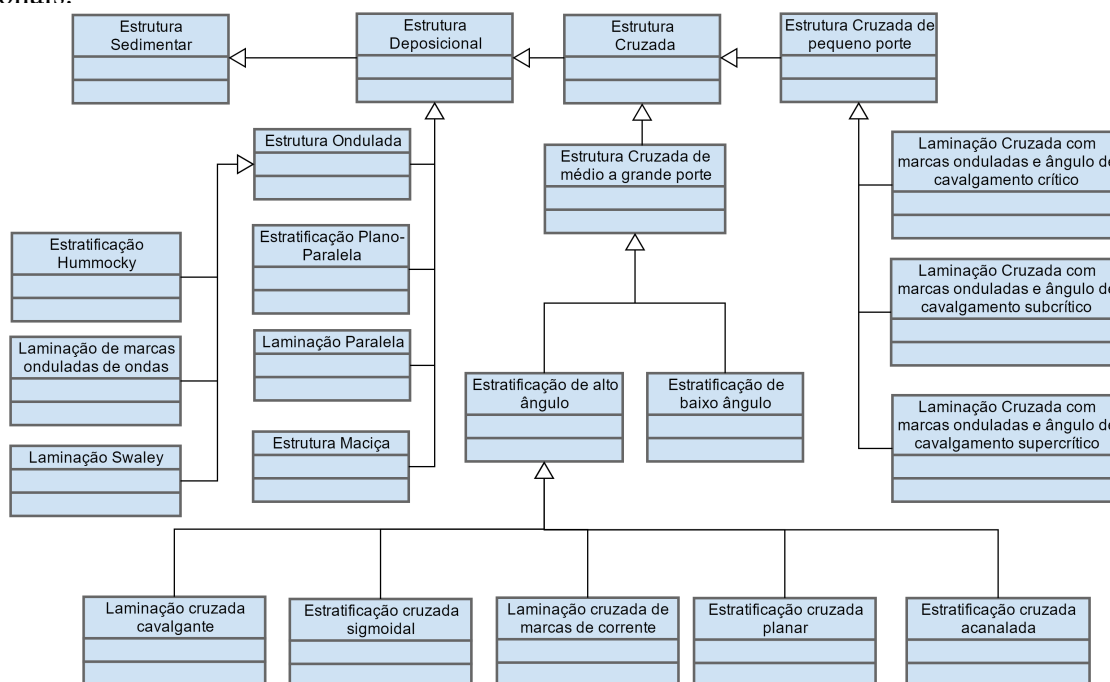


Fonte: Produzida pelo autor.

Ou seja, esta regra diz que para toda instância  $f$  e toda instância  $p$ , se  $f$  é uma *Fácies Gerada Por Migração de Dunas 3D* e  $f$  foi gerada por  $p$ , então  $p$  é uma instância de *Migração de Dunas 3D* (uma subclasse de processo deposicional). Assim, uma vez que uma dada fácies possui uma classificação, regras deste tipo permitem que seja possível determinar o tipo do processo deposicional que gerou a fácies.

Conforme já mencionado, o modelo de conhecimento discutido até o momento é responsável pela representação do componente clássico do conhecimento utilizado pela aplicação. No entanto, este constitui apenas um dos componentes de base de conhecimento. Uma outra parcela do conhecimento é representada através de exemplares e protótipo. Para representar protótipos e exemplares nesta aplicação, adotou-se um modelo de *vetor de características*, tal como o adotado em trabalhos como (GARCIA; CARBONERA; ABEL, 2013; CARBONERA; ABEL, 2014b; GARCIA; CARBONERA; ABEL,

Figura 4.12: Representação da taxonomia de Estruturas Sedimentares incluída no modelo de conhecimento clássico adotado na aplicação para interpretação de processos deposicionais.



Fonte: Produzida pelo autor.

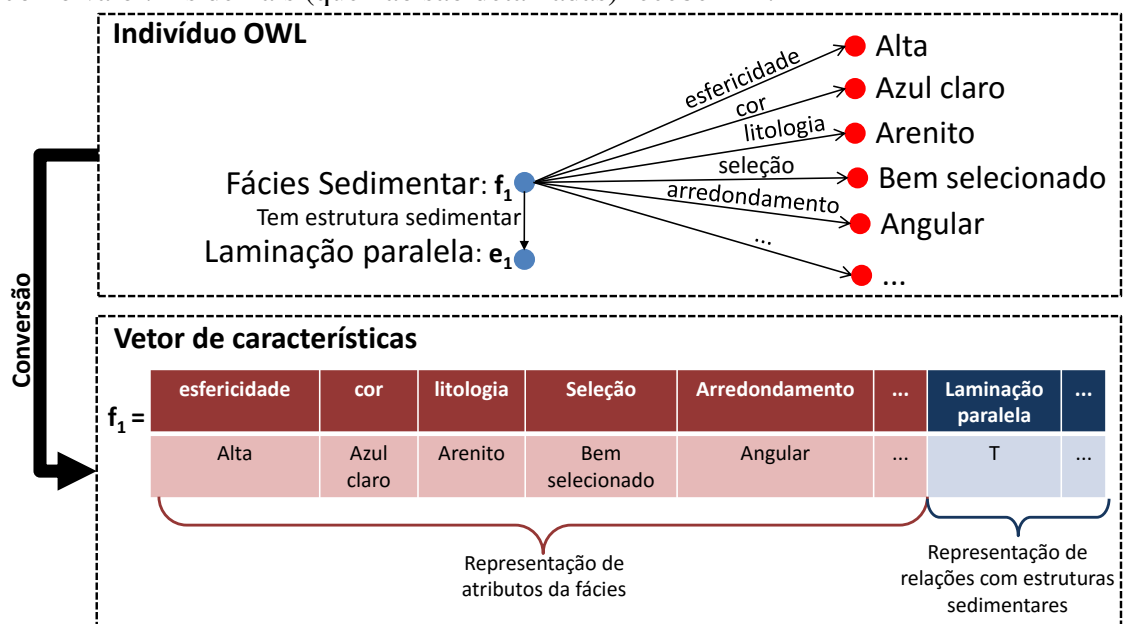
2014; CARBONERA; ABEL, 2015a). Deste modo, cada protótipo ou exemplar é representado por um vetor de  $n$  posições, cada qual representando o valor de uma determinada característica (em geral, atributos). Nesta aplicação específica, deve-se representar exemplares e protótipos do conceito de Fácies Sedimentar. Deste modo, os exemplares e protótipos são representados por vetores com até 26 posições<sup>3</sup>. Destas 26 posições, 11 representam valores para os 11 atributos de fácies sedimentares. As 15 posições remanescentes são utilizadas para representar as relações do exemplar ou protótipo com estruturas sedimentares. São consideradas 15 posições porque cada posição está relacionada a um dos tipos de estruturas sedimentares considerados no modelo de conhecimento adotado. Deste modo, cada uma destas 15 posições remanescentes representa se existe ou não uma relação *tem estrutura sedimentar* com umas das 15 subclasses mais específicas (folhas da taxonomia) de estruturas sedimentares. As 15 posições utilizadas para representar as relações com instâncias dos diferentes tipos de estruturas sedimentares podem assumir o valor  $T$  (de *true*), que indica que existe a relação, ou  $F$  (de *false*), que indica que não existe a relação. Desta forma, por exemplo, se o protótipo do conceito de Fácies Sedimentar indica que tipicamente, instâncias de fácies possuem uma relação *tem estrutura sedimentar* com instâncias de *Laminação paralela*, então a posição correspondente à estrutura *Laminação paralela*, no vetor de características que representa o protótipo, rece-

<sup>3</sup>Os vetores podem possuir menos posições, em função das necessidades de cada aplicação. Em determinadas aplicações, certas características podem ser irrelevantes e, devido a isso, as posições dos vetores que seriam necessárias para representar tais características poderiam não ser necessárias.

berá o valor  $T$ . É importante salientar que todos os atributos dos vetores de características resultantes são categoriais (possuem valores categoriais) ou booleanos (possuem valores booleanos). Além disso, para cada um dos atributos, também é adotado um valor especial, representado pelo símbolo  $?$ , que representa um valor desconhecido (ou não informado).

Nesta abordagem, os exemplares são selecionados dentre os indivíduos da base de conhecimento estendida, os quais são representados como indivíduos OWL na aplicação. Por este motivo, quando um exemplar é selecionado, é realizado um processo de conversão de um indivíduo OWL para um vetor de características. Além disso, um indivíduo OWL também é convertido para um vetor de características quando é necessário julgar sua similaridade com um protótipo ou exemplar. A Figura 4.13 ilustra um exemplo de processo de conversão de um indivíduo OWL (do banco de dados do usuário) para um vetor de características.

Figura 4.13: Exemplo de conversão de um indivíduo OWL para um vetor de características. As posições em azul do vetor representam os atributos do indivíduo  $f_1$ , enquanto demais posições representam as relações de  $f_1$  com diferentes tipos de estruturas sedimentares. Neste caso, apenas a posição correspondente à *Laminação paralela* recebe  $T$  como valor. As demais (que não são detalhadas) recebem  $F$ .



Fonte: Produzida pelo autor.

Conforme visto no Capítulo 3, a abordagem proposta utiliza uma função de distância/dissimilaridade para realizar seleção de exemplares e para calcular a MAC de um conceito para um dado indivíduo. Nesta aplicação, adotou-se a função de distância/dissimilaridade  $d: V \times V \rightarrow \mathbb{R}$ , adotada em (HUANG, 1997b), onde  $V$  representa o conjunto de todos os vetores de características considerados pela aplicação. A função  $d$  é formalizada da seguinte forma:

$$d(x, y) = \sum_{j=1}^f \theta(x_j, y_j) \quad (4.2)$$

onde

$$\theta(x_j, y_j) = \begin{cases} 1, & \text{se } x_j \neq y_j \\ 0, & \text{se } x_j = y_j \end{cases} \quad (4.3)$$

, onde  $x_j$  representa o valor do atributo  $j$  do vetor de características  $x \in V$ , e  $\theta$  é uma função que mapeia dois valores categoriais  $x_j$  e  $y_j$  em um valor  $v \in \{0, 1\}$  que representa a distância entre  $x$  e  $y$ , em relação ao atributo  $j$ . Além disso, a função adota  $f$  como o tamanho dos vetores de característica considerados, que, no caso desta aplicação específica é 26. Esta função foi selecionada por ser comumente utilizada em casos nos quais todos os atributos considerados são categoriais (ou booleanos). É importante notar que esta função também é capaz de lidar com os casos nos quais os valores dos atributos são desconhecidos (representados por  $?$ ). Assim, por exemplo, considerando-se um dado atributo  $j$ , se  $x_j = ?$  e  $y_j \neq ?$  (ou vice-versa), então  $\theta(x_j, y_j) = 1$ . Por outro lado, se  $x_j = ?$  e  $y_j = ?$ , então  $\theta(x_j, y_j) = 0$ .

No Capítulo 5 são discutidos os resultados de experimentos realizados para avaliar a aplicação descrita nesta Seção (e, indiretamente, a abordagem teórica que a suporta).





## 5 AVALIAÇÃO

Nesta Seção, serão discutidos os resultados de experimentos conduzidos para avaliar a aplicação da abordagem descrita na Seção 4.2 para interpretação automática de processos deposicionais. Os objetivos destes experimentos incluem:

- Comparar os resultados alcançados pela abordagem descrita neste trabalho com os resultados alcançados por uma abordagem puramente clássica de representação de conhecimento e raciocínio. O principal objetivo desta comparação é demonstrar as vantagens que a abordagem híbrida possui em relação à abordagem clássica.
- Analisar os efeitos dos parâmetros  $n$  e *limiar*, adotados pela estratégia de raciocínio híbrido na qualidade das classificações.
- Analisar os efeitos da seleção de exemplares realizada pelo algoritmo LDIS na qualidade das classificações.
- Comparar a qualidade das classificações resultantes da abordagem proposta, que combina informações sobre exemplares e protótipos para definir a *MAC*, com a qualidade das classificações de abordagens que definem versões alternativas da *MAC*, utilizando apenas protótipos ou exemplares.

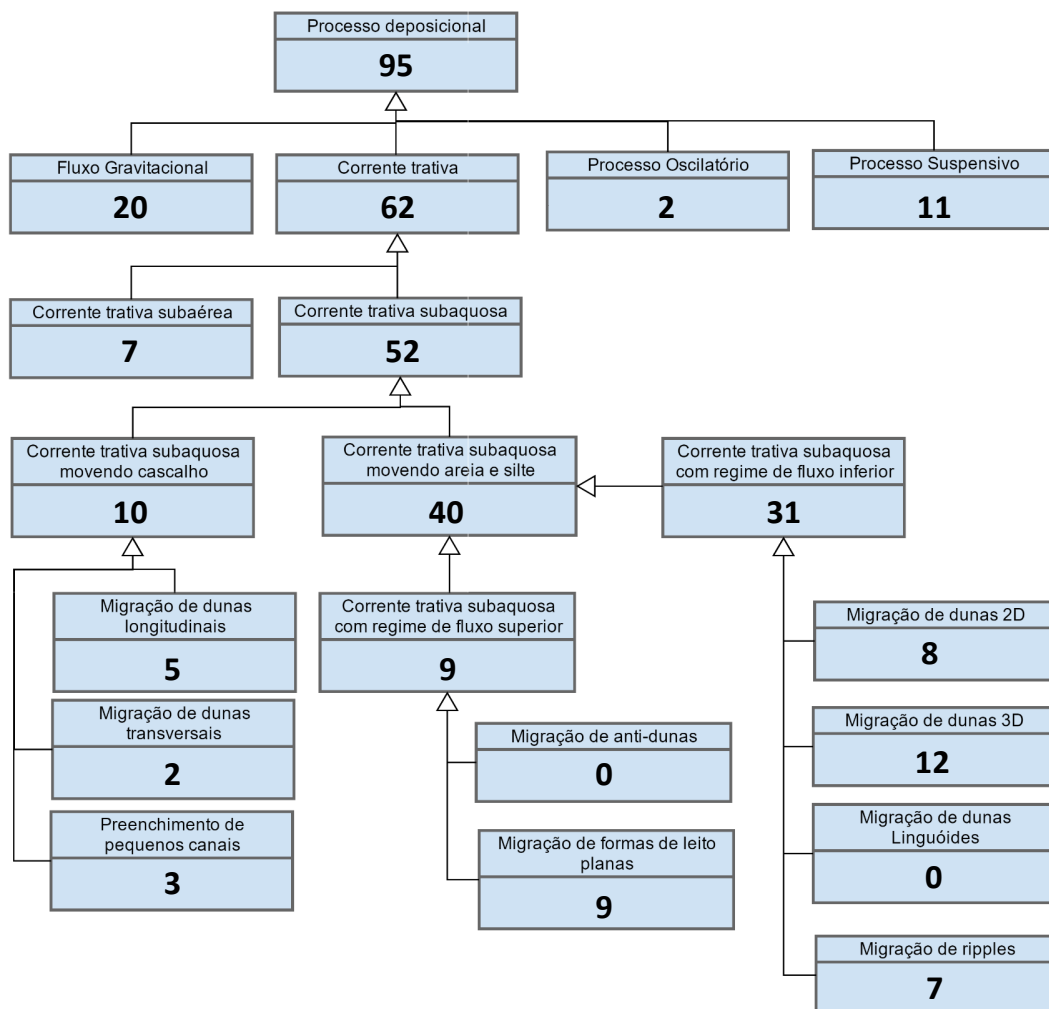
Nos experimentos conduzidos neste trabalho, a abordagem descrita na Seção 4.2 foi aplicada para interpretar fácies sedimentares reais, devidamente descritas por geólogos e disponíveis em relatórios técnicos de estudos geológicos acessíveis na literatura. O conjunto de dados utilizado nestes experimentos (e disponível<sup>1</sup> no Apêndice C) inclui as descrições de fácies provenientes de 9 corpos de rocha distintos, que foram descritos em (JO; CHOUGH, 2001; MORAIS et al., 2006; GHAZI; MOUNTNEY, 2009; ZECCHIN; MELLERE; RODA, 2006; SARKAR et al., 2012; JENSEN; PEDERSEN, 2010; MARTINS-NETO, 2000; KAAKINEN; LUNKKA, 2003; GANI; ALAM, 2004). O conjunto de dados resultante totaliza 95 descrições de fácies sedimentares, cada qual associada ao tipo do respectivo processo deposicional gerador.

Para elaborar o conjunto de dados utilizado nestes experimentos, inicialmente foi necessário selecionar casos significativos da literatura da Estratigrafia Sedimentar. Este processo foi realizado por um especialista na área. Foram selecionados casos que, na avaliação do especialista, estivessem corretamente descritos e que possuíssem características tipicamente encontradas na Estratigrafia Sedimentar. Uma vez selecionados os casos, que são descritos em *texto livre* na literatura da área, foi realizado um processo de *tradução* destas descrições, com suporte de um geólogo. Neste processo, a descrição original da fácies foi adequada à terminologia capturada pela ontologia de domínio adotada (apresentada na Seção 4.2 e detalhada no Apêndice B). Este processo resultou em um

<sup>1</sup>O conjunto de dados utilizado nestes experimentos também está disponível em formato ARFF em <[http://www.inf.ufrgs.br/~jcarbonera/?page\\_id=151](http://www.inf.ufrgs.br/~jcarbonera/?page_id=151)>

conjunto de 95 indivíduos da ontologia de domínio, cada qual representando uma instância do conceito de *Fácies Sedimentar* efetivamente descrito em função dos atributos que caracterizam este conceito e associado ao tipo do processo deposicional gerador (considerado como a interpretação de cada fácies). É importante notar que as interpretações relacionadas às fácies variam em termos de especificidade. A maior parte das interpretações constituem interpretações específicas, correspondendo às folhas da taxonomia de processos deposicionais (apresentada na Figura 4.11). No entanto, em diversos casos, a interpretação oferecida é mais geral, correspondendo a conceitos de nível intermediário na taxonomia de processos deposicionais.

Figura 5.1: Representação da quantidade de instâncias de cada tipo de processo deposicional presente no conjunto de dados. Cada classe  $C$  inclui todas as instâncias das classes que especializam  $C$ .



Fonte: Produzida pelo autor.

A Figura 5.1 apresenta a quantidade de instâncias de cada uma das classes presentes no conjunto de dados utilizado nos experimentos. Uma vez que um indivíduo que é instância de uma classe  $c$  também é instância de todas as classes que generalizam  $c$ , a interpretação de cada indivíduo de fácies sedimentar pode estar classificada em mais de

uma classe (sua classe específica e todas as superclasses). Por este motivo, por exemplo, uma vez que toda fácies sedimentar é necessariamente gerada por um subtipo de processo deposicional, a classe *Processo Depositional* inclui as 95 fácies sedimentares; que corresponde ao total de indivíduos do conjunto de dados. Também é importante notar que, em alguns casos, o total de instâncias de uma classe  $C$  é maior do que a soma das instâncias das classes que especializam  $C$ . Um exemplo deste fato ocorre com a classe *Corrente trativa*, que possui mais instâncias que as classes *Corrente trativa subaérea* e *Corrente trativa subaquosa*, que a especializam. Isto ocorre porque as interpretações de algumas das descrições foram estabelecidas níveis mais gerais, na fonte da qual ela foi obtida.

É importante também notar que o total de descrições de fácies não é uniformemente distribuído ao longo do conjunto de classes. Este fato também deve ser considerado na interpretação dos resultados, uma vez que esta característica dos dados tende a impactar negativamente na performance de classificadores baseados em instâncias (WANG; DING; HUANG, 2010). Além disso, algumas das classes possuem um número extremamente reduzido de instâncias, como é o caso das classes *Migração De Dunas Transversais*, *Processo Oscilatório* e *Preenchimento De Pequenos Canais*. Também espera-se que a existência de um número tão pequeno de instâncias impacte negativamente na performance da abordagem. Finalmente, também deve-se salientar que, conforme pode ser visto no Apêndice C, um número bastante elevado de instâncias do conjunto de dados adotado possui descrição imperfeita, uma vez que não possui valores atribuídos para diversos dos atributos. Conforme discutido nos Capítulos 3 e 1, quando faltam informações relacionadas às condições necessárias e suficientes estabelecidas pelas definições dos conceitos isso pode impactar negativamente nos resultados obtidos pelo raciocínio clássico.

Os experimentos realizados envolveram a interpretação de cada uma das descrições de fácies pela aplicação desenvolvida e a comparação da interpretação alcançada com a interpretação originalmente associada à fácies (tal como fora informada pela literatura). Nestes experimentos, consideramos que as interpretações oferecidas pela aplicação podem ser classificadas em 4 categorias, dependendo da sua relação com a interpretação original: *Interpretação correspondente*, *Interpretação mais geral*, *Interpretação mais específica* e *Interpretação incorreta*. Tais categorias são caracterizadas da seguinte forma.

1. **Interpretação correspondente:** Classe das interpretações oferecidas pela aplicação que correspondem exatamente às interpretações originais, conforme descritas na literatura. Por exemplo, se a interpretação determinada pela aplicação for *Migração de dunas 3D* e a interpretação original for também *Migração de dunas 3D*, então a interpretação determinada pelo sistema pode ser considerada uma *Interpretação correspondente* à interpretação original.

2. **Interpretação mais geral:** Classe das interpretações oferecidas pela aplicação que são mais gerais que as interpretações originais, conforme descritas na literatura. Por exemplo, se a interpretação determinada pela aplicação for *Corrente trativa subaquosa com regime de fluxo inferior* e a interpretação original for *Migração de dunas 3D*, então a interpretação determinada pelo sistema pode ser considerada uma *Interpretação mais geral* que a interpretação original.
3. **Interpretação mais específica:** Classe das interpretações oferecidas pela aplicação que são mais específicas que as interpretações originais, conforme descritas na literatura e que constituem interpretações corretas, do ponto de vista do especialista. Por exemplo, se a interpretação determinada pela aplicação for *Migração de dunas 3D* e a interpretação original for *Corrente trativa subaquosa com regime de fluxo inferior*, isto indica que a aplicação alcançou uma interpretação mais informativa do que a oferecida pela literatura. Por este motivo, este resultado deve ser analisado pelo especialista, que deve verificar se a interpretação oferecida pode ser sustentada. Em caso positivo, então a interpretação determinada pelo sistema pode ser considerada uma *Interpretação mais específica* que a interpretação original.
4. **Interpretação incorreta:** Classe das interpretações oferecidas pela literatura que não correspondem às interpretações oferecidas pela literatura, não constituem subclasses ou superclasses das interpretações oferecidas pela literatura, ou constituem subclasses das interpretações originais, mas a interpretação não pode ser considerada correta, do ponto de vista do especialista. Então, por exemplo, se a interpretação determinada pela literatura for *Corrente trativa subaquosa com regime de fluxo inferior* e a interpretação oferecida pela aplicação for qualquer classe de processos deposicionais que não seja subclasse ou superclasse de *Corrente trativa subaquosa com regime de fluxo inferior*, a interpretação oferecida pela aplicação pode ser considerada uma *Interpretação incorreta*. Isto também ocorreria se, por exemplo, a interpretação determinada pela aplicação for *Migração de dunas 3D* e o especialista não encontrar razões que sustentem tal interpretação.

As interpretações classificadas na categorias 1, 2 e 3 são consideradas *Interpretações satisfatórias*, enquanto as interpretações classificadas na categoria 4 são consideradas *Interpretações insatisfatórias*.

Neste trabalho foram realizados 4 experimentos. O primeiro experimento, apresentado na Seção 5.1, verifica os efeitos do parâmetro *limiar* nos resultados da aplicação. Já o segundo experimento, apresentado na Seção 5.2, verifica os efeitos do parâmetro *n* nos resultados da aplicação. O terceiro experimento, apresentado na Seção 5.3, verifica

os efeitos da aplicação do algoritmo LDIS nos resultados da aplicação. E, finalmente, o quarto experimento, apresentado na Seção 5.4, compara as classificações obtidas pela abordagem proposta, que combina protótipos e exemplares para definir a *MAC*, com as classificações obtidas por abordagens que utilizam apenas protótipos ou exemplares.

## 5.1 Experimento 1

No primeiro experimento realizado, buscou-se verificar os efeitos do parâmetro *limiar* nos resultados alcançados pela aplicação ao interpretar as 95 descrições de fácies do conjunto de dados adotado. Para isso, o valor de *limiar* foi variado no intervalo  $[0, 1]$  a uma taxa de 0, 1, e para cada valor de *limiar*, analisaram-se os resultados da interpretação realizada pela aplicação de cada fácies do conjunto de dados.

É importante salientar que foi adotado um esquema de validação cruzada *leave-one-out*. Deste modo, considerando-se *CD* como o conjunto total de dados com as 95 fácies, para cada fácies *f* interpretada pela aplicação, considerou-se o conjunto  $CD - \{f\}$  como o conjunto de treinamento. Neste contexto, o conjunto de treinamento é adotado como o conjunto  $\mathbb{I}$  (de *indivíduos*) da *base de conhecimento estendida* adotada pela aplicação. Deste conjunto são determinados os conjuntos  $\mathcal{P}$  (dos protótipos) e  $\mathcal{E}$  (dos exemplares).

Neste primeiro experimento considerou-se que, para um dado conceito  $c \in \mathbb{C}$ ,  $ex(c) = ext(c)$ . Ou seja, considerou-se que o conjunto de exemplares de um determinado conceito é exatamente idêntico ao conjunto de indivíduos que constitui a extensão deste conceito.

Também é importante destacar que, neste experimento, considerou-se  $n = 4$ , uma vez que, segundo os testes empíricos realizados, este valor resultou no menor número de *interpretações incorretas* entre os valores testados.

Além disso, neste experimento, os resultados obtidos pela aplicação desenvolvida (com base na abordagem híbrida para representação de conhecimento e raciocínio) também foram comparados com os resultados obtidos por uma abordagem completamente clássica. Neste contexto, o que se considerou como interpretações obtidas por uma abordagem clássica foram as classificações geradas diretamente por um raciocinador OWL (que, neste caso, foi o raciocinador Hermit<sup>2</sup> (SHEARER; MOTIK; HORROCKS, 2008)).

Os resultados deste experimento são apresentados na Tabela 5.1 e na Figura 5.2.

Os resultados apresentados na Tabela 5.1 demonstram que conforme o valor de *limiar* aumenta, diminui a quantidade das interpretações incorretas, das interpretações mais específicas e das interpretações correspondentes; enquanto aumenta a quantidade das interpretações mais gerais. Esta tendência fica ainda mais clara na Figura 5.2. Es-

<sup>2</sup><http://www.hermit-reasoner.com>

Tabela 5.1: Variação da quantidade de interpretações em cada classe obtidas pela abordagem híbrida proposta na tese, em função da variação dos valores do parâmetro *limiar*, adotando-se o parâmetro  $n = 4$ . Tais resultados também são comparados com as interpretações obtidas por uma abordagem puramente clássica.

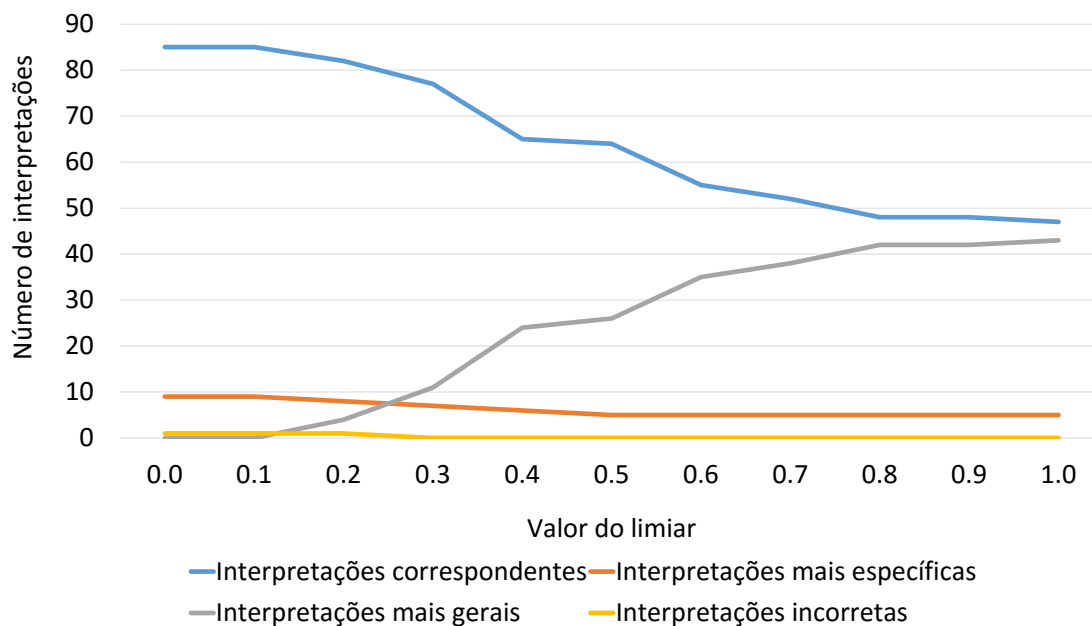
Interpretações		Abordagem híbrida											Abordagem clássica
		Valor do limiar											
		0.0	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9	1.0	
Satisfatórias	Correspondentes	85	85	82	77	65	64	55	52	48	48	47	46
	Mais específicas	9	9	8	7	6	5	5	5	5	5	5	5
	Mais gerais	0	0	4	11	24	26	35	38	42	42	43	44
Insatisfatórias	Incorretas	1	1	1	0	0	0	0	0	0	0	0	0

tes resultados sugerem que quanto menor o valor do parâmetro *limiar*, mais *arriscadas* tendem a ser as interpretações, e quanto maior o valor de *limiar*, mais *conservadoras* tendem a ser as interpretações. Também é possível constatar que quanto maior o valor adotado para o parâmetro *limiar*, mais os resultados se aproximam dos resultados alcançados pela *abordagem clássica* que, no contexto desta análise, pode ser vista como a abordagem que não assume nenhum risco nas interpretações.

Os resultados apresentados na Tabela 5.1 sugerem que, de modo geral, os resultados fornecidos pela abordagem híbrida tendem a ser mais informativos do que os resultados fornecidos pela abordagem puramente clássica. Isto é refletido em uma quantidade maior de interpretações correspondentes ou mais específicas. Por outro lado, nota-se também que a abordagem híbrida cometeu um erro de interpretação. Neste sentido, pode-se dizer que a abordagem híbrida é capaz de oferecer interpretações mais informativas, mas isto envolve um risco de obter-se interpretações incorretas (mesmo que em um número reduzido, como neste caso). Este *trade-off* é controlado pelo parâmetro *limiar*.

Neste experimento, constatou-se a ocorrência de interpretações incorretas em casos para os quais havia uma quantidade pequena de exemplares (da classe correta) para suportar uma interpretação satisfatória. Ou seja, em grande medida, a ocorrência de interpretações incorretas se deve ao fato da base de dados não garantir a representatividade estatística adequada de instâncias para todas as classes consideradas. Em geral, abordagens baseadas em similaridade, tais como a proposta nesta tese e as apresentadas em (COVER; HART, 1967; ALTMAN, 1992; WU; AI, 2008; MITANI; HAMAMOTO, 2006; ZENG; YANG; ZHAO, 2009; GOU; XIONG; KUANG, 2011) tendem a ser sensíveis à representatividade dos dados no conjunto de treinamento.

Figura 5.2: Gráfico ilustrando a variação da quantidade de interpretações em cada classe obtidas pela abordagem híbrida proposta na tese, em função do parâmetro *limiar*.



Fonte: Produzida pelo autor.

## 5.2 Experimento 2

No segundo experimento realizado, buscou-se verificar os efeitos do parâmetro  $n$  nos resultados alcançados pela aplicação ao interpretar as 95 descrições de fácies do conjunto de dados adotado. Para isso, o valor de  $n$  foi variado no intervalo  $[1, 10]$  a uma taxa de 1, e para cada valor de  $n$ , analisaram-se os resultados da interpretação realizada pela aplicação de cada fácies do conjunto de dados.

Neste experimento também foi adotado um esquema de validação cruzada *leave-one-out*, do mesmo modo que foi adotado no experimento anterior. Neste experimento também considerou-se que, para um dado conceito  $c \in \mathbb{C}$ ,  $ex(c) = ext(c)$ . Ou seja, considerou-se que o conjunto de exemplares de um determinado conceito é exatamente idêntico ao conjunto de indivíduos que constitui a extensão deste conceito.

Além disso, neste experimento, considerou-se  $limiar = 0.0$ . Este valor foi selecionado para induzir um comportamento mais arriscado na aplicação de interpretação. Este comportamento mais arriscado tende a gerar resultados de diferentes categorias (incluindo interpretações incorretas), o que permite evidenciar melhor os efeitos do parâmetro  $n$ .

Os resultados deste experimento são apresentados na Tabela 5.2.

Tabela 5.2: Variação da quantidade de interpretações em cada classe obtidas pela abordagem híbrida proposta na tese, em função da variação dos valores do parâmetro  $n$ , adotando-se o parâmetro  $limiar = 0.0$ .

Interpretações		Valor de $n$									
		1	2	3	4	5	6	7	8	9	10
Satisfatórias	Correspondentes	80	82	82	84	82	82	82	83	83	84
	Mais específicas	9	9	9	9	9	9	9	9	9	9
	Mais gerais	0	0	0	0	0	0	0	0	0	0
Insatisfatórias	Incorretas	6	4	4	2	4	4	4	3	3	2

Conforme discutido na Seção 4, o parâmetro  $n$  determina a quantidade dos exemplares de um conceito  $c \in \mathbb{C}$  mais próximos de  $i$  (onde  $i$  representa um indivíduo que se deseja classificar) que serão considerados para determinar a MAC de  $c$  em relação a  $i$ . Deste modo, quanto maior o valor de  $n$ , maior é a quantidade de informações relativas a exemplares que é considerada para determinar a MAC. No entanto, conforme pode ser visto na Tabela 5.2 não é possível afirmar que o aumento do valor de  $n$  implica em melhores resultados.

Nota-se que quando  $n = 1$ , o número de *interpretações incorretas* atinge o seu maior valor, dentre os valores de  $n$  considerados. Este resultado é esperado, visto que um único exemplar constitui pouca informação para determinar a classificação de uma nova instância. Neste caso, a classificação fica bastante suscetível à presença de ruído.

Nota-se também que, apesar do número de interpretações incorretas diminuir, com  $n = 2$ , esta tendência não é verificada à medida que o valor de  $n$  aumenta. As menores quantidades de interpretações incorretas são obtidas com  $n = 4$  e  $n = 10$ . Ou seja, não há uma correlação entre o valor de  $n$  e a qualidade dos resultados obtidos pelo abordagem. Estes resultados sugerem que o valor de  $n$  interage de modo complexo com a distribuição dos exemplares. Esta é uma característica comum a outras abordagens para classificação de indivíduos com base na proximidade (ou similaridade) destes indivíduos com outros indivíduos previamente classificados, tais como o algoritmo KNN (*k-nearest neighbor*) (ALTMAN, 1992; WU; AI, 2008). Assim, o valor ideal de  $k$  depende da tarefa e, por este motivo, ele deve ser empiricamente ajustado.

### 5.3 Experimento 3

No terceiro experimento, buscou-se analisar o efeito da seleção de instâncias com o algoritmo LDIS sobre a performance da aplicação. É importante notar que o algoritmo ASBI não foi considerado no experimento por não ser capaz de lidar com conceitos não disjuntos (e, conseqüentemente, indivíduos classificados em múltiplos conceitos).



Neste experimento também adotou-se um esquema de validação cruzada *leave-one-out*. No entanto, diferentemente dos experimentos anteriores, neste experimento *não* considerou-se o conjunto de exemplares de um determinado conceito como sendo idêntico ao conjunto de indivíduos que constitui a extensão deste conceito. Em vez disso, neste experimento, para cada conceito  $c \in \mathbb{C}$ , adotou-se  $ex(c)$  como sendo o conjunto de exemplares selecionados pelo algoritmo LDIS, a partir do conjunto de indivíduos que constitui a extensão de  $c$ . Deste modo, para verificar os efeitos do parâmetro  $k$  do algoritmo LDIS sobre a performance da aplicação, o parâmetro  $k$  foi variado no intervalo  $[1, 10]$  a uma taxa de 1, e para cada valor de  $k$  foi realizada a interpretação de todas as fácies sedimentares do conjunto de dados adotado.

Os parâmetros *limiar* e  $n$  foram fixados em 0 e 4 respectivamente. O parâmetro *limiar* foi fixado em 0 para forçar a aplicação a realizar interpretações mais arriscadas, viabilizando a obtenção de diversas categorias de resultados (interpretações precisas, incorretas, mais gerais e mais específicas). O parâmetro  $n$  foi fixado em 4 devido ao fato deste valor resultar em interpretações melhores, de acordo com os experimentos.

Além disso, é importante notar que o LDIS reduz a quantidade de exemplares disponíveis. Com isto em mente, para cada valor de  $k$ , mediu-se também o percentual de *redução média* do conjunto de exemplares. Esta medida é, para um dado valor de  $k$ , uma média da redução obtida pelo algoritmo LDIS ao selecionar exemplares do conjunto total de indivíduos, para a cada fácies sedimentar interpretada no esquema *leave-one-out*. Ou seja, para um dado valor do parâmetro  $k$  (utilizado pelo LDIS), todas as fácies do conjunto de dados são interpretadas. Para cada fácies  $f$  que é interpretada,  $f$  é retirada do conjunto de treinamento. A partir do conjunto de treinamento restante, o algoritmo LDIS seleciona os exemplares de cada conceito da base de conhecimento estendida. Neste ponto, é possível medir a *redução* do conjunto de exemplares. Como este processo é repetido para cada uma das fácies do conjunto de dados, ao fim do processo, é possível determinar a redução média, a partir das reduções individuais.

Os resultados deste experimento são apresentados na Tabela 5.3.

Tabela 5.3: Variação da quantidade de interpretações em cada classe obtidas pela abordagem híbrida proposta na tese, em função da variação dos valores do parâmetro  $k$  do algoritmo LDIS, adotando-se o parâmetro *limiar* = 0.0 e o parâmetro  $n$  = 4. Também são apresentadas as taxas de redução média do conjunto de exemplares obtidas pela aplicação do algoritmo LDIS, com cada valor de  $k$ , bem como os resultados das interpretações realizadas sem a utilização do algoritmo LDIS e os resultados das interpretações realizadas pela abordagem clássica.

Interpretações		Abordagem híbrida com LDIS										Abordagem híbrida sem LDIS	Abordagem clássica
		Valor do $k$ do LDIS											
		1	2	3	4	5	6	7	8	9	10		
Satisfatórias	Correspondentes	77	76	76	75	75	80	78	78	78	78	85	46
	Mais específicas	9	9	9	9	9	9	8	8	8	8	9	5
	Mais gerais	0	0	0	0	0	0	0	0	0	0	0	44
Insatisfatórias	Incorretas	9	10	10	11	11	6	9	9	9	9	1	0
Redução média do conjunto de exemplares		31%	46%	52%	52%	56%	58%	63%	65%	65%	65%	0%	0%

Os resultados do experimento, apresentados na Tabela 5.3 demonstram que, à medida que o valor de  $k$  aumenta, o percentual de redução média do conjunto de exemplares também aumenta. Este comportamento é esperado, uma vez que o parâmetro  $k$  determina o tamanho da *k-vizinhança parcial* considerada pelo LDIS. E, considerando-se que o algoritmo LDIS mantém apenas os indivíduos cuja densidade local é a maior dentre os indivíduos da sua *k-vizinhança parcial*, quanto maior o valor de  $k$ , menor tende a ser o número de indivíduos selecionados.

A partir dos resultados apresentados na Tabela 5.3, constatou-se que a melhor performance da aplicação foi atingida adotando-se  $k = 6$ . Constata-se também, a partir destes resultados, que não há uma correlação entre o parâmetro  $k$  e a qualidade da performance da abordagem. Ou seja, não é possível afirmar que o aumento do valor de  $k$ , sozinho, implica na degeneração da qualidade dos resultados obtidos pela aplicação, ou que a diminuição do valor de  $k$  implica em uma melhor qualidade das interpretações. Apesar do aumento do valor de  $k$  implicar na redução da quantidade de informações disponíveis para a aplicação utilizar para realizar interpretações, o impacto desta diminuição de informações não é necessariamente negativo, conforme os dados da Tabela 5.3 sugerem. Isto ocorre sobretudo porque, eventualmente, no processo de seleção de exemplares realizado pelo LDIS, podem ser descartados exemplares pouco representativos ou ruidosos, que prejudicam a interpretação.

Os dados da Tabela 5.3 também demonstram que, em comparação com os resultados obtidos pela abordagem híbrida sem utilizar o LDIS e com os resultados obtidos pela abordagem clássica, os resultados obtidos pela aplicação utilizando o LDIS apresentam uma maior incidência de interpretações incorretas. Isto ocorre devido à relação entre as características do conjunto de dados considerado e as suposições incorporadas pelo algoritmo LDIS. O algoritmo LDIS assume que a densidade local de um indivíduo é um indicativo da representatividade deste indivíduo para um dado conceito. No entanto, em alguns casos, a representatividade real de um indivíduo no domínio pode não estar efetivamente correlacionada com a densidade deste exemplar no conjunto de treinamento adotado. Nestes casos, um exemplar que seria realmente representativo no domínio poderia não ser selecionado pelo algoritmo LDIS. Ou seja, a representatividade dos exemplares selecionados pelo LDIS é afetada pelas características do conjunto de indivíduos adotado como conjunto de treinamento. O conjunto de treinamento deve, idealmente, ser estatisticamente representativo da variabilidade das instâncias do domínio.

No entanto, apesar da adoção do LDIS resultar em um aumento de interpretações incorretas realizadas pela aplicação, é importante notar que a aplicação também realizou um número maior de interpretações correspondentes e interpretações mais específicas, em comparação com a abordagem clássica. Além disso, o número de interpretações mais específicas alcançado, adotando-se o LDIS, é idêntico ao número de interpretações mais específicas alcançado sem adotar o LDIS. Mesmo quando considera-se as interpretações

correspondentes, adotando-se o LDIS, o número de interpretações nesta categoria é muito semelhante ao alcançado pela abordagem sem adotar o LDIS. Este resultado sugere que o LDIS é efetivo em selecionar exemplares representativos. Esta conclusão é reforçada pelos resultados dos experimentos discutidos no Apêndice A, onde verifica-se a performance dos algoritmos propostos na tarefa de *seleção de instâncias*.

#### 5.4 Experimento 4

Neste experimento, buscou-se verificar o impacto de se considerar as informações sobre exemplares e protótipos individualmente ou de modo combinado no cálculo da MAC. Deste modo, comparou-se a performance da abordagem proposta nesta tese, com a performance de versões modificadas desta abordagem, nas quais a MAC foi definida de modo alternativo. Em uma das versões alternativas, a *MAC* foi substituída pela noção de  $MAC_P$  (Medida de ajustamento conceitual baseada em protótipos), que é definida conforme estabelecido pelo Algoritmo 7. A noção de  $MAC_P$  é definida unicamente como o inverso da distância entre o indivíduo  $i$  que se deseja classificar e o protótipo do conceito  $c$ . Com isso, quanto mais similar (ou mais próximo) o indivíduo  $i$  é do protótipo de  $c$ , maior é o valor da MAC. Na outra versão alternativa, a MAC foi substituída pela noção de  $MAC_E$  (Medida de ajustamento conceitual baseada em exemplares), que é definida conforme estabelecido pelo Algoritmo 8. Nesta versão, o valor da  $MAC_E$  é definida unicamente como o inverso da distância entre o indivíduo  $i$  que se deseja classificar e o exemplar do conceito  $c$  mais próximo de  $i$ . Assim, quanto mais similar (ou mais próximo) o indivíduo  $i$  é do exemplar de  $c$  mais próximo de  $i$ , maior é o valor da MAC. O resultado da comparação pode ser visto na Tabela 5.4.

---

**Algoritmo 7:**  $MAC_P$  (Medida de ajustamento conceitual baseada em protótipos)

---

**Input:** Um dado conceito  $c \in \mathbb{C}$  e um dado indivíduo  $i \in \mathbb{I}$  que deve ser classificado.

**Output:** Um valor  $mac \in \mathbb{R}$  que indica o quanto o conceito  $c$  é adequado para classificar o indivíduo  $i$ , utilizando apenas informações sobre protótipos.

**begin**

$distancia \leftarrow d(i, prot(c));$

$MAC_P \leftarrow \begin{cases} 1, & distancia = 0 \\ \frac{1}{distancia}, & distancia > 0 \end{cases};$

**return**  $MAC_P$ ;

---

Segundo os resultados apresentados na Tabela 5.4 é possível constatar que a abordagem que combina informações sobre protótipos e exemplares resulta em um número maior de *interpretações correspondentes* e em um número menor de *interpretações incorretas*, em comparação com as abordagens que utilizam exclusivamente informações sobre protótipos ou exemplares.

**Algoritmo 8:**  $MAC_E$  (Medida de ajustamento conceitual)

---

**Input:** Um dado conceito  $c \in \mathbb{C}$  e um dado indivíduo  $i \in \mathbb{I}$  que deve ser classificado.  
**Output:** Um valor  $mac \in \mathbb{R}$  que indica o quanto o conceito  $c$  é adequado para classificar o indivíduo  $i$ , utilizando apenas informações sobre o exemplar mais próximo.

**begin**

$e \leftarrow$  exemplar de  $c$  mais próximo de  $i$ ;  
 $distancia \leftarrow d(i, e)$ ;

$MAC_E \leftarrow \begin{cases} 1, & distancia = 0 \\ \frac{1}{distancia}, & distancia > 0 \end{cases}$ ;

**return**  $MAC_E$ ;

---

Tabela 5.4: Comparação da performance de 4 abordagens: a abordagem proposta (adotando a  $MAC$ ), a abordagem que adota a  $MAC_P$ , a abordagem que adota a  $MAC_E$  e a abordagem clássica.

Interpretações		Abordagem com $MAC$	Abordagem com $MAC_E$	Abordagem com $MAC_P$	Abordagem clássica
Satisfatórias	Correspondentes	85	78	61	46
	Mais específicas	9	9	9	5
	Mais gerais	0	0	0	44
Insatisfatórias	Incorretas	1	8	25	0

Este experimento também oferece subsídios para comparar as decisões incorporadas na propostas desta tese, com as suposições assumidas nas abordagens propostas em (LIETO et al., 2015) e (FRANCONI; MAGNINI; STOCK, 1992). Neste sentido, é importante lembrar que, para classificar um dado indivíduo  $i$ , na abordagem proposta em (LIETO et al., 2015) utiliza-se unicamente a distância entre  $i$  com o seu exemplar mais próximo, enquanto na abordagem proposta em (FRANCONI; MAGNINI; STOCK, 1992) utiliza-se unicamente a distância entre  $i$  com o protótipo mais próximo. Ou seja, a abordagem proposta em (LIETO et al., 2015) adota uma abordagem semelhante à  $MAC_E$ , enquanto a abordagem proposta em (FRANCONI; MAGNINI; STOCK, 1992) adota uma abordagem semelhante à  $MAC_P$ .

## 5.5 Discussão dos resultados

De modo geral, os resultados dos três experimentos apresentados neste capítulo demonstram que a abordagem proposta nesta tese foi capaz de oferecer interpretações mais informativas que a abordagem puramente clássica. Além disso, constata-se também que a abordagem proposta nesta tese demonstrou-se mais robusta que a abordagem clássica nestes experimentos, uma vez que foi capaz de oferecer interpretações informativas, mesmo em situações nas quais os dados possuíam descrição imperfeita. Estes resultados corroboram a hipótese inicial assumida neste trabalho e discutida no Capítulo 1.

Os experimentos demonstram também, no entanto, que a abordagem incorpora um compromisso entre o grau da especificidade das interpretações alcançadas e o risco de se obter interpretações incorretas. Este compromisso pode ser ajustado através do parâmetro *limiar*, adotado pela estratégia de raciocínio híbrido. Quanto menor este valor, mais *arriscado* tende a ser o comportamento do processo de raciocínio, uma vez que mais informativas tendem a ser as interpretações obtidas pela abordagem, mas também maiores são as chances da abordagem obter interpretações incorretas. Por outro lado, quanto maior este valor, mais *conservador* tende a ser o comportamento do processo de raciocínio, aproximando-se do comportamento exibido por uma abordagem clássica. Neste caso, os riscos de se obter interpretações incorretas tendem a ser menores, mas as interpretações obtidas também tendem a ser menos informativas.

Também foi possível verificar que o algoritmo LDIS é capaz de selecionar exemplares representativos dos conceitos, uma vez que em todos os experimentos, a abordagem de interpretação utilizando o LDIS foi capaz de gerar interpretações mais específicas que as oferecidas pela abordagem clássica. No entanto, os experimentos também sugerem que a performance do algoritmo LDIS pode degenerar quando a distribuição dos dados de treinamento não reflete a distribuição estatística real dos objetos do domínio.

Constatou-se também que não há uma correlação entre o parâmetro  $n$ , da abordagem híbrida de raciocínio, e a qualidade dos resultados alcançados pela abordagem. O mesmo pode ser dito em relação ao parâmetro  $k$ , do algoritmo LDIS. Os valores destes parâmetros devem ser empiricamente ajustados, dependendo da tarefa, do domínio e do conjunto de dados de treinamento.

Durante os experimentos, não foram realizadas comparações experimentais entre os resultados da abordagem aqui proposta com a performance de outras abordagens híbridas, uma vez que tais abordagens possuem limitações, em relação à abordagem aqui proposta, do ponto de vista conceitual. Por exemplo, a abordagem proposta em (LIETO et al., 2015) é incapaz de lidar diretamente com atributos categoriais. Uma vez que o conjunto de dados adotado neste experimento possui apenas atributos categoriais, esta abordagem sequer poderia ser aplicada sobre tais dados. Além disso, é importante lembrar que, diferentemente da abordagem proposta nesta tese, a abordagem proposta em (LIETO et al., 2015) não é capaz de classificar indivíduos em múltiplas classes. A abordagem proposta em (FRANCONI; MAGNINI; STOCK, 1992), por outro lado, utiliza apenas protótipos para realizar os refinamentos, sem considerar exemplares. No entanto, trabalhos como (HUANG et al., 2010; DING et al., 2013; DOHNÁLEK et al., 2014) demonstram que abordagens baseadas em exemplares resultam em maior acurácia do que abordagens baseadas em protótipos.

No entanto, apesar de não serem realizadas comparações explícitas entre a abordagem aqui proposta e as abordagens propostas em (LIETO et al., 2015) e (FRANCONI; MAGNINI; STOCK, 1992), na Seção 5.4 realizou-se um experimento para investigar o impacto das suposições subjacentes a estas abordagens na qualidade das interpretações. Os resultados deste experimento sugerem que o uso combinado das informações sobre protótipos e exemplares resulta em uma performance superior em comparação com a performance das abordagens que utilizam exclusivamente informações sobre protótipos ou exemplares.

## 6 CONCLUSÃO

A Inteligência Artificial, enquanto área de pesquisa, investiga abordagens que permitam que agentes artificiais sejam capazes de se comportar de modo inteligente no ambiente. Na subárea da IA conhecida como *Representação de conhecimento e raciocínio*, assume-se que o comportamento inteligente pode ser alcançado dotando-se os agentes artificiais com uma representação do conhecimento sobre o mundo e com meios de processar tal conhecimento para estabelecer conclusões que possibilitem que o agente lide com o mundo de modo adequado.

Tradicionalmente, as abordagens desenvolvidas para representação de conhecimento e raciocínio na Inteligência Artificial adotam (mesmo que implicitamente) uma perspectiva *clássica* a respeito dos conceitos. Nesta perspectiva, um conceito é caracterizado por uma *definição*, que estabelece as *condições necessárias e suficientes* que uma determinada entidade deve atender para ser classificada pelo dado conceito.

No entanto, diversos trabalhos vêm demonstrando diversas limitações da perspectiva clássica dos conceitos, no que tange à sua capacidade de explicar a notória flexibilidade e robustez com que os seres humanos utilizam o conhecimento nas mais diversas tarefas cognitivas, tais como a percepção, a categorização, o planejamento, etc. Entre os alegados problemas da perspectiva clássica é possível citar a dificuldade de se encontrar definições em termos de condições necessárias e suficientes para a maioria dos conceitos; a falta de suporte e explicação para os chamados *efeitos de tipicidade* (marcados pela existência de instâncias de um dado conceito mais típicas que outras); dificuldades para lidar com conceitos que possuem limites vagos; dificuldades para explicar o fato de que, geralmente, em processos de classificação, as pessoas utilizam atributos que *não* participam da definição do conceito (não são necessários, no sentido definicional); ausência de suporte para julgamento de similaridade entre objetos, etc.

É interessante notar que estes problemas da perspectiva clássica dos conceitos também são herdados pelas abordagens de representação de conhecimento que adotam este paradigma. Por esta razão, nesta tese assumimos que, para viabilizar comportamentos inteligentes mais flexíveis e robustos em agentes artificiais, é necessário desenvolver abordagens de representação de conhecimento e raciocínio que transcendam essas limitações impostas pela perspectiva clássica. Com isso em mente, nesta tese, foi proposto um arcabouço híbrido, cognitivamente inspirado, para representação de conhecimento e raciocínio que visa superar algumas das limitações da perspectiva clássica dos conceitos. De modo geral, os resultados demonstraram que o arcabouço proposto é capaz de suportar a tarefa de classificação de um modo mais flexível que abordagens puramente clássicas. Este resultado concorda com a hipótese inicial assumida nesta tese.

Na Seção 6.1 serão discutidas as principais contribuições desta tese, enquanto na Seção 6.2 serão discutidas perspectivas para trabalhos futuros.

## 6.1 Principais contribuições

Esta tese possui 4 grupos de contribuições principais: uma concepção teórica acerca da representação de conceitos e a formalização desta concepção em um arcabouço para representação de conhecimento; uma abordagem híbrida para raciocínio que utiliza o arcabouço de representação proposto nesta tese; duas abordagens para seleção de exemplares; e uma aplicação para interpretação de processos deposicionais, que adota o arcabouço proposto. A seguir, cada uma dessas contribuições será brevemente discutida.

### 6.1.1 Abordagem híbrida para representação de conhecimento

Conforme previamente mencionado, uma das principais contribuições desta tese consiste em uma abordagem para representação de conhecimento que transcende as limitações da concepção clássica. O desenvolvimento desta abordagem envolveu o desenvolvimento de uma concepção teórica acerca da representação de conceitos e a posterior formalização de um arcabouço para representação de conhecimento, que é fundamentado pela concepção teórica desenvolvida e que pode ser utilizado de modo geral em aplicações diversas.

Inspirada em estudos realizados nas Ciências Cognitivas, a abordagem para representação de conhecimento desenvolvida nesta tese busca combinar características de três teorias cognitivas a respeito da representação de conceitos: a própria *teoria clássica*, a *teoria do protótipo* e a *teoria do exemplar*. Assim, do ponto de vista teórico, nesta tese assumimos que conceitos são entidades multifacetadas, que integram diferentes tipos de informação tais como: informações clássicas, que incluem uma definição que estabelece um conjunto de condições necessárias (embora possa incluir condições suficientes), bem como relações com outros conceito; um protótipo que define as características típicas de uma instância do conceito; e um conjunto de exemplares que representam a variabilidade de instâncias do conceito. Deste modo, a concepção teórica desenvolvida nesta tese pode ser vista como uma concepção híbrida, segundo os critérios adotados em (VICENTE; MANRIQUE, 2014).

Esta concepção teórica desenvolvida foi utilizada como fundamento para a formalização da noção de *base de conhecimento estendida*. Uma base de conhecimento estendida foi formalmente definida como uma tupla e um conjunto de axiomas que caracterizam formalmente os diferentes tipos de informação que constituem um conceito, bem como as relações entre esses diferentes tipos de informações.



Além desta abordagem permitir a realização de inferência de modo mais flexível, também é importante notar que é possível converter facilmente um modelo de conhecimento clássico em uma base de conhecimento estendida, sem a necessidade de se representar o modelo de conhecimento em um novo formalismo. Deste modo, esta abordagem promove o reuso de componentes de conhecimento.

### 6.1.2 Abordagem híbrida para raciocínio

Uma vez que uma abordagem para representação de conhecimento só é útil se houver um mecanismo capaz de processar as representações resultantes para estabelecer conclusões úteis, nesta tese também foi proposta uma abordagem híbrida para raciocínio que processa *bases de conhecimento estendidas*. No escopo desta tese, o foco do processo de raciocínio desenvolvido foi na tarefa de classificação, na qual é necessário decidir, dentre um conjunto de conceitos (ou classes), quais classificam um determinado indivíduo (ou de quais conceitos um determinado indivíduo é instância).

Esta abordagem de raciocínio permite classificar indivíduos mesmo em contextos nos quais as informações que descrevem o indivíduo estão incompletas, ou nas quais os conceitos não possuem definições completas (com todas as condições necessárias e suficientes). De modo geral, a abordagem utiliza o raciocínio clássico (baseado em condições necessárias e suficientes) para gerar uma primeira classificação e, caso esta classificação não seja a mais específica (e informativa) possível, a abordagem realiza ciclos de refinamento das classificações e de verificação de consistência das novas classificações obtidas. O ciclo se repete até que sejam alcançadas as interpretações mais específicas possíveis, ou não seja mais possível refinar as classificações. Nestes ciclos, o refinamento é realizado com base nas informações de exemplares e protótipos, enquanto a verificação de consistência é realizada utilizando-se raciocínio clássico, com base nas definições clássicas dos conceitos. Deste modo, esta abordagem de raciocínio assume uma postura mais arriscada, abrindo mão da segurança garantida pelo raciocínio puramente baseado em lógica, para alcançar classificações mais informativas.

A abordagem de raciocínio híbrido desenvolvida nesta tese aperfeiçoa abordagens previamente propostas na literatura, tais como as apresentadas em (FRANCONI; MAGNINI; STOCK, 1992; LIETO et al., 2015). Entre as principais diferenças da abordagem proposta nesta tese destaca-se a capacidade de classificar indivíduos em mais de um conceito, e a capacidade de utilizar de modo combinado definições clássicas, exemplares e protótipos para realizar a classificação.

### 6.1.3 Abordagens para seleção de exemplares

Conforme já mencionado, o arcabouço desenvolvido nesta tese inclui aspectos da *teoria do exemplar* (além de aspectos da teoria clássica e da teoria do protótipo). Deste modo, assume-se que a representação de um conceito inclui informações sobre seus exemplares. No entanto, existem diferentes modelos cognitivos de categorização que são fundamentados pela teoria do exemplar, e que adotam diferentes visões a respeito de quais das instâncias do conceito seriam consideradas como representativas (MURPHY, 2002; GOLDSTONE; KERSTEN, 2003). Conforme discutido em (SMITH; MINDA, 2002), alguns modelos assumem que *todas* as instâncias conhecidas pelo agente são adotadas como exemplares dos seus respectivos conceitos. No entanto, esta suposição não se ajusta ao *princípio da economia cognitiva*, que estabelece que os processos cognitivos tendem a minimizar esforços de processamento e recursos (COLMAN, 2015), porque a representação explícita de informações de todas as instâncias já encontradas por um sujeito seria muito dispendiosa, considerando os recursos cognitivos limitados que seres humanos possuem.

A concepção teórica desenvolvida nesta tese não estabelece nenhuma restrição a respeito de quais instâncias de um conceito devem ser consideradas como exemplares. Esta liberdade é desejável do ponto de vista de engenharia, uma vez que dependendo dos recursos computacionais à disposição, e dependendo das características da tarefa, diferentes restrições podem ser adotadas a respeito de quais instâncias serão consideradas como exemplares. Neste sentido, a teoria aqui desenvolvida é capaz de acomodar diferentes concepções sobre quais exemplares devem ser selecionados, incluindo a visão que considera que todas as instâncias são exemplares dos seus respectivos conceitos.

Por outro lado, uma vez que o conjunto de exemplares adotado pode impactar na eficiência do processamento de uma *base de conhecimento estendida*, nesta tese também foram propostas duas abordagens para seleção de exemplares. Inspiradas pelo princípio da economia cognitiva, ambas as abordagens visam selecionar um conjunto de exemplares relativamente menor que o conjunto total de indivíduos da base de conhecimento estendida, mas que capture informação suficientemente representativa das instâncias de cada conceito para auxiliar na classificação de novos indivíduos.

A primeira abordagem, chamada ASBI (*approach for selection of border instances*), assume que os exemplares mais representativos são as instâncias que constituem as bordas dos conceitos, isto é, as instâncias que são bastante similares a instâncias de outros conceitos. Assim, sob uma perspectiva geral, esta abordagem assume que as instâncias limítrofes dos conceitos incorporam informação suficiente sobre o conceito para permitir a classificação de novas instâncias, pois tais instâncias são capazes de demarcar a separação de conceitos semelhantes. Esta suposição é compartilhada por algumas abordagens para *seleção de instâncias* (na área de *Mineração de dados*), tais como a abordagem apresentada em (LEYVA; GONZÁLEZ; PÉREZ, 2015).

O algoritmo ASBI possui uma complexidade temporal de  $O(|\mathbb{I}|^2)$ , onde  $\mathbb{I}$  é o conjunto de instâncias a partir do qual o algoritmo seleciona os exemplares. Esta complexidade é equivalente à complexidade da maior parte dos algoritmos de seleção de instâncias disponíveis na literatura. Uma das limitações desta abordagem é o fato do algoritmo só ser aplicável a conceitos cujas extensões são conjuntos disjuntos. Ou seja, o algoritmo ASBI é incapaz de lidar com instâncias classificadas em múltiplos conceitos.

A segunda abordagem, chamada LDIS (*Local density-based instance selection*), assume que os exemplares mais representativos são as instâncias que possuem uma densidade mais alta que a das instâncias vizinhas. Neste contexto, a densidade de uma instância  $x$  é o oposto da média das distâncias entre  $x$  e todas as demais instâncias do mesmo conceito. Assim, para um dado valor  $k$  (escolhido pelo usuário), o algoritmo LDIS verifica para cada instância  $x$  se entre os seus  $k$  vizinhos mais próximos (considerando apenas instâncias do mesmo conceito que  $x$ ) há alguma instância mais densa que  $x$ . Caso não existam instâncias mais densas que  $x$ , o algoritmo LDIS seleciona esta instância como um exemplar. Adotando esta estratégia, não é necessário que o algoritmo LDIS realize uma *busca global*, como no caso do algoritmo ASBI, uma vez que é possível lidar com as instâncias de cada conceito separadamente, realizando *buscas locais*.

A complexidade temporal do algoritmo LDIS é equivalente a  $O(\sum_{c_i \in \mathbb{C}} |ext(c_i)|^2)$ , onde  $\mathbb{C}$  é o conjunto dos conceitos considerados. Ou seja, o tempo de execução do algoritmo LDIS aumenta proporcionalmente à soma dos quadrados das cardinalidades das extensões dos conceitos considerados. Deste modo, para a grande maioria dos casos, o algoritmo LDIS é mais eficiente que o algoritmo ASBI (e outros algoritmos que possuem a mesma complexidade temporal). Isto é consequência do fato do LDIS buscar exemplares de cada conceito separadamente, adotando uma estratégia de busca local.

Em experimentos realizados para avaliar a performance de ambos os algoritmos em uma tarefa de *seleção de instâncias*, verificou-se que ambos possuem uma performance superior ou comparável aos algoritmos no estado-da-arte. A performance, nesses experimentos, foi medida em termos de acurácia, taxa de redução do conjunto de dados e eficiência (dada pela multiplicação da acurácia pela taxa de redução). Além disso, também foi constatado que os tempos de execução do algoritmo ASBI são semelhantes aos de outros algoritmos no estado-da-arte. Já os tempos de execução do LDIS são significativamente menores que os dos demais algoritmos comparados.

#### 6.1.4 Aplicação para interpretação de processos deposicionais

Nesta tese também foi desenvolvida uma aplicação para interpretação automática de processos deposicionais, que utiliza o arcabouço para representação de conhecimento e raciocínio aqui proposto.

A interpretação de processos deposicionais é uma tarefa realizada no domínio da Estratigrafia Sedimentar (que é uma subárea da Geologia), que é fundamental para determinar interpretações de ambientes sedimentares e para determinar a localização de reservas de recursos minerais. A aplicação desenvolvida ilustra como o arcabouço desenvolvido nesta tese pode ser utilizado para desenvolver sistemas baseados em conhecimento mais robustos e flexíveis.

A aplicação desenvolvida foi avaliada em um conjunto de experimentos, utilizando-se um conjunto de dados reais, selecionados da literatura da área da Estratigrafia Sedimentar. Os resultados dos experimentos sugerem que o arcabouço proposto nesta tese possibilita que a aplicação ofereça interpretações mais informativas que as interpretações oferecidas por uma abordagem completamente clássica de representação de conhecimento e raciocínio.

Como resultado dos experimentos realizados, também foi constatado que o parâmetro *limiar*, utilizado pelo raciocínio híbrido, possui efeitos significativos sobre o comportamento do sistema. Quanto menor o valor de *limiar*, mais arriscadas (e mais informativas) tendem a ser as interpretações geradas; e quanto maior o valor, mais conservadoras tendem a ser as interpretações (aproximando-se do comportamento assumido pela abordagem clássica). No entanto, é importante salientar que quando a aplicação adota um comportamento mais arriscado, aumentam as chances de surgirem interpretações incorretas.

Além disso, em relação ao parâmetro *n*, utilizado pela abordagem de raciocínio híbrido para determinar o número de exemplares que são considerados para o cálculo da *medida de ajuste conceitual* (MAC), os experimentos sugerem que não há uma relação direta entre o seu valor e a qualidade das interpretações resultantes. Estes resultados sugerem que o valor de *n* interage de modo complexo com a distribuição dos exemplares. Esta é uma característica comum a outras abordagens para classificação de indivíduos com base na proximidade (ou similaridade) destes indivíduos com outros indivíduos previamente classificados, tais como o algoritmo KNN (*k-nearest neighbor*) (ALTMAN, 1992; WU; AI, 2008). Assim, o valor ideal de *k* depende da tarefa e, por este motivo, ele deve ser empiricamente ajustado.

Os experimentos realizados também permitiram determinar o impacto da adoção do algoritmo LDIS nas interpretações geradas pelo sistema. Estes experimentos sugerem que também não há uma relação direta entre o valor do parâmetro *k*, do algoritmo LDIS, e a qualidade das interpretações resultantes. Ou seja, apesar de, com o aumento do valor de *k*, o conjunto de exemplares selecionados pelo LDIS ser menor, não há necessariamente uma degradação na qualidade das interpretações do sistema. Isto ocorre porque, em alguns casos, com o aumento do valor de *k*, pode ocorrer a remoção de exemplares menos representativos (e possivelmente ruidosos), que prejudicavam a classificação.

Também foi possível constatar, através dos resultados experimentais, que a combinação de informações de exemplares e de protótipos para definir a *MAC* resultam em interpretações com qualidade superior às interpretações fornecidas por abordagens que utilizam versões alternativas da *MAC*, definidas unicamente em função de protótipos ou exemplares.

O desenvolvimento da aplicação também demandou um estudo da área da Estratigrafia Sedimentar. Este estudo envolveu a identificação do conhecimento relevante da área, bem como a compreensão da tarefa de interpretação de processos deposicionais. Este estudo teve como resultados uma extensão da ontologia de domínio previamente proposta em (LORENZATTI, 2009) e estendida em (CARBONERA, 2012), e um conjunto de dados interpretados de fácies sedimentares, que pode ser utilizado em trabalhos futuros. Estes resultados também podem ser considerados contribuições do trabalho realizado.

## 6.2 Perspectivas de trabalhos futuros

Esta tese partiu de hipóteses iniciais e buscou oferecer respostas adequadas para diversas questões que surgiram ao longo do seu desenvolvimento. No entanto, este trabalho também resulta em novas questões e novas possibilidades de investigação que podem ser explorados em trabalhos futuros.

Uma parte considerável desta tese envolveu a concepção teórica e a formalização da noção de *base de conhecimento estendida*, que assume que conceitos articulam diferentes tipos de informação, como definições, protótipos e exemplares. Ou seja, o foco principal da tese foi em estabelecer as bases conceituais e formais de uma abordagem híbrida para representação de conhecimento. No entanto, bases de conhecimento são atualizadas ao longo do tempo (pela inclusão, exclusão ou modificação de conceitos, ou inclusão e remoção de instâncias) e, nesta tese, não foram discutidos os aspectos relacionados aos mecanismos e processos envolvidos na atualização de bases de conhecimento estendidas. Deste modo, há toda uma gama de novas questões que surgem quando pensamos em um cenário onde o conhecimento muda. Estas questões motivam toda uma linha de investigações futuras.

Um dos pontos fortes de sistemas baseados em conhecimento, que adotam o paradigma clássico, é a possibilidade de oferecerem *justificativas e explicações* para as inferências realizadas. As inferências realizadas pela abordagem proposta nesta tese, no entanto, consideram também informações não clássicas, tais como informações relativas a protótipos e exemplares, processadas por meio de raciocínio baseado em similaridade. Este cenário coloca a necessidade de se investigar novas abordagens para elaboração de justificativas e explicações das inferências realizadas.

Em relação à noção de base de conhecimento estendida, é possível pensar em caracterizações alternativas dos seus elementos constituintes. Por exemplo, a noção de protótipo adotada neste trabalho a identifica ao centroide do conjunto de indivíduos de um dado conceito. Este centroide é determinado considerando-se os valores típicos de cada um dos atributos que caracterizam o conceito. Quando o atributo é numérico, o valor típico é considerado como sendo a média dos valores assumidos pelas instâncias do conceito. Quando o atributo é categorial, o valor típico é considerado o mais frequente (a moda). Em trabalhos futuros poderia ser investigado o impacto da adoção de caracterizações mais sofisticadas da noção de centroide (como a apresentada em (CHEN; WANG, 2013)) na abordagem desenvolvida. Outra possibilidade seria considerar, em vez de um, diversos protótipos. Esta possibilidade já é discutida em trabalhos como (GÄRDENFORS, 2004b; CAI; LEUNG; FU, 2008). O impacto da adoção desta abordagem poderia também ser investigado em trabalhos futuros.

Conforme discutido na Seção 3.3.2, a noção de base de conhecimento estendida é relativamente independente da abordagem híbrida de raciocínio para classificação desenvolvida nesta tese. Por este motivo, também é possível investigar em trabalhos futuros outras abordagens de raciocínio para classificação sobre bases de conhecimento estendidas. Também é possível investigar versões mais eficientes do algoritmo proposto.

Além disso, é importante ter em mente que a abordagem de raciocínio desenvolvida nesta tese teve como foco a tarefa de *classificação* de indivíduos. No entanto, serviços de raciocínio tradicionalmente oferecidos para bases de conhecimento puramente clássicas incluem, além da classificação, também a computação da subsunção, verificação de equivalência entre classes, etc. Deste modo, naturalmente surge a questão de como a informação adicional incorporada aos conceitos (como exemplares e protótipos), em bases de conhecimento estendidas, afetaria o modo como esses outros serviços de raciocínio tradicionalmente são realizados. Estas questões motivam todo um conjunto de investigações futuras.

Na Seção 3.4.2.1 apresentou-se o algoritmo ASBI, para seleção de exemplares. Discutiu-se nesta mesma seção que este algoritmo não foi projetado para lidar com bases de conhecimento em que os indivíduos são classificados em mais de um conceito. Esta constitui uma limitação fundamental do algoritmo. No entanto, é possível desenvolver uma versão do algoritmo capaz de lidar com os casos que são problemáticos para a versão atual. Este tópico também poderia ser investigado em trabalhos futuros.

Em relação ao algoritmo LDIS, apresentado na Seção 3.4.2.2, também existem diversas possibilidades de investigações futuras. A questão mais evidente diz respeito à possibilidade de se desenvolver uma abordagem para estimar automaticamente o melhor valor do parâmetro  $k$ , considerando-se a estrutura dos dados de entrada do algoritmo. Isto permitiria eliminar a necessidade de intervenção do usuário na seleção do valor deste parâmetro. Além disso, trabalhos futuros também poderiam investigar versões do LDIS

que, em vez apenas eliminar as instâncias que são menos densas em uma dada vizinhança, abstrair as instâncias da vizinhança em um centroide local. Uma abordagem deste tipo já não poderia mais ser vista como uma abordagem de *seleção* de exemplares, mas poderia gerar instâncias virtuais que abstraem as informações da vizinhança e que poderiam auxiliar na classificação de novas instâncias. A efetividade de abordagens deste tipo poderia ser investigada. Além disso, a boa performance (em termos de tempo de execução) do algoritmo LDIS encoraja novas pesquisas que investiguem a utilização de outras propriedades locais (além da densidade local) para selecionar instâncias. Uma possibilidade seria utilizar medidas de centralidade desenvolvidas no campo emergente da *Ciência das redes* (*Network Science*) (BRANDES et al., 2013). Também é possível aperfeiçoar o algoritmo LDIS, investigando-se outras caracterizações da densidade de um indivíduo, conforme a discussão levantada em (CARBONERA, 2016).

Tendo em mente as discussões realizadas em trabalhos como (CARBONERA; ABEL, 2014b; CARBONERA; ABEL, 2015a; CARBONERA; ABEL, 2014a), também é possível investigar abordagens para seleção de exemplares que realizem a busca de exemplares em *subespaços* do espaço total. Consideramos a hipótese de que os exemplares selecionados poderiam ser mais representativos de suas respectivas classes, se considerarmos que cada classe pode ser vista como um subespaço diferente e que, em cada subespaço as dimensões podem possuir diferentes pesos.

A discussão em (CARBONERA; ABEL, 2015e) levanta também a possibilidade de se utilizar a noção de base de conhecimento estendida para auxiliar na tarefa de alinhamento de ontologias. O que motiva a consideração desta possibilidade é o fato de que, diferentemente do que ocorre nas ontologias puramente clássicas, nas bases de conhecimento estendidas os conceitos integram também informações a respeito de protótipos e exemplares. Estas informações adicionais poderiam ser utilizadas em abordagens que buscam determinar a equivalência entre conceitos de ontologias diferentes. Uma vez que ontologias e bases de conhecimento estendidas são diferentes, para que seja possível utilizar tais informações adicionais no alinhamento de ontologias, antes tais ontologias deveriam ser convertidas em bases de conhecimento estendidas. Esta possibilidade também deveria ser investigada em trabalhos futuros.

Por fim, é importante notar que a aplicação desenvolvida nesta tese para interpretação de processos deposicionais constitui apenas um exemplo de aplicação do arcabouço aqui desenvolvido. Deste modo, existe a possibilidade de se investigar a aplicabilidade desta abordagem em outros domínios e tarefas. Alguns exemplos de tarefas em que, hipoteticamente, este arcabouço também poderia ser utilizado incluem o diagnóstico médico e interpretação de imagens.





## REFERÊNCIAS

- AGGARWAL, C. C. **Data Classification: Algorithms and Applications**. [S.l.]: CRC, 2014.
- ALTMAN, N. S. An introduction to kernel and nearest-neighbor nonparametric regression. **The American Statistician**, Taylor & Francis, v. 46, n. 3, p. 175–185, 1992.
- ANDRITSOS, P.; TSAPARAS, P. Categorical data clustering. In: **Encyclopedia of Machine Learning**. [S.l.]: Springer, 2010. p. 154–159.
- ANTONIOU, G.; HARMELEN, F. van. Handbook on ontologies. In: \_\_\_\_\_. 2. ed. [S.l.]: Epringer, 2009. (International Handbooks on Information Systems), chp. Web Ontology Language: OWL, p. 91 – 110.
- BAADER, F. **The description logic handbook: theory, implementation, and applications**. [S.l.]: Cambridge university press, 2003.
- BAADER, F.; HOLLUNDER, B. Embedding defaults into terminological knowledge representation formalisms. **Journal of Automated Reasoning**, Springer, v. 14, n. 1, p. 149–180, 1995.
- BAADER, F.; HORROCKS, I.; SATTLER, U. Handbook of ontologies. In: \_\_\_\_\_. [S.l.]: Springer, 2009. (International Handbooks on Information Systems), chp. Description Logics.
- BAADER IAN HORROCKS, U. S. F. Handbook of knowledge representation. In: \_\_\_\_\_. [S.l.]: Elsevier, 2008. chp. Description Logics.
- BAI, L. et al. A cluster centers initialization method for clustering categorical data. **Expert Systems with Applications**, Elsevier, v. 39, n. 9, p. 8022–8029, 2012.
- BARSALOU, L. W. Ad hoe categories. **Memory & cognition**, Springer, v. 11, n. 3, p. 211–227, 1983.
- BAYAT, B. et al. Requirements for building an ontology for autonomous robots. **Industrial Robot**, 2016. (in prelo).
- BERNARAS, A. et al. An ontology for fault diagnosis in electrical networks. In: IEEE. **Intelligent Systems Applications to Power Systems, 1996. Proceedings, ISAP'96., International Conference on**. [S.l.], 1996. p. 199–203.
- BERNERS-LEE, T. et al. The semantic web. **Scientific american**, New York, NY, USA:, v. 284, n. 5, p. 28–37, 2001.
- BOBILLO, F.; STRACCIA, U. Fuzzy description logics with general t-norms and datatypes. **Fuzzy Sets and Systems**, Elsevier, v. 160, n. 23, p. 3382–3402, 2009.
- BONATTI, P. A.; LUTZ, C.; WOLTER, F. Description logics with circumscription. In: **KR**. [S.l.: s.n.], 2006. p. 400–410.
- BRACHMAN, R.; LEVESQUE, H. **Knowledge representation and reasoning**. [S.l.]: Elsevier, 2004.

- BRANDES, U. et al. What is network science? **Network Science**, Cambridge Univ Press, v. 1, n. 01, p. 1–15, 2013.
- BRICKLEY, D.; GUHA, R. V. Rdf vocabulary description language 1.0: Rdf schema. 2004.
- BRIGHTON, H.; MELLISH, C. Advances in instance selection for instance-based learning algorithms. **Data mining and knowledge discovery**, Springer, v. 6, n. 2, p. 153–172, 2002.
- CAI, Y.; LEUNG, H.-f.; FU, A. W.-C. Multi-prototype concept and object typicality in ontology. In: **FLAIRS Conference**. [S.l.: s.n.], 2008. p. 470–475.
- CAISES, Y. et al. Combining instance selection methods based on data characterization: An approach to increase their effectiveness. **Information Sciences**, Elsevier, v. 181, n. 20, p. 4780–4798, 2011.
- CANTOR, N. et al. Psychiatric diagnosis as prototype categorization. **Journal of abnormal psychology**, American Psychological Association, v. 89, n. 2, p. 181, 1980.
- CARBONERA, J. L. **Raciocínio sobre conhecimento visual: Um estudo em Estratigrafia Sedimentar**. Dissertation (Master) — Universidade Federal do Rio Grande do Sul (UFRGS), 2012.
- CARBONERA, J. L. A novel approach for density-based instance selection. In: **Proceedings of the IEEE International Conference on Tools with Artificial Intelligence (ICTAI) 2016**. [S.l.: s.n.], 2016.
- CARBONERA, J. L.; ABEL, M. Categorical data clustering: a correlation-based approach for unsupervised attribute weighting. In: **Proceedings of ICTAI 2014**. [S.l.: s.n.], 2014.
- CARBONERA, J. L.; ABEL, M. An entropy-based subspace clustering algorithm for categorical data. In: **Proceedings of ICTAI 2014**. [S.l.: s.n.], 2014.
- CARBONERA, J. L.; ABEL, M. Cbk-modes: A correlation-based algorithm for categorical data clustering. In: **Proceedings of the 17th International Conference on Enterprise Information Systems**. [S.l.: s.n.], 2015.
- CARBONERA, J. L.; ABEL, M. A cognition-inspired knowledge representation approach for knowledge-based interpretation systems. In: **Proceedings of 17th ICEIS**. [S.l.: s.n.], 2015. p. 644–649.
- CARBONERA, J. L.; ABEL, M. A cognitively inspired approach for knowledge representation and reasoning in knowledge-based systems. In: **Proceedings of the 24th International Joint Conference on Artificial Intelligence (IJCAI 2015)**. [S.l.: s.n.], 2015.
- CARBONERA, J. L.; ABEL, M. A density-based approach for instance selection. In: **Proceedings of the 27th IEEE International Conference on Tools with Artificial Intelligence (ICTAI)**. [S.l.: s.n.], 2015.

CARBONERA, J. L.; ABEL, M. Extended ontologies: a cognitively inspired approach. In: **Proceedings of the 7th Ontology Research Seminar in Brazil (Ontobras)**. [S.l.: s.n.], 2015.

CARBONERA, J. L.; ABEL, M.; SCHERER, C. M. Visual interpretation of events in petroleum exploration: An approach supported by well-founded ontologies. **Expert Systems with Applications**, Elsevier, v. 42, p. 2749–2763, 2015.

CARBONERA, J. L. et al. Visual interpretation of events in petroleum geology. In: **Proceedings of ICTAI 2013**. [S.l.: s.n.], 2013.

CARBONERA, J. L. et al. Reasoning over visual knowledge. In: VIEIRA, R.; GUIZZARDI, G.; FIORINI, S. R. (Ed.). **Proceedings of Joint IV Seminar on Ontology Research in Brazil and VI International Workshop on Metamodels, Ontologies and Semantic Technologies**. [S.l.: s.n.], 2011. v. 776.

CARBONERA, J. L. et al. Defining positioning in a core ontology for robotics. In: **IEEE Intelligent Robots and Systems (IROS), 2013 IEEE/RSJ International Conference on**. [S.l.], 2013. p. 1867–1872.

CASTRO, M. R. d.; PERINOTTO, J. A. d. J.; CASTRO, J. C. d. Fácies, análise estratigráfica e evolução pós-glacial do membro triunfo/formação rio bonito, na faixa subaflorante do norte catarinense. **Revista Brasileira de Geociências**, v. 29, n. 4, p. 533–538, 1999.

CHANDRASEKARAN, B.; JOSEPHSON, J. R.; BENJAMINS, V. R. What are ontologies, and why do we need them? **IEEE Intelligent systems**, IEEE, n. 1, p. 20–26, 1999.

CHE, D.; SAFRAN, M.; PENG, Z. From big data to big data mining: challenges, issues, and opportunities. In: SPRINGER. **International Conference on Database Systems for Advanced Applications**. [S.l.], 2013. p. 1–15.

CHEN, L.; WANG, S. Central clustering of categorical data with automated feature weighting. In: CITESEER. **IJCAI**. [S.l.], 2013.

CHEN, M.; MAO, S.; LIU, Y. Big data: a survey. **Mobile Networks and Applications**, Springer, v. 19, n. 2, p. 171–209, 2014.

CHOU, C.-H.; KUO, B.-H.; CHANG, F. The generalized condensed nearest neighbor rule as a data reduction method. In: IEEE. **Pattern Recognition, 2006. ICPR 2006. 18th International Conference on**. [S.l.], 2006. v. 2, p. 556–559.

COLLINSON, J. Encyclopedia of geology. In: \_\_\_\_\_. [S.l.]: Elsevier, 2005. chp. Depositional Sedimentary Structures, p. 593–599.

COLMAN, A. M. **A dictionary of psychology**. [S.l.]: Oxford university press, 2015.

COVER, T. M.; HART, P. E. Nearest neighbor pattern classification. **Information Theory, IEEE Transactions on**, IEEE, v. 13, n. 1, p. 21–27, 1967.

DEZA, M. M.; DEZA, E. **Encyclopedia of distances**. [S.l.]: Springer, 2009.

DING, L.-H. et al. Distinct transcriptome profiles identified in normal human bronchial epithelial cells after exposure to  $\gamma$ -rays and different elemental particles of high z and energy. **BMC genomics**, BioMed Central Ltd, v. 14, n. 1, p. 372, 2013.

DOHNÁLEK, P. et al. Orthogonal matching pursuit based classifier for premature ventricular contraction detection. In: SPRINGER. **International Joint Conference SOCO13-CISIS13-ICEUTE13**. [S.l.], 2014. p. 201–210.

EVANS, J. S. B.; FRANKISH, K. E. **In two minds: Dual processes and beyond**. [S.l.]: Oxford University Press, 2009.

EVANS, J. S. B. T. Dual-processing accounts of reasoning, judgment and social cognition. **Annual Review of Psychology**, v. 59, p. 255–278, 2008.

EVANS, J. S. T. The heuristic-analytic theory of reasoning: Extension and evaluation. **Psychonomic Bulletin & Review**, v. 13, n. 3, p. 378–395, June 2006.

FÁVERA, J. C. D. **Fundamentos de Estratigrafia Moderna**. [S.l.]: EdUERJ, 2001.

FIORINI, S. R. et al. Extensions to the core ontology for robotics and automation. **Robotics and Computer-Integrated Manufacturing**, Elsevier, v. 33, p. 3–11, 2015.

FODOR, J.; LEPORE, E. The red herring and the pet fish: why concepts still can't be prototypes. **Cognition**, Elsevier, v. 58, n. 2, p. 253–270, 1996.

FODOR, J. A. et al. Against definitions. **Cognition**, Elsevier, v. 8, n. 3, p. 263–367, 1980.

FRANCONI, E.; MAGNINI, B.; STOCK, O. Prototypes in a hybrid language with primitive descriptions. **Computers & Mathematics with Applications**, Elsevier, v. 23, n. 6, p. 543–555, 1992.

GALINDO, C. et al. Robot task planning using semantic maps. **Robotics and autonomous systems**, Elsevier, v. 56, n. 11, p. 955–966, 2008.

GANI, M. R.; ALAM, M. M. Fluvial facies architecture in small-scale river systems in the upper dupi tila formation, northeast bengal basin, bangladesh. **Journal of Asian Earth Sciences**, Elsevier, v. 24, n. 2, p. 225–236, 2004.

GARCIA, L. F.; CARBONERA, J. L.; ABEL, M. Ontologias aplicadas ao problema de correlação litológica no domínio da geologia do petróleo. In: CEUR. **6th Seminar on Ontology Research in Brazil**. [S.l.], 2013. p. 203–208.

GARCIA, L. F.; CARBONERA, J. L.; ABEL, M. An ontology-based automatic approach for lithologic correlation. In: **Proceedings of ICTAI 2014**. [S.l.: s.n.], 2014.

GARCÍA, S.; LUENGO, J.; HERRERA, F. **Data preprocessing in data mining**. [S.l.]: Springer, 2015.

GÄRDENFORS, P. Conceptual spaces as a framework for knowledge representation. **Mind and Matter**, v. 2, p. 9–27, 2004.

GÄRDENFORS, P. **Conceptual spaces: The geometry of thought**. [S.l.]: The MIT Press, 2004.

- GÄRDENFORS, P. How to make the semantic web more semantic. In: VARZI, A. C.; VIEU, L. (Ed.). **Formal Ontology in Information Systems: proceedings of the third international conference (FOIS-2004)**. [S.l.]: IOS Press, 2004. (Frontiers in Artificial Intelligence and Applications, v. 114), p. 17–34.
- GATES, G. W. Reduced nearest neighbor rule. **IEEE TRansactions on Information Theory**, v. 18, n. 3, p. 431–433, 1972.
- GENESERETH, M. R.; NILSSON, N. J. **Logical Foundation of Artificial Intelligence**. [S.l.]: Morgan Kaufmann, 1987.
- GHAZI, S.; MOUNTNEY, N. P. Facies and architectural element analysis of a meandering fluvial succession: The permian warchha sandstone, salt range, pakistan. **Sedimentary Geology**, Elsevier, v. 221, n. 1, p. 99–126, 2009.
- GIORDANO, L. et al. A non-monotonic description logic for reasoning about typicality. **Artificial Intelligence**, Elsevier, v. 195, p. 165–202, 2013.
- GOLDSTONE, R. L.; KERSTEN, A. Handbook of psychology. In: \_\_\_\_\_. [S.l.]: Wiley, 2003. chp. Concepts and categorization, p. 607–630.
- GÓMES-PÉREZ, A.; FERNÁNDEZ-LÓPEZ, M.; CORCHO, O. **Ontological Engineering: with examples from the areas of knowledge management, e-commerce and the semantic web**. Londres: Springer, 2004. 403 p.
- GONNERMAN, C.; WEINBERG, J. M. Two uneliminated uses for concept: Hybrids and guides for inquiry. **Behavioral and Brain Sciences**, Cambridge Univ Press, v. 33, n. 2-3, p. 211–212, 2010.
- GOU, J.; XIONG, T.; KUANG, Y. A novel weighted voting for k-nearest neighbor rule. **Journal of Computers**, v. 6, n. 5, p. 833–840, 2011.
- GRAU, B. C. et al. Owl 2: The next step for owl. **Web Semantics: Science, Services and Agents on the World Wide Web**, Elsevier, v. 6, n. 4, p. 309–322, 2008.
- GROUP, W. O. W. Owl 2 web ontology language document overview. 2009.
- GUARINO, N. Understanding, building and using ontologies. **International Journal of Human-Computer Studies**, Elsevier, v. 46, n. 2, p. 293–310, 1997.
- HAMIDZADEH, J.; MONSEFI, R.; YAZDI, H. S. Irahc: Instance reduction algorithm using hyperrectangle clustering. **Pattern Recognition**, Elsevier, v. 48, n. 5, p. 1878–1889, 2015.
- HART, P. E. The condensed nearest neighbor rule. **IEEE TRansactions on Information Theory**, v. 14, p. 515–516, 1968.
- HASHEM, I. A. T. et al. The rise of big data on cloud computing: Review and open research issues. **Information Systems**, Elsevier, v. 47, p. 98–115, 2015.
- HORROCKS, I.; PATEL-SCHNEIDER, P. F.; HARMELEN, F. V. From shiq and rdf to owl: The making of a web ontology language. **Web semantics: science, services and agents on the World Wide Web**, Elsevier, v. 1, n. 1, p. 7–26, 2003.

HUANG, J. et al. Genomic indicators in the blood predict drug-induced liver injury. **The pharmacogenomics journal**, Nature Publishing Group, v. 10, n. 4, p. 267–277, 2010.

HUANG, Z. A fast clustering algorithm to cluster very large categorical data sets in data mining. In: CITESEER. **DMKD**. [S.l.], 1997. p. 0.

HUANG, Z. A fast clustering algorithm to cluster very large categorical data sets in data mining. In: CITESEER. **DMKD**. [S.l.], 1997. p. 0.

JAGADISH, H. V. et al. idistance: An adaptive b+-tree based indexing method for nearest neighbor search. **ACM Transactions on Database Systems (TODS)**, ACM, v. 30, n. 2, p. 364–397, 2005.

JENSEN, M. A.; PEDERSEN, G. K. Architecture of vertically stacked fluvial deposits, atane formation, cretaceous, nuussuaq, central west greenland. **Sedimentology**, Wiley Online Library, v. 57, n. 5, p. 1280–1314, 2010.

JO, H.; CHOUGH, S. Architectural analysis of fluvial sequences in the northwestern part of kyongsang basin (early cretaceous), se korea. **Sedimentary Geology**, v. 144, p. 307–334, 2001.

JOHNSTON, B. et al. Ontology based object categorization for robots. In: SPRINGER. **International Conference on Practical Aspects of Knowledge Management**. [S.l.], 2008. p. 219–231.

JORGE, V. A. et al. Exploring the iee ontology for robotics and automation for heterogeneous agent interaction. **Robotics and Computer-Integrated Manufacturing**, Elsevier, v. 33, p. 12–20, 2015.

KAAKINEN, A.; LUNKKA, J. P. Sedimentation of the late miocene bahe formation and its implications for stable environments adjacent to qinling mountains in shaanxi, china. **Journal of Asian Earth Sciences**, Elsevier, v. 22, n. 1, p. 67–78, 2003.

KAISLER, S. et al. Big data: issues and challenges moving forward. In: IEEE. **System Sciences (HICSS), 2013 46th Hawaii International Conference on**. [S.l.], 2013. p. 995–1004.

KALFOGLOU, Y.; SCHORLEMMER, M. Information-flow-based ontology mapping. In: **On the move to meaningful internet systems 2002: CoopIS, DOA, and ODBASE**. [S.l.]: Springer, 2002. p. 1132–1151.

KASNECI, G. et al. Naga: Searching and ranking knowledge. In: IEEE. **2008 IEEE 24th International Conference on Data Engineering**. [S.l.], 2008. p. 953–962.

KATAL, A.; WAZID, M.; GOUDAR, R. Big data: issues, challenges, tools and good practices. In: IEEE. **Contemporary Computing (IC3), 2013 Sixth International Conference on**. [S.l.], 2013. p. 404–409.

KEIL, F. Hybrid vigor and conceptual structure. **Behavioral and Brain Sciences**, Cambridge Univ Press, v. 33, n. 2-3, p. 215–216, 2010.

KLYNE, G.; CARROLL, J. J. Resource description framework (rdf): Concepts and abstract syntax. 2006.

- LEYVA, E.; GONZÁLEZ, A.; PÉREZ, R. Three new instance selection methods based on local sets: A comparative study with several approaches from a bi-objective perspective. **Pattern Recognition**, Elsevier, v. 48, n. 4, p. 1523–1537, 2015.
- LIETO, A. **Non classical concept representation and reasoning in formal ontologies**. Thesis (PhD) — Università degli studi di Salerno, 2012.
- LIETO, A. et al. A common-sense conceptual categorization system integrating heterogeneous proxytypes and the dual process of reasoning. In: AAAI PRESS. **Proceedings of the 24th International Conference on Artificial Intelligence**. [S.l.], 2015. p. 875–881.
- LIM, G. H.; SUH, I. H.; SUH, H. Ontology-based unified robot knowledge for service robots in indoor environments. **IEEE Transactions on Systems, Man, and Cybernetics-Part A: Systems and Humans**, IEEE, v. 41, n. 3, p. 492–509, 2011.
- LIN, W.-C. et al. Learning to detect representative data for large scale instance selection. **Journal of Systems and Software**, Elsevier, v. 106, p. 1–8, 2015.
- LIU, H.; MOTODA, H. On issues of instance selection. **Data Mining and Knowledge Discovery**, Springer, v. 6, n. 2, p. 115–130, 2002.
- LORENZATTI, A. **Ontologia para Domínios Imagísticos: Combinando Primitivas Textuais e Pictóricas**. Dissertation (Master) — UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL, 2009.
- LOZANO, J. et al. Ontology view extraction: an approach based on ontological meta-properties. In: **Proceedings of IEEE international conference on tools with artificial intelligence 2014**. [S.l.: s.n.], 2014.
- LUKASIEWICZ, T. Expressive probabilistic description logics. **Artificial Intelligence**, Elsevier, v. 172, n. 6, p. 852–883, 2008.
- MACQUEEN, J. et al. Some methods for classification and analysis of multivariate observations. In: OAKLAND, CA, USA. **Proceedings of the fifth Berkeley symposium on mathematical statistics and probability**. [S.l.], 1967. v. 1, n. 14, p. 281–297.
- MARGOLIS, E.; LAURENCE, S. Concepts. In: ZALTA, E. N. (Ed.). **The Stanford Encyclopedia of Philosophy**. Spring 2014. [S.l.: s.n.], 2014.
- MARKMAN, E. M. **Categorization and naming in children: Problems of induction**. [S.l.]: Mit Press, 1991.
- MARTINS-NETO, M. A. Tectonics and sedimentation in a paleo/mesoproterozoic rift-sag basin (espinhaço basin, southeastern brazil). **Precambrian Research**, Elsevier, v. 103, n. 3, p. 147–173, 2000.
- MCCARTHY, J. Circumscription – a form of non-monotonic reasoning. **Artificial Intelligence**, n. 13, p. 27 – 39, 1980.
- MCGUINNESS, D. L.; HARMELEN, F. V. et al. Owl web ontology language overview. **W3C recommendation**, v. 10, n. 10, p. 2004, 2004.

- MEDIN, D. L.; SCHAFFER, M. M. Context theory of classification learning. **Psychological review**, American Psychological Association, v. 85, n. 3, p. 207, 1978.
- MEDIN, D. L.; SMITH, E. E. Concepts and concept formation. **Annual review of psychology**, Annual Reviews 4139 El Camino Way, PO Box 10139, Palo Alto, CA 94303-0139, USA, v. 35, n. 1, p. 113–138, 1984.
- MENDOZA, R.; WILLIAMS, M.-A. Ontology based object categorisation for robots. In: AUSTRALIAN COMPUTER SOCIETY, INC. **Proceedings of the 2005 Australasian Ontology Workshop-Volume 58**. [S.l.], 2005. p. 61–67.
- MILLER, G. A.; JOHNSON-LAIRD, P. N. **Language and perception**. [S.l.]: Belknap Press, 1976.
- MINSKY, M. The psychology of computer vision. In: \_\_\_\_\_. [S.l.]: McGraw-Hill, 1975. chp. A framework for representing knowledge, p. 211–277.
- MITANI, Y.; HAMAMOTO, Y. A local mean-based nonparametric classifier. **Pattern Recognition Letters**, Elsevier, v. 27, n. 10, p. 1151–1159, 2006.
- MOODLEY, K.; MEYER, T.; SATTLER, U. Practical defeasible reasoning for description logics. In: **STAIRS**. [S.l.: s.n.], 2014. p. 191–200.
- MORAIS, R. M. O. d. et al. Fácies sedimentares e ambientes deposicionais associados aos sepósitos da formação barreiras no estado do rio de janeiro. **Geologia USP. Série Científica**, Instituto de Geociências, Universidade de São Paulo, v. 6, n. 2, p. 19–30, 2006.
- MOTIK, B. et al. Owl 2 web ontology language: Profiles. **W3C recommendation**, v. 27, p. 61, 2009.
- MURPHY, G. L. **The big book of concepts**. [S.l.]: MIT press, 2002.
- NEWELL, A. The knowledge level. **Artificial Intelligence**, v. 28, n. 2, p. 87–127, 1982.
- NIKOLAIDIS, K.; GOULERMAS, J. Y.; WU, Q. A class boundary preserving algorithm for data condensation. **Pattern Recognition**, Elsevier, v. 44, n. 3, p. 704–715, 2011.
- OSHERSON, D. N.; SMITH, E. E. On the adequacy of prototype theory as a theory of concepts. **Cognition**, Elsevier, v. 9, n. 1, p. 35–58, 1981.
- PALMERI, T. J.; NOELLE, D. C. The handbook of brain theory and neural networks. In: \_\_\_\_\_. Second. [S.l.]: THE MIT PRESS, 2003. chp. Concept Learning, p. 252–256.
- PICCININI, G.; SCOTT, S. Splitting concepts\*. **Philosophy of Science**, JSTOR, v. 73, n. 4, p. 390–409, 2006.
- PRESS, F. et al. **Para entender aTerra. 4.ed.** [S.l.]: Bookman,, 2004.
- PRESTES, E. et al. Towards a core ontology for robotics and automation. **Robotics and Autonomous Systems**, Elsevier, v. 61, n. 11, p. 1193–1204, 2013.
- PROTHERO, D. R. **Interpreting the Stratigraphic Record**. New York: W.H. Freeman and Company, 1991. 410 p.



QUILLAN, R. **A notation for representing conceptual information: an application to semantics and mechanical English paraphrasing**. [S.l.]: Systems Development Corp., 1963.

QUILLIAN, M. R. Semantic information processing. In: \_\_\_\_\_. [S.l.]: MIT Press, 1968. chp. Semantic memory, p. 227–270.

ROSCH, E. Cognitive reference points. **Cognitive psychology**, Elsevier, v. 7, n. 4, p. 532–547, 1975.

ROSCH, E. Cognitive representations of semantic categories. **Journal of experimental psychology: General**, American Psychological Association, v. 104, n. 3, p. 192, 1975.

ROSCH, E. Cognition and categorization. In: \_\_\_\_\_. **Cognition and Categorization**. Hillsdale (NJ), USA: Lawrence Erlbaum Associates, 1978. chp. Principles of Categorization, p. 27–48. Reprinted in *Readings in Cognitive Science. A Perspective from Psychology and Artificial Intelligence*, A. Collins and E.E. Smith, editors, Morgan Kaufmann Publishers, Los Altos (CA), USA, 1991.

ROSCH, E. Principles of categorization. **Concepts: core readings**, MIT Press, p. 189–206, 1999.

ROSCH, E.; MERVIS, C. B. Family resemblances: Studies in the internal structure of categories. **Cognitive psychology**, Elsevier, v. 7, n. 4, p. 573–605, 1975.

ROSCH, E.; SIMPSON, C.; MILLER, R. S. Structural bases of typicality effects. **Journal of Experimental Psychology: Human perception and performance**, American Psychological Association, v. 2, n. 4, p. 491, 1976.

ROSCH, E. H. Natural categories. **Cognitive psychology**, Elsevier, v. 4, n. 3, p. 328–350, 1973.

SARKAR, S. et al. Stratigraphic architecture of the sonia fluvial interval, india in its precambrian context. **Precambrian Research**, Elsevier, v. 214, p. 210–226, 2012.

SCARANTINO, A. Evidence of coordination as a cure for concept eliminativism. **Behavioral and Brain Sciences**, Cambridge University Press, v. 33, n. 2-3, p. 223, 2010.

SCHLENOFF, C. et al. Using ontologies to aid navigation planning in autonomous vehicles. **The knowledge engineering review**, Cambridge Univ Press, v. 18, n. 03, p. 243–255, 2003.

SCHREIBER, G. et al. **Knowledge Engineering and Management: The CommonKADS Methodology**. 2nd ed.. ed. Cambridge, Mass.: MIT Press, 1999. ISBN 0-262-19300-0.

SHADBOLT, N.; BERNERS-LEE, T.; HALL, W. The semantic web revisited. **IEEE intelligent systems**, IEEE, v. 21, n. 3, p. 96–101, 2006.

SHEARER, R.; MOTIK, B.; HORROCKS, I. Hermit: A highly-efficient owl reasoner. In: **Proceedings of the 5th International Workshop on OWL: Experiences and Directions (OWLED 2008)**. [S.l.: s.n.], 2008. v. 432, p. 91.

SIEG, A.; MOBASHER, B.; BURKE, R. Web search personalization with ontological user profiles. In: ACM. **Proceedings of the sixteenth ACM conference on Conference on information and knowledge management**. [S.l.], 2007. p. 525–534.

SLOUTSKY, V. M. From perceptual categories to concepts: What develops? **Cognitive science**, Wiley Online Library, v. 34, n. 7, p. 1244–1286, 2010.

SMITH, B.; WELTY, C. Ontology: Towards a new synthesis. In: ACM PRESS, USA, PP. III-X. **Formal Ontology in Information Systems**. [S.l.], 2001. p. 3–9.

SMITH, E. Foundations of cognitive science. In: \_\_\_\_\_. [S.l.]: MIT Press, 1989. chp. Concepts and induction, p. 501–526.

SMITH, E. E.; MEDIN, D. L. **Categories and concepts**. [S.l.]: Harvard University Press Cambridge, MA, 1981.

SMITH, J. D. Prototypes, exemplars, and the natural history of categorization. **Psychonomic bulletin & review**, Springer, v. 21, n. 2, p. 312–331, 2014.

SMITH, J. D.; MINDA, J. P. Distinguishing prototype-based and exemplar-based processes in dot-pattern category learning. **Journal of Experimental Psychology: Learning, Memory, and Cognition**, American Psychological Association, v. 28, n. 4, p. 800, 2002.

SMOLENSKY, P. Connectionist ai, symbolic ai, and the brain. **Artificial Intelligence Review**, Springer, v. 1, n. 2, p. 95–109, 1987.

STANTON, C.; WILLIAMS, M.-A. Grounding robot sensory and symbolic information using the semantic web. In: SPRINGER. **Robot Soccer World Cup**. [S.l.], 2003. p. 757–764.

STUDER, R.; BENJAMINS, V. R.; FENSEL, D. Knowledge engineering: Principles and methods. **Data and Knowledge Engineering**, v. 25, n. 1-2, p. 161–197, March 1998.

SUGUIO, K. **Geologia Sedimentar**. São Paulo: Edgar Bücher LTDA, 2003. 400 p.

SUH, I. H. et al. Ontology-based multi-layered robot knowledge framework (omrkf) for robot intelligence. In: IEEE. **2007 IEEE/RSJ International Conference on Intelligent Robots and Systems**. [S.l.], 2007. p. 429–436.

SZABÓ, Z. G. Compositionality. In: ZALTA, E. N. (Ed.). **The Stanford Encyclopedia of Philosophy**. Fall 2013. [S.l.: s.n.], 2013.

TENORTH, M.; BEETZ, M. Knowrob: knowledge processing for autonomous personal robots. In: IEEE. **2009 IEEE/RSJ International Conference on Intelligent Robots and Systems**. [S.l.], 2009. p. 4261–4266.

TENORTH, M. et al. The roboearth language: Representing and exchanging knowledge about actions, objects, and environments. In: IEEE. **Robotics and Automation (ICRA), 2012 IEEE International Conference on**. [S.l.], 2012. p. 1284–1289.

TOMEK, I. An experiment with the edited nearest-neighbor rule. **IEEE Transactions on Systems, Man, and Cybernetics**, n. 6, p. 448–452, 1976.

VICENTE, A.; MANRIQUE, F. M. The big concepts paper: A defence of hybridism. **The British Journal for the Philosophy of Science**, Br Soc Philosophy Sci, p. axu022, 2014.

WANG, H.; DING, C. H.; HUANG, H. Multi-label classification: Inconsistency and class balanced k-nearest neighbor. In: **AAAI**. [S.l.: s.n.], 2010.

WEISKOPF, D. A. The plurality of concepts. **Synthese**, Springer, v. 169, n. 1, p. 145–173, 2009.

WILSON, D. L. Asymptotic properties of nearest neighbor rules using edited data. **Systems, Man and Cybernetics, IEEE Transactions on**, IEEE, n. 3, p. 408–421, 1972.

WILSON, D. R.; MARTINEZ, T. R. Reduction techniques for instance-based learning algorithms. **Machine learning**, Springer, v. 38, n. 3, p. 257–286, 2000.

WITTGENSTEIN, L. J. J. **Philosophical Investigations**. [S.l.]: Oxford: Blackwell, 1953.

WU, Y.; AI, X. Face detection in color images using adaboost algorithm based on skin color information. **International Workshop on Knowledge Discovery and Data Mining**, IEEE Computer Society, Los Alamitos, CA, USA, v. 0, p. 339–342, 2008.

XU, Z.; ZHANG, S.; DONG, Y. Mapping between relational database schema and owl ontology for deep annotation. In: IEEE COMPUTER SOCIETY. **Proceedings of the 2006 IEEE/WIC/ACM international Conference on Web intelligence**. [S.l.], 2006. p. 548–552.

YEUNG, C.-m. A.; LEUNG, H.-f. Ontology with likeliness and typicality of objects in concepts. In: **Conceptual Modeling-ER 2006**. [S.l.]: Springer, 2006. p. 98–111.

YEUNG, C.-m. A.; LEUNG, H.-F. A formal model of ontology for handling fuzzy membership and typicality of instances. **The computer journal**, Br Computer Soc, 2008.

ZECCHIN, M.; MELLERE, D.; RODA, C. Sequence stratigraphy and architectural variability in growth fault-bounded basin fills: a review of plio-pleistocene stratal units of the crotone basin, southern italy. **Journal of the Geological Society**, Geological Society of London, v. 163, n. 3, p. 471–486, 2006.

ZENG, Y.; YANG, Y.; ZHAO, L. Pseudo nearest neighbor rule for pattern classification. **Expert Systems with Applications**, Elsevier, v. 36, n. 2, p. 3587–3595, 2009.



## APÊNDICE A — AVALIAÇÃO DOS ALGORITMOS LDIS E ASBI NA TAREFA DE SELEÇÃO DE INSTÂNCIAS

Nesta Seção serão discutidos os resultados dos experimentos realizados para avaliar a performance dos algoritmos ASBI e LDIS, apresentados respectivamente nas Seções 3.4.2.1 e 3.4.2.2. Conforme discutido na Seção 3.4.2, o objetivo destes algoritmos é selecionar um conjunto reduzido de instâncias representativas o suficiente para servirem de suporte para a classificação de novas instâncias. Neste sentido, ambos os algoritmos podem ser vistos como abordagens para *seleção de instâncias*, como as discutidas na Seção 2.3. Por este motivo, os experimentos cujos resultados serão discutidos nesta seção foram realizados para comparar a performance dos algoritmos ASBI e LDIS com a performance dos algoritmos discutidos na Seção 2.3. Assim, o principal objetivo dos experimentos realizados nesta seção é demonstrar a efetividade dos algoritmos propostos, comparando a performance destes algoritmos com os métodos de seleção de instância no estado da arte.

O experimento discutido nesta seção foi conduzido com base em 27 conjuntos de dados bem conhecidos e tradicionalmente utilizados em experimentos de abordagens de seleção de instâncias. Os conjuntos de dados são: audiology, breast cancer, cardiotocography, cars, dermatology, diabetes, e. coli, glass, heart statelog, ionosphere, iris, landsat, letter, lung cancer, lymph, mushroom, optdigits, page-blocks, parkinsons, genetic promoters, segment, soybean<sup>1</sup>, spambase, splice-junction gene sequences, voting, wine e zoo. Todos os conjuntos de dados foram obtidos do UCI Machine Learning Repository<sup>2</sup>. A Tabela A.1 apresenta os detalhes de cada conjunto de dados.

---

<sup>1</sup>Este conjunto de dados combina ambos os conjuntos de dados de treinamento e de teste do conjunto de dados soybean.

<sup>2</sup><<http://archive.ics.uci.edu/ml/>>

Tabela A.1: Detalhes dos conjuntos de dados utilizados nos experimentos.

Conjunto de dados	Instâncias	Atributos	Classes
<b>Audiology</b>	226	70	24
<b>Breast cancer</b>	286	10	2
<b>Cardiotocography</b>	2126	21	10
<b>Cars</b>	1728	6	4
<b>Dermatology</b>	358	35	6
<b>Diabetes</b>	768	9	2
<b>E. Coli</b>	336	8	8
<b>Glass</b>	214	10	7
<b>Heart statelogs</b>	270	14	2
<b>Ionosphere</b>	351	35	2
<b>Iris</b>	150	5	3
<b>Landsat</b>	4435	37	6
<b>Letter</b>	20000	17	26
<b>Lung cancer</b>	32	57	3
<b>Lymph</b>	148	19	4
<b>Mushroom</b>	8124	23	2
<b>Optdigits</b>	5620	65	10
<b>Page-blocks</b>	5473	11	5
<b>Parkinsons</b>	195	23	2
<b>Promoters</b>	106	58	2
<b>Segment</b>	2310	20	7
<b>Soybean</b>	683	36	19
<b>Spambase</b>	4601	58	2
<b>Splice</b>	3190	61	3
<b>Voting</b>	435	17	2
<b>Wine</b>	178	14	3
<b>Zoo</b>	101	18	7

O experimento foi realizado para comparar 3 medidas de avaliação de performance diferentes: *acurácia*, *redução* e *eficiência*. Seguindo (LEYVA; GONZÁLEZ; PÉREZ, 2015), nós assumimos que

$$\text{acurácia} = \frac{\text{Sucesso}(T_{\text{este}})}{|T_{\text{este}}|} \quad (\text{A.1})$$

e

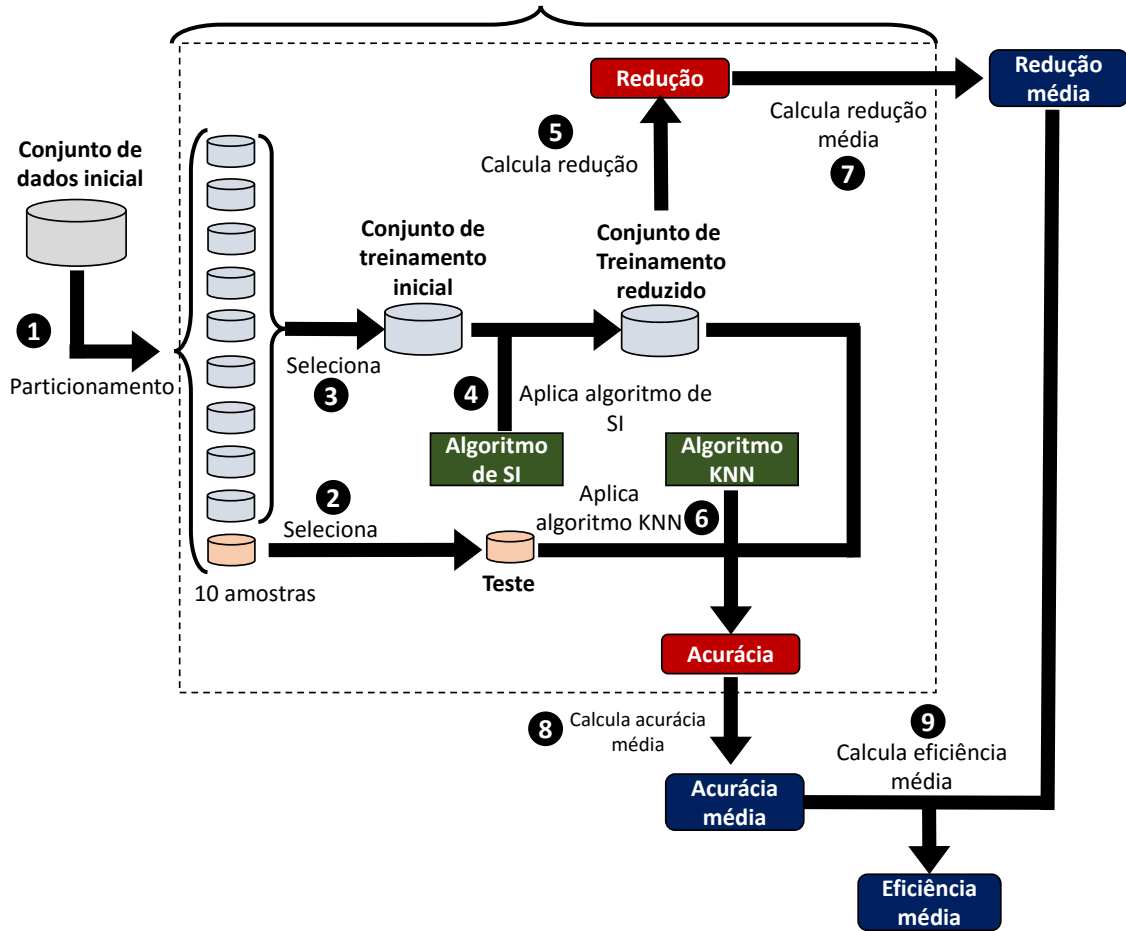
$$\text{redução} = \frac{|T| - |S|}{|T|} \quad (\text{A.2})$$

, onde  $T_{\text{este}}$  é um dado conjunto de instâncias que são selecionadas para serem testadas em uma tarefa de classificação, e  $\text{Sucesso}(T_{\text{este}})$  é o número de instâncias em  $T_{\text{este}}$  corretamente classificadas na tarefa de classificação. Além disso, neste trabalho nós também consideramos *eficiência* como uma medida do grau com que um algoritmo de seleção de instâncias é capaz de produzir um conjunto reduzido de instâncias que permite a

classificação de novas instâncias com alta acurácia. Assim, assumimos que *eficiência* = *acurácia* × *redução*. Ou seja, quanto maior a redução de conjunto de instâncias original e quanto maior for a acurácia suportada pelo conjunto de instâncias resultante, maior é a eficiência do algoritmo.

Para avaliar a *acurácia* da classificação de novas instâncias (com base nas instâncias selecionadas pelos algoritmos testados), foi aplicado o algoritmo KNN (*k-Nearest Neighbors*) (COVER; HART, 1967), considerando  $k = 3$ , assim como foi considerado em (LEYVA; GONZÁLEZ; PÉREZ, 2015). Além disso, a acurácia e a redução foram avaliadas em um esquema de validação cruzada *n-fold*, onde  $n = 10$ . Neste esquema, primeiramente o conjunto de instâncias original é particionado aleatoriamente em 10 subconjuntos com o mesmo número de instâncias. Destes subconjuntos, um único subconjunto desempenha o papel de dados de validação (*Teste*), enquanto a união dos 9 subconjuntos restantes é considerado o *conjunto de treinamento iniciais* (*CTI*). A seguir, um algoritmo de seleção de instâncias é aplicado para reduzir o *CTI*, produzindo o *conjunto de treinamento reduzido* (*CTR*). Neste ponto, é possível medir a *redução* do conjunto de dados. Finalmente, o *CTR* é usado como conjunto de treinamento para o algoritmo KNN, para avaliar as instâncias em *Teste*. Neste ponto, é possível medir a acurácia alcançada pelo KNN, usando o *CTR* como conjunto de treinamento. O processo de validação cruzada é repetido 10 vezes, de modo que cada subconjunto é utilizado uma vez como *Teste*. É obtida a média dos 10 valores de acurácia e redução para produzir, respectivamente, a *acurácia média* (*AM*) e a *redução média* (*RM*). A *eficiência média* (*EM*) é calculada considerando-se *AM* e *RM*. Este esquema é representado na Figura A.1. As Tabelas A.2, A.3 e A.4 apresentam, respectivamente, os valores de *AM*, *RM* e *EM* resultantes de cada combinação de conjunto de dados e algoritmo de seleção de instâncias. Nestas tabelas, os melhores resultados para cada conjunto de dados são marcados em negrito.

Figura A.1: Esquema de validação cruzada adotada. Repete 10 vezes, com cada amostra usada uma vez como **Teste**



Fonte: Produzida pelo autor.

Além disso, adotou-se uma função de distância  $d: V \times V \rightarrow \mathbb{R}$ , onde  $V$  representa o conjunto de todos os vetores de características considerados em um conjunto de dados e cada instância  $x$  de cada conjunto de dados avaliado é representado por um vetor de características que pertence a  $V$ . Tal função de distância é formalizada da seguinte forma:

$$d(x, y) = \sum_{j=1}^f \theta_j(x, y) \quad (\text{A.3})$$

onde

$$\theta_j(x, y) = \begin{cases} \alpha(x_j, y_j), & \text{se } j \text{ é um atributo categorial ou booleano} \\ |x_j - y_j|, & \text{se } j \text{ é um atributo numérico} \end{cases} \quad (\text{A.4})$$

onde

$$\alpha(x_j, y_j) = \begin{cases} 1, & \text{se } x_j \neq y_j \\ 0, & \text{se } x_j = y_j \end{cases} \quad (\text{A.5})$$



Tabela A.2: Comparação da *acurácia* alcançada pelo conjunto de instâncias selecionado por cada algoritmo de seleção de instâncias em cada um dos conjuntos de dados.

Algoritmo	LDIS	ASBI	LSBo	DROP3	ICF	ENN	LSSm	Média
Audiology	0,367	0,424	0,485	0,441	0,444	0,470	<b>0,537</b>	0,453
Breast cancer	0,694	0,727	0,613	0,731	0,717	<b>0,741</b>	0,736	0,708
Cardiotocography	0,542	0,547	0,557	0,610	0,598	0,657	<b>0,684</b>	0,599
Cars	0,759	0,739	0,655	0,750	0,755	<b>0,762</b>	0,757	0,740
Dermatology	0,712	0,729	0,734	0,781	0,776	0,822	<b>0,841</b>	0,771
Diabetes	0,688	0,725	0,709	0,725	0,703	<b>0,726</b>	0,722	0,714
E. Coli	0,853	0,815	0,798	0,828	0,814	<b>0,861</b>	0,847	0,831
Glass	0,606	0,561	0,563	0,624	0,615	0,653	<b>0,710</b>	0,619
Heart statelogs	<b>0,695</b>	0,675	0,676	0,682	0,686	0,693	0,690	0,685
Ionosphere	0,827	0,886	0,894	0,870	0,874	0,889	<b>0,903</b>	0,878
Iris	0,960	0,935	0,937	0,965	0,944	<b>0,967</b>	0,956	0,952
Landsat	0,868	0,882	0,864	0,887	0,851	0,898	<b>0,901</b>	0,879
Letter	0,772	0,759	0,748	0,872	0,804	0,918	<b>0,920</b>	0,827
Lung cancer	0,383	0,380	0,320	0,313	0,407	0,340	<b>0,447</b>	0,370
Lymph	0,749	0,789	0,777	0,726	0,750	0,789	<b>0,791</b>	0,767
Mushroom	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	0,998	<b>1,000</b>	<b>1,000</b>	1,000
Optdigits	0,936	0,919	0,908	0,968	0,913	0,979	<b>0,980</b>	0,943
Page-blocks	0,943	<b>0,974</b>	0,945	0,954	0,950	0,959	0,957	0,955
Parkinsons	0,800	0,847	0,852	0,831	0,807	0,853	<b>0,855</b>	0,835
Promoters	0,762	0,740	0,718	0,790	0,724	0,792	<b>0,818</b>	0,763
Segment	0,906	0,860	0,866	0,933	0,911	0,950	<b>0,954</b>	0,911
Soybean	0,782	0,611	0,629	0,848	0,835	0,897	<b>0,906</b>	0,787
Spambase	0,762	0,823	0,839	0,821	0,822	0,838	<b>0,848</b>	0,822
Splice	0,745	<b>0,760</b>	0,754	0,714	0,703	0,728	0,759	0,738
Voting	0,914	0,914	0,892	0,917	0,913	0,922	<b>0,924</b>	0,914
Wine	0,689	0,769	<b>0,778</b>	0,705	0,726	0,735	0,762	0,738
Zoo	0,824	0,682	0,706	<b>0,908</b>	0,880	0,884	0,900	0,826
Média	0,761	0,758	0,749	0,785	0,775	0,805	<b>0,819</b>	0,779

, onde  $x_j$  representa o valor do atributo  $j$ , da instância  $x$ ;  $\theta_j$  é uma função que mapeia dois vetores de características ( $x \in V$  e  $y \in V$ ) em um valor (que pertence a  $\mathbb{R}$ ) que representa a distância entre  $x$  e  $y$  em relação ao atributo  $j$ ;  $\alpha$  é uma função que mapeia dois valores categoriais ( $x_j$  e  $y_j$ ) em um valor que pertence a  $\{0, 1\}$  e representa a distância entre tais valores; e  $f$  representa o tamanho dos vetores de característica (ou número de atributos considerado em cada conjunto de dados.).

Também é importante notar que, neste experimento, adotou-se  $k = 3$  para DROP3, ENN, ICF e LDIS.

A Tabela A.2 demonstra que o algoritmo LSSm apresenta a maior *acurácia* na maior parte dos conjuntos de dados e a maior *acurácia* média. No entanto, é importante notar que o LSSm foi projetado principalmente para remover ruído e, devido a isto, ele não oferece uma boa taxa de redução; conseqüentemente, ele também não é tão eficiente quanto outros algoritmos. Isto fica claro nos resultados apresentados nas Tabelas A.3 e A.4. Também é importante notar que, apesar dos algoritmos ASBI e LDIS não oferecerem as maiores medidas de *acurácia*, eles alcançam níveis de *acurácia* maiores que a média, em diversos conjuntos de dados. O algoritmo ASBI resultou nas maiores medidas de *acurácia* para 3 conjuntos de dados (Mushroom, Page-blocks e Splice), e o algoritmo LDIS também apresentou as maiores medidas de *acurácia* para 2 conjuntos de dados (Heart statelogs e Mushroom). Além disso, constata-se também que a *acurácia* média dos algoritmos ASBI

Tabela A.3: Comparação da *redução* alcançada por cada algoritmo de seleção de instâncias em cada um dos conjuntos de dados.

Algoritmo	LDIS	ASBI	LSBo	DROP3	ICF	ENN	LSSm	Média
Audiology	<b>0,742</b>	0,723	0,603	0,713	0,772	0,353	0,079	0,569
Breast cancer	<b>0,876</b>	0,840	0,728	0,766	0,855	0,285	0,138	0,641
Cardiotocography	<b>0,855</b>	0,800	0,696	0,699	0,711	0,309	0,126	0,599
Cars	0,859	0,849	0,742	<b>0,875</b>	0,824	0,185	0,118	0,636
Dermatology	<b>0,883</b>	0,807	0,729	0,653	0,682	0,155	0,123	0,576
Diabetes	<b>0,906</b>	0,844	0,758	0,770	0,858	0,306	0,128	0,653
E. Coli	<b>0,899</b>	0,887	0,821	0,714	0,861	0,163	0,092	0,634
Glass	<b>0,901</b>	0,815	0,716	0,759	0,687	0,323	0,137	0,620
Heart stategog	<b>0,921</b>	0,805	0,685	0,728	0,783	0,301	0,144	0,624
Ionosphere	0,899	0,893	0,859	0,799	<b>0,917</b>	0,111	0,042	0,646
Iris	0,893	<b>0,945</b>	0,931	0,717	0,579	0,041	0,061	0,595
landsat	<b>0,916</b>	0,911	0,875	0,721	0,904	0,098	0,052	0,640
Letter	0,826	<b>0,871</b>	0,832	0,676	0,804	0,051	0,036	0,585
Lung cancer	<b>0,846</b>	0,741	0,517	0,702	0,743	0,593	0,175	0,617
Lymph	<b>0,904</b>	0,802	0,747	0,694	0,800	0,187	0,111	0,606
Mushroom	0,864	<b>0,995</b>	<b>0,995</b>	0,861	0,941	0,000	0,002	0,665
Optdigits	0,913	<b>0,925</b>	0,901	0,713	0,921	0,016	0,021	0,630
Page-blocks	0,862	<b>0,974</b>	0,963	0,714	0,953	0,043	0,031	0,649
Parkinsons	0,810	<b>0,902</b>	0,872	0,707	0,751	0,152	0,116	0,616
Promoters	<b>0,842</b>	0,739	0,598	0,601	0,703	0,179	0,046	0,530
Segment	0,825	<b>0,934</b>	0,913	0,687	0,827	0,037	0,038	0,609
Soybean	0,779	<b>0,868</b>	0,831	0,678	0,581	0,090	0,048	0,554
Spambase	0,832	<b>0,863</b>	0,814	0,738	0,806	0,156	0,076	0,612
Splice	<b>0,813</b>	0,705	0,591	0,658	0,759	0,229	0,053	0,544
Voting	0,773	0,921	0,885	0,789	<b>0,922</b>	0,074	0,041	0,629
Wine	<b>0,868</b>	0,852	0,781	0,710	0,784	0,227	0,098	0,617
Zoo	0,646	<b>0,893</b>	0,876	0,647	0,326	0,059	0,059	0,501
Média	0,850	<b>0,856</b>	0,787	0,722	0,780	0,175	0,081	0,607

e LDIS é superior à acurácia média de algoritmos recentes, como o LSBo. Observando-se as Tabelas A.3 e A.4, verifica-se que a acurácia levemente inferior dos algoritmos ASBI e LDIS é compensada pela taxa de redução que eles alcançam e, conseqüentemente, pela eficiência resultante. A Tabela A.3 mostra que o LDIS e o ASBI superam, os demais algoritmos em termos de taxa de redução; eles apresentam as maiores taxas de *redução* na maior parte dos conjuntos de dados, e também apresentam a maior taxa de redução média. Finalmente, a Tabela A.4 mostra que os algoritmos ASBI e LDIS também superam os demais algoritmos em termos de *eficiência*; eles apresentam as maiores medidas de eficiência na maior parte dos conjuntos de dados, e apresentam a maior eficiência média. Assim, os resultados mostram que apesar dos algoritmos ASBI e LDIS não apresentarem as maiores medidas de acurácia, eles apresentam as maiores taxas de redução e as maiores medidas de eficiência (que busca medir o compromisso entre acurácia e redução).


Além de comparar acurácia, redução e eficiência, também foram comparados os tempos de execução dos algoritmos anteriormente citados, em 3 dos maiores conjuntos de dados considerados: letter, splice-junction gene sequences e mushroom. Estes conjuntos de dados foram selecionados por possuírem, além de uma grande quantidade de instâncias, uma grande quantidade de atributos e quantidades variáveis de classes. A execução dos algoritmos foi realizada em um laptop Intel® Core™ i5-3210M com uma CPU de 2.5

Tabela A.4: Comparação da *eficiência* alcançada por cada algoritmo de seleção de instâncias em cada um dos conjuntos de dados.

Algoritmo	LDIS	ASBI	LSBo	DROP3	ICF	ENN	LSSm	Média
Audiology	0,272	0,306	0,293	0,314	<b>0,342</b>	0,166	0,042	0,248
Breast cancer	0,608	0,611	0,446	0,560	<b>0,613</b>	0,211	0,101	0,450
Cardiotocography	<b>0,463</b>	0,437	0,387	0,427	0,425	0,203	0,086	0,347
Cars	<b>0,651</b>	0,627	0,486	0,656	0,622	0,141	0,089	0,468
Dermatology	<b>0,629</b>	0,589	0,535	0,510	0,529	0,128	0,104	0,432
Diabetes	<b>0,623</b>	0,612	0,538	0,558	0,603	0,222	0,093	0,464
E. Coli	<b>0,766</b>	0,722	0,655	0,592	0,701	0,141	0,078	0,522
Glass	<b>0,546</b>	0,457	0,403	0,474	0,422	0,211	0,097	0,373
Heart statelogs	<b>0,640</b>	0,543	0,463	0,497	0,537	0,209	0,100	0,427
Ionosphere	0,744	0,791	0,767	0,695	<b>0,801</b>	0,099	0,038	0,562
Iris	0,857	<b>0,884</b>	0,873	0,693	0,547	0,040	0,058	0,564
landsat	0,795	<b>0,803</b>	0,756	0,640	0,769	0,088	0,047	0,557
Letter	0,638	<b>0,661</b>	0,622	0,590	0,646	0,047	0,034	0,463
Lung cancer	<b>0,324</b>	0,281	0,165	0,220	0,302	0,202	0,078	0,225
Lymph	<b>0,677</b>	0,633	0,581	0,504	0,600	0,148	0,088	0,461
Mushroom	0,864	<b>0,995</b>	<b>0,995</b>	0,861	0,939	0,000	0,002	0,665
Optdigits	<b>0,855</b>	0,851	0,818	0,690	0,841	0,015	0,021	0,585
Page-blocks	0,813	<b>0,949</b>	0,910	0,681	0,905	0,041	0,030	0,618
Parkinsons	0,648	<b>0,764</b>	0,743	0,588	0,607	0,130	0,099	0,511
Promoters	<b>0,641</b>	0,547	0,430	0,475	0,509	0,142	0,038	0,397
Segment	0,748	<b>0,803</b>	0,791	0,641	0,753	0,035	0,036	0,544
Soybean	<b>0,609</b>	0,530	0,523	0,576	0,485	0,081	0,043	0,407
Spambase	0,634	<b>0,710</b>	0,683	0,606	0,662	0,131	0,065	0,499
Splice	<b>0,606</b>	0,536	0,445	0,470	0,534	0,167	0,040	0,400
Voting	0,706	<b>0,842</b>	0,789	0,723	<b>0,842</b>	0,068	0,038	0,573
Wine	0,598	<b>0,656</b>	0,607	0,501	0,569	0,167	0,075	0,453
Zoo	0,532	0,609	<b>0,619</b>	0,588	0,287	0,052	0,053	0,391
Média	0,648	<b>0,657</b>	0,605	0,568	0,607	0,122	0,062	0,467

GHz e 6 GB de RAM. Os tempos de execução dos algoritmos são apresentados na Figura A.2. De acordo com esta figura, é possível constatar que o algoritmo LDIS consistentemente apresenta os menores tempos de execução, dentre os algoritmos considerados. Este resultado é uma consequência do fato de que o algoritmo LDIS lida com os conjuntos de instâncias de cada classe separadamente. Esta estratégia requer um número muito menor de comparações entre instâncias do que o número de comparações realizados por algoritmos que selecionam instâncias de borda (como o ICF, o LSBo e o ASBI). Além disso é possível constatar que algoritmos como o LSSm e o ENN, mais utilizados para remoção de ruído, possuem tempos de execução inferiores aos tempos de execução de algoritmos como o DROP3, ICF, LSBo e ASBI. Este resultado confirma o esperado, visto que os algoritmos DROP3, ICF, LSBo e ASBI utilizam algoritmos de redução de ruído. Além disso, também é possível constatar que o algoritmo ASBI apresenta tempos de execução semelhantes aos tempos de execução do algoritmo LSBo. Ou seja, além do algoritmo ASBI apresentar medidas de acurácia, redução e eficiência melhores que os apresentados pelo LSBo, ele também possui tempos de execução inferiores. Por fim, também é possível constatar que os tempos de execução do algoritmo ASBI são razoavelmente inferiores aos tempos de execução dos algoritmos DROP3 e ICF.

Figura A.2: Comparação do tempo de execução dos algoritmos de seleção de instâncias.



Fonte: Produzida pelo autor.

Além disso, uma vez que o algoritmo LDIS adota um parâmetro  $k$  que especifica a quantidade de vizinhos que são considerados para determinar a  $k$  – vizinhança parcial, também foram realizados experimentos para avaliar o impacto do parâmetro  $k$  na performance do algoritmo LDIS. As Tabelas A.5, A.6 e A.7 apresentam, respectivamente, a acurácia, a redução e a eficiência do algoritmo LDIS, com o parâmetro  $k$  assumindo os valores 1, 2, 3, 5, 10 e 20. Estes resultados mostram que a variação de  $k$  tem um impacto significativo na performance do algoritmo. Os resultados sugerem que, em geral, conforme o valor de  $k$  aumenta, a acurácia tende a diminuir, a redução tende a aumentar, e a eficiência tende a aumentar até um ponto a partir do qual ela diminui. Ou seja, ajustando-se o parâmetro  $k$ , sacrifica-se a acurácia para ganhar em redução. Além disso, a Tabela A.5 mostra algumas exceções à regra geral comentada anteriormente, como no caso dos conjuntos de dados *breast cancer*, *diabetes* e *heart statelog*. Uma possível explicação para estas exceções é que com o aumento do valor de  $k$  é possível que mais ruído tenha sido removido do conjunto de dados, resultando em um aumento da acurácia com o aumento do valor de  $k$ . Finalmente, estas tabelas também mostram que a acurácia alcançada pelo algoritmo LDIS pode aproximar-se da acurácia alcançada por algoritmos conservadores, como o LSSm e o ENN, quando adota-se um valor de  $k$  baixo. Por exemplo, Na tabela A.2, constata-se que a acurácia média do algoritmo LSSm é de 0,819, enquanto na Tabela A.5, constata-se que a acurácia média do algoritmo LDIS, com  $k = 1$  é de 0,812; um valor muito próximo. No entanto, mesmo neste caso, o algoritmo LDIS (com  $k = 1$ ) apresenta taxas de redução e eficiência (0,577 e 0,463, respectivamente) maiores que as apresentadas pelo LSSm (0,081 e 0,062, respectivamente).

Tabela A.5: Comparação da *acurácia* alcançada pelo algoritmo LDIS, com diferentes valores de  $k$ , para cada conjunto de dados.

Conjunto de dados	K=1	K=2	K=3	K=5	K=10	K=20	Média
Audiology	<b>0,659</b>	0,441	0,367	0,273	0,245	0,236	0,370
Breast cancer	0,686	0,693	<b>0,694</b>	0,668	0,561	0,611	0,652
Cardiotocography	<b>0,707</b>	0,617	0,542	0,443	0,361	0,290	0,493
Cars	0,746	<b>0,770</b>	0,759	0,736	0,663	0,533	0,701
Dermatology	<b>0,797</b>	0,731	0,712	0,597	0,537	0,566	0,657
Diabetes	0,705	0,695	0,688	<b>0,708</b>	0,658	0,612	0,678
E. Coli	0,818	0,824	<b>0,853</b>	0,809	0,803	0,806	0,819
Glass	<b>0,681</b>	0,610	0,606	0,486	0,414	0,433	0,538
Heart statellog	0,659	0,689	0,695	0,641	<b>0,704</b>	0,693	0,680
Ionosphere	<b>0,874</b>	0,854	0,827	0,829	0,797	0,691	0,812
Iris	0,947	<b>0,967</b>	0,960	0,933	0,893	0,927	0,938
landsat	<b>0,891</b>	0,881	0,868	0,831	0,644	0,581	0,783
Letter	<b>0,934</b>	0,870	0,772	0,598	0,326	0,189	0,615
Lung cancer	<b>0,467</b>	0,367	0,383	0,367	0,533	0,433	0,425
Lymph	0,764	<b>0,829</b>	0,749	0,700	0,679	0,679	0,733
Mushroom	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	0,991	0,990	0,997
Optdigits	<b>0,976</b>	0,960	0,936	0,875	0,483	0,457	0,781
Page-blocks	<b>0,954</b>	0,947	0,943	0,924	0,907	0,465	0,857
Parkinsons	<b>0,868</b>	0,774	0,800	0,805	0,716	0,726	0,782
Promoters	<b>0,800</b>	0,730	0,762	0,670	0,580	0,690	0,705
Segment	<b>0,964</b>	0,936	0,906	0,826	0,541	0,417	0,765
Soybean	0,775	0,776	<b>0,782</b>	0,768	0,769	0,769	0,773
Spambase	<b>0,817</b>	0,786	0,762	0,724	0,678	0,703	0,745
Splice	<b>0,774</b>	0,755	0,745	0,717	0,668	0,614	0,712
Voting	0,928	<b>0,937</b>	0,914	0,914	0,877	0,874	0,907
Wine	<b>0,776</b>	<b>0,776</b>	0,689	0,724	0,712	0,759	0,739
Zoo	<b>0,950</b>	0,870	0,824	0,720	0,650	0,630	0,774
<b>Média</b>	<b>0,812</b>	0,781	0,761	0,714	0,644	0,606	0,720

Tabela A.6: Comparação da *redução* alcançada pelo algoritmo LDIS, com diferentes valores de  $k$ , para cada conjunto de dados.

Conjunto de dados	K=1	K=2	K=3	K=5	K=10	K=20	Média
Audiology	0,473	0,628	0,742	0,801	<b>0,813</b>	0,807	0,711
Breast cancer	0,581	0,774	0,876	0,947	0,976	<b>0,988</b>	0,857
Cardiotocography	0,561	0,761	0,855	0,934	0,982	<b>0,993</b>	0,848
Cars	0,508	0,740	0,859	0,940	0,987	<b>0,995</b>	0,838
Dermatology	0,637	0,816	0,883	0,936	0,975	<b>0,981</b>	0,871
Diabetes	0,629	0,835	0,906	0,959	0,982	<b>0,992</b>	0,884
E. Coli	0,679	0,843	0,899	0,951	0,966	<b>0,968</b>	0,884
Glass	0,620	0,830	0,901	0,949	0,967	<b>0,968</b>	0,873
Heart statellog	0,658	0,859	0,921	0,969	0,988	<b>0,992</b>	0,898
Ionosphere	0,670	0,847	0,899	0,960	0,990	<b>0,994</b>	0,893
Iris	0,599	0,816	0,893	0,950	<b>0,978</b>	0,976	0,868
landsat	0,607	0,833	0,916	0,972	0,992	<b>0,997</b>	0,886
Letter	0,514	0,723	0,826	0,914	0,971	<b>0,988</b>	0,823
Lung cancer	0,696	0,807	0,846	0,870	0,874	<b>0,889</b>	0,830
Lymph	0,652	0,819	0,904	0,943	<b>0,960</b>	<b>0,960</b>	0,873
Mushroom	0,491	0,750	0,864	0,962	0,996	<b>0,997</b>	0,843
Optdigits	0,641	0,838	0,913	0,965	0,990	<b>0,996</b>	0,890
Page-blocks	0,528	0,755	0,862	0,949	0,993	<b>0,998</b>	0,847
Parkinsons	0,469	0,689	0,810	0,913	0,957	<b>0,985</b>	0,804
Promoters	0,652	0,787	0,842	0,903	0,944	<b>0,974</b>	0,850
Segment	0,439	0,697	0,825	0,926	0,976	<b>0,994</b>	0,809
Soybean	0,783	0,780	0,779	<b>0,787</b>	0,774	0,783	0,781
Spambase	0,567	0,748	0,832	0,906	0,951	<b>0,973</b>	0,829
Splice	0,512	0,714	0,813	0,901	0,962	<b>0,986</b>	0,815
Voting	0,556	0,734	0,773	0,849	0,942	<b>0,980</b>	0,806
Wine	0,574	0,765	0,868	0,960	0,978	<b>0,980</b>	0,854
Zoo	0,277	0,447	0,646	0,692	0,723	<b>0,743</b>	0,588
<b>Média</b>	<b>0,577</b>	<b>0,764</b>	<b>0,850</b>	<b>0,915</b>	<b>0,948</b>	<b>0,958</b>	<b>0,835</b>

Tabela A.7: Comparação da *eficiência* alcançada pelo LDIS, com diferentes valores de  $k$ , para cada conjunto de dados.

Conjunto de dados	K=1	K=2	K=3	K=5	K=10	K=20	Média
Audiology	<b>0,312</b>	0,277	0,272	0,218	0,200	0,191	0,245
Breast cancer	0,399	0,536	0,608	<b>0,633</b>	0,547	0,603	0,554
Cardiotocography	0,396	<b>0,469</b>	0,463	0,414	0,355	0,288	0,398
Cars	0,379	0,570	0,651	<b>0,692</b>	0,655	0,530	0,579
Dermatology	0,508	0,597	<b>0,629</b>	0,559	0,524	0,555	0,562
Diabetes	0,443	0,580	0,623	<b>0,679</b>	0,646	0,607	0,596
E. Coli	0,555	0,695	0,766	0,769	0,776	<b>0,780</b>	0,724
Glass	0,422	0,506	<b>0,546</b>	0,461	0,401	0,420	0,459
Heart statellog	0,434	0,592	0,640	0,621	<b>0,696</b>	0,687	0,612
Ionosphere	0,586	0,724	0,744	<b>0,795</b>	0,789	0,687	0,721
Iris	0,567	0,788	0,857	0,887	0,873	<b>0,904</b>	0,813
landsat	0,541	0,733	0,795	<b>0,808</b>	0,639	0,580	0,683
Letter	0,480	0,629	<b>0,638</b>	0,546	0,317	0,187	0,466
Lung cancer	0,325	0,296	0,324	0,319	<b>0,466</b>	0,385	0,353
Lymph	0,499	<b>0,679</b>	0,677	0,660	0,652	0,651	0,636
Mushroom	0,491	0,750	0,864	0,962	<b>0,987</b>	<b>0,987</b>	0,840
Optdigits	0,625	0,804	<b>0,855</b>	0,845	0,478	0,456	0,677
Page-blocks	0,503	0,715	0,813	0,877	<b>0,901</b>	0,464	0,712
Parkinsons	0,407	0,533	0,648	<b>0,735</b>	0,685	0,715	0,621
Promoters	0,522	0,574	0,641	0,605	0,548	<b>0,672</b>	0,594
Segment	0,423	0,653	0,748	<b>0,765</b>	0,528	0,415	0,589
Soybean	0,607	0,606	<b>0,609</b>	0,604	0,595	0,603	0,604
Spambase	0,464	0,588	0,634	0,656	0,645	<b>0,684</b>	0,612
Splice	0,396	0,539	0,606	<b>0,646</b>	0,643	0,605	0,573
Voting	0,516	0,688	0,706	0,776	0,826	<b>0,857</b>	0,728
Wine	0,446	0,594	0,598	0,695	0,696	<b>0,744</b>	0,629
Zoo	0,263	0,389	<b>0,532</b>	0,498	0,470	0,468	0,437
<b>Média</b>	0,463	0,596	0,648	<b>0,656</b>	0,612	0,582	0,593





## APÊNDICE B — MODELO DE CONHECIMENTO CLÁSSICO

A seguir, apresenta-se o modelo de conhecimento clássico adotado na aplicação apresentada no Capítulo 4. Este modelo<sup>1</sup>, implementado em OWL, será apresentado aqui utilizando a sintaxe Manchester.

Prefix: : <<http://www.semanticweb.org/estratigrafia/ontologies/2016/1/facies#>>

Prefix: owl: <<http://www.w3.org/2002/07/owl#>>

Prefix: rdf: <<http://www.w3.org/1999/02/22-rdf-syntax-ns#>>

Prefix: rdfs: <<http://www.w3.org/2000/01/rdf-schema#>>

Prefix: swrl: <<http://www.w3.org/2003/11/swrl#>>

Prefix: swrlb: <<http://www.w3.org/2003/11/swrlb#>>

Prefix: xml: <<http://www.w3.org/XML/1998/namespace>>

Prefix: xsd: <<http://www.w3.org/2001/XMLSchema#>>

Ontology: <<http://www.semanticweb.org/estratigrafia/ontologies/2016/1/facies>>

Datatype: rdf:PlainLiteral

Datatype: xsd:string

ObjectProperty: geradaPor

Characteristics:

Functional,

Irreflexive,

Asymmetric

Domain:

FaciesSedimentar

Range:

ProcessoDeposicional

ObjectProperty: temEstruturaSedimentar

<sup>1</sup>Este modelo está disponível em OWL em <[http://www.inf.ufrgs.br/~jlcarbonera/?page\\_id=153](http://www.inf.ufrgs.br/~jlcarbonera/?page_id=153)>

Characteristics:

Irreflexive,  
Asymmetric

Domain:

FaciesSedimentar

Range:

EstruturaSedimentar

DataProperty: arredondamento

Characteristics:

Functional

Domain:

FaciesSedimentar

Range:

xsd:string

DataProperty: cor

Characteristics:

Functional

Domain:

FaciesSedimentar

Range:

xsd:string

DataProperty: esfericidade

Characteristics:

Functional

Domain:  
FaciesSedimentar

Range:  
xsd:string

DataProperty: gradacaoDeCamada

Characteristics:  
Functional

Domain:  
FaciesSedimentar

Range:  
xsd:string

DataProperty: gradacaoDeLamina

Characteristics:  
Functional

Domain:  
FaciesSedimentar

Range:  
xsd:string

DataProperty: granulometria

Characteristics:  
Functional

Domain:  
FaciesSedimentar

Range:  
xsd:string

DataProperty: litologia

Characteristics:  
Functional

Domain:  
FaciesSedimentar

Range:  
xsd:string

DataProperty: ocorrenciaDeGraosEspecificos

Characteristics:  
Functional

Domain:  
FaciesSedimentar

Range:  
xsd:string

DataProperty: orientacaoDeFabrica

Characteristics:  
Functional

Domain:  
FaciesSedimentar

Range:  
xsd:string

DataProperty: selecao

Characteristics:

Functional

Domain:

FaciesSedimentar

Range:

xsd:string

DataProperty: suporteDeFabrica

Characteristics:

Functional

Domain:

FaciesSedimentar

Range:

xsd:string

Class: CorrenteTrativa

SubClassOf:

ProcessoDeposicional

Class: CorrenteTrativaSubAerea

SubClassOf:

CorrenteTrativa

Class: CorrenteTrativaSubAquosa

SubClassOf:

CorrenteTrativa

Class: CorrenteTrativaSubAquosaComRegimeDeFluxoInferior

SubClassOf:

CorrenteTrativaSubAquosaMovendoAreiaESilte

Class: CorrenteTrativaSubAquosaComRegimeDeFluxoSuperior

SubClassOf:

CorrenteTrativaSubAquosaMovendoAreiaESilte

Class: CorrenteTrativaSubAquosaMovendoAreiaESilte

SubClassOf:

CorrenteTrativaSubAquosa

Class: CorrenteTrativaSubAquosaMovendoCascalho

SubClassOf:

CorrenteTrativaSubAquosa

Class: EstratificacaoCruzada

SubClassOf:

EstruturaDeposicional

Class: EstratificacaoCruzadaAcanalada

SubClassOf:

EstratificacaoDeAltoAngulo

Class: EstratificacaoCruzadaDeMedioEGrandePorte

SubClassOf:

EstratificacaoCruzada

Class: EstratificacaoCruzadaDePequenoPorte

SubClassOf:

EstratificacaoCruzada

Class: EstratificacaoCruzadaHummocky

SubClassOf:

EstratificacaoOndulada

Class: EstratificacaoCruzadaPlanar

SubClassOf:

EstratificacaoDeAltoAngulo

Class: EstratificacaoCruzadaSigmoidal

SubClassOf:

EstratificacaoDeAltoAngulo

Class: EstratificacaoCruzadaTangencial

SubClassOf:

EstratificacaoDeAltoAngulo

Class: EstratificacaoDeAltoAngulo

SubClassOf:

EstratificacaoCruzadaDeMedioEGrandePorte

Class: EstratificacaoDeBaixoAngulo

SubClassOf:

EstratificacaoCruzadaDeMedioEGrandePorte

Class: EstratificacaoOndulada

SubClassOf:

EstruturaDeposicional

Class: EstratificacaoPlanoParalela

SubClassOf:

EstruturaDeposicional

Class: EstruturaDeposicional

SubClassOf:

EstruturaSedimentar

Class: EstruturaSedimentar

Class: FaciesGeradaPorCorrenteTrativa

EquivalentTo:

FaciesSedimentar

and ((temEstruturaSedimentar some EstratificacaoCruzada)

or (temEstruturaSedimentar some EstratificacaoPlanoParalela))

SubClassOf:

FaciesSedimentar

DisjointWith:

FaciesGeradaPorFluxoGravitacional

Class: FaciesGeradaPorCorrenteTrativaSubAerea

SubClassOf:

FaciesGeradaPorCorrenteTrativa

DisjointWith:



FaciesGeradaPorCorrenteTrativaSubAquosa

Class: FaciesGeradaPorCorrenteTrativaSubAquosa

EquivalentTo:

FaciesGeradaPorCorrenteTrativa

and (((gradacaoDeLamina value "Ausente")

or (gradacaoDeLamina value "Normal"))

or ((ocorrenciaDeGraosEspecificos value "ExtraClastos")

or (ocorrenciaDeGraosEspecificos value "IntraClastos"))

or (selecao value "MalSelecionado"))

SubClassOf:

FaciesGeradaPorCorrenteTrativa

DisjointWith:

FaciesGeradaPorCorrenteTrativaSubAerea

Class: FaciesGeradaPorCorrenteTrativaSubAquosaComRegimeDeFluxoInferior

EquivalentTo:

FaciesGeradaPorCorrenteTrativaSubAquosaMovendoAreiaESilte

and (temEstruturaSedimentar some EstratificacaoDeAltoAngulo)

SubClassOf:

FaciesGeradaPorCorrenteTrativaSubAquosaMovendoAreiaESilte

DisjointWith:

FaciesGeradaPorCorrenteTrativaSubAquosaComRegimeDeFluxoSuperior

Class: FaciesGeradaPorCorrenteTrativaSubAquosaComRegimeDeFluxoSuperior

EquivalentTo:

FaciesGeradaPorCorrenteTrativaSubAquosaMovendoAreiaESilte

and ((temEstruturaSedimentar some EstratificacaoDeBaixoAngulo)

or (temEstruturaSedimentar some EstratificacaoPlanoParalela))

SubClassOf:

FaciesGeradaPorCorrenteTrativaSubAquosaMovendoAreiaESilte

DisjointWith:

FaciesGeradaPorCorrenteTrativaSubAquosaComRegimeDeFluxoInferior

Class: FaciesGeradaPorCorrenteTrativaSubAquosaMovendoAreiaESilte

EquivalentTo:

FaciesGeradaPorCorrenteTrativaSubAquosa

and ((litologia value "Arenito")

or (litologia value "Siltito"))

SubClassOf:

FaciesGeradaPorCorrenteTrativaSubAquosa

DisjointWith:

FaciesGeradaPorCorrenteTrativaSubAquosaMovendoCascalho

Class: FaciesGeradaPorCorrenteTrativaSubAquosaMovendoCascalho

EquivalentTo:

FaciesGeradaPorCorrenteTrativaSubAquosa

and (litologia value "Conglomerado")

SubClassOf:

FaciesGeradaPorCorrenteTrativaSubAquosa

DisjointWith:

FaciesGeradaPorCorrenteTrativaSubAquosaMovendoAreiaESilte

Class: FaciesGeradaPorFluxoGravitacional

SubClassOf:

FaciesSedimentar

DisjointWith:

FaciesGeradaPorCorrenteTrativa

Class: FaciesGeradaPorMigracaoDeAntiDunas

EquivalentTo:

FaciesGeradaPorCorrenteTrativaSubAquosaComRegimeDeFluxoSuperior  
and (temEstruturaSedimentar some EstraticacaoDeBaixoAngulo)

SubClassOf:

FaciesGeradaPorCorrenteTrativaSubAquosaComRegimeDeFluxoSuperior

DisjointWith:

FaciesGeradaPorMigracaoDeFormasDeLeitoPlanos

Class: FaciesGeradaPorMigracaoDeDunas2D

EquivalentTo:

FaciesGeradaPorCorrenteTrativaSubAquosaComRegimeDeFluxoInferior  
and (temEstruturaSedimentar some EstraticacaoCruzadaPlanar)

SubClassOf:

FaciesGeradaPorCorrenteTrativaSubAquosaComRegimeDeFluxoInferior

Class: FaciesGeradaPorMigracaoDeDunas3D

EquivalentTo:

FaciesGeradaPorCorrenteTrativaSubAquosaComRegimeDeFluxoInferior  
and (temEstruturaSedimentar some EstraticacaoCruzadaAcanalada)

SubClassOf:

FaciesGeradaPorCorrenteTrativaSubAquosaComRegimeDeFluxoInferior

Class: FaciesGeradaPorMigracaoDeDunasLinguoides

EquivalentTo:

FaciesGeradaPorCorrenteTrativaSubAquosaComRegimeDeFluxoInferior  
and (temEstruturaSedimentar some EstraticacaoCruzadaSigmoidal)

SubClassOf:

FaciesGeradaPorCorrenteTrativaSubAquosaComRegimeDeFluxoInferior

Class: FaciesGeradaPorMigracaoDeDunasLongitudinais

EquivalentTo:

FaciesGeradaPorCorrenteTrativaSubAquosaMovendoCascalho  
and (temEstruturaSedimentar some EstratificacaoPlanoParalela)  
and (orientacaoDeFabrica value "Imbricada")

SubClassOf:

FaciesGeradaPorCorrenteTrativaSubAquosaMovendoCascalho

Class: FaciesGeradaPorMigracaoDeDunasTransversais

EquivalentTo:

FaciesGeradaPorCorrenteTrativaSubAquosaMovendoCascalho  
and (temEstruturaSedimentar some EstratificacaoCruzadaPlanar)

SubClassOf:

FaciesGeradaPorCorrenteTrativaSubAquosaMovendoCascalho

Class: FaciesGeradaPorMigracaoDeFormasDeLeitoPlanos

EquivalentTo:

FaciesGeradaPorCorrenteTrativaSubAquosaComRegimeDeFluxoSuperior  
and (temEstruturaSedimentar some EstratificacaoPlanoParalela)

SubClassOf:

FaciesGeradaPorCorrenteTrativaSubAquosaComRegimeDeFluxoSuperior

DisjointWith:

FaciesGeradaPorMigracaoDeAntiDunas

Class: FaciesGeradaPorMigracaoDeRipples

EquivalentTo:

FaciesGeradaPorCorrenteTrativaSubAquosaComRegimeDeFluxoInferior

and (temEstruturaSedimentar some LaminacaoCruzadaDeMarcasDeCorrente)

SubClassOf:

FaciesGeradaPorCorrenteTrativaSubAquosaComRegimeDeFluxoInferior

Class: FaciesGeradaPorPreenchimentoDePequenosCanais

EquivalentTo:

FaciesGeradaPorCorrenteTrativaSubAquosaMovendoCascalho

and (temEstruturaSedimentar some EstratificacaoCruzadaAcanalada)

SubClassOf:

FaciesGeradaPorCorrenteTrativaSubAquosaMovendoCascalho

Class: FaciesGeradaPorProcessoOscilatorio

SubClassOf:

FaciesSedimentar

Class: FaciesGeradaPorProcessoSuspensivo

SubClassOf:

FaciesSedimentar

Class: FaciesSedimentar

Class: FluxoGravitacional

SubClassOf:

ProcessoDeposicional

Class: LaminacaoCruzadaCavalgante

SubClassOf:

EstratificacaoDeAltoAngulo

Class: LaminacaoCruzadaComMarcasOnduladasEAnguloDeCavalgamentoCritico

SubClassOf:

EstratificacaoCruzadaDePequenoPorte

Class: LaminacaoCruzadaComMarcasOnduladasEAnguloDeCavalgamentoSubCritico

SubClassOf:

EstratificacaoCruzadaDePequenoPorte

Class: LaminacaoCruzadaComMarcasOnduladasEAnguloDeCavalgamentoSupercritico

SubClassOf:

EstratificacaoCruzadaDePequenoPorte

Class: LaminacaoCruzadaDeMarcasDeCorrente

SubClassOf:

EstratificacaoDeAltoAngulo

Class: LaminacaoCruzadaDeMarcasOnduladasDeOndas

SubClassOf:

EstratificacaoOndulada

Class: LaminacaoCruzadaSwaley

SubClassOf:

EstratificacaoOndulada

Class: LaminacaoParalela

SubClassOf:

EstruturaDeposicional

Class: Macica

SubClassOf:  
EstruturaDeposicional

Class: MigracaoDeAntiDunas

SubClassOf:  
CorrenteTrativaSubAquosaComRegimeDeFluxoSuperior

Class: MigracaoDeDunas2D

SubClassOf:  
CorrenteTrativaSubAquosaComRegimeDeFluxoInferior

Class: MigracaoDeDunas3D

SubClassOf:  
CorrenteTrativaSubAquosaComRegimeDeFluxoInferior

Class: MigracaoDeDunasLinguoides

SubClassOf:  
CorrenteTrativaSubAquosaComRegimeDeFluxoInferior

Class: MigracaoDeDunasLongitudinais

SubClassOf:  
CorrenteTrativaSubAquosaMovendoCascalho

Class: MigracaoDeDunasTransversais

SubClassOf:

CorrenteTrativaSubAquosaMovendoCascalho

Class: MigracaoDeFormasDeLeitoPlanos

SubClassOf:

CorrenteTrativaSubAquosaComRegimeDeFluxoSuperior

Class: MigracaoDeRipples

SubClassOf:

CorrenteTrativaSubAquosaComRegimeDeFluxoInferior

Class: PreenchimentoDePequenosCanais

SubClassOf:

CorrenteTrativaSubAquosaMovendoCascalho

Class: ProcessoDeposicional

Class: ProcessoOscilatorio

SubClassOf:

ProcessoDeposicional

Class: ProcessoSuspensivo

SubClassOf:

ProcessoDeposicional

DisjointClasses:

FaciesGeradaPorMigracaoDeDunas2D,

FaciesGeradaPorMigracaoDeDunas3D,

FaciesGeradaPorMigracaoDeDunasLinguoides,



FaciesGeradaPorMigracaoDeRipples

DisjointClasses:

FaciesGeradaPorMigracaoDeDunasLongitudinais,  
FaciesGeradaPorMigracaoDeDunasTransversais,  
FaciesGeradaPorPreenchimentoDePequenosCanais

Rule:

CorrenteTrativa(?p),  
geradaPor(?f, ?p) ->  
FaciesGeradaPorCorrenteTrativa(?f)

Rule:

CorrenteTrativaSubAerea(?p),  
geradaPor(?f, ?p) ->  
FaciesGeradaPorCorrenteTrativaSubAerea(?f)

Rule:

CorrenteTrativaSubAquosa(?p),  
geradaPor(?f, ?p) ->  
FaciesGeradaPorCorrenteTrativaSubAquosa(?f)

Rule:

CorrenteTrativaSubAquosaComRegimeDeFluxoInferior(?p),  
geradaPor(?f, ?p) ->  
FaciesGeradaPorCorrenteTrativaSubAquosaComRegimeDeFluxoInferior(?f)

Rule:

CorrenteTrativaSubAquosaComRegimeDeFluxoSuperior(?p),  
geradaPor(?f, ?p) ->  
FaciesGeradaPorCorrenteTrativaSubAquosaComRegimeDeFluxoSuperior(?f)

Rule:

CorrenteTrativaSubAquosaMovendoAreiaESilte(?p),  
geradaPor(?f, ?p) ->  
FaciesGeradaPorCorrenteTrativaSubAquosaMovendoAreiaESilte(?f)

Rule:

CorrenteTrativaSubAquosaMovendoCascalho(?p),  
geradaPor(?f, ?p) ->  
FaciesGeradaPorCorrenteTrativaSubAquosaMovendoCascalho(?f)

Rule:

```
FaciesGeradaPorCorrenteTrativa(?f),  
geradaPor(?f, ?p) ->  
CorrenteTrativa(?p)
```

Rule:

```
FaciesGeradaPorCorrenteTrativaSubAerea(?f),  
geradaPor(?f, ?p) ->  
CorrenteTrativaSubAerea(?p)
```

Rule:

```
FaciesGeradaPorCorrenteTrativaSubAquosa(?f),  
geradaPor(?f, ?p) ->  
CorrenteTrativaSubAquosa(?p)
```

Rule:

```
FaciesGeradaPorCorrenteTrativaSubAquosaComRegimeDeFluxoInferior(?f),  
geradaPor(?f, ?p) ->  
CorrenteTrativaSubAquosaComRegimeDeFluxoInferior(?p)
```

Rule:

```
FaciesGeradaPorCorrenteTrativaSubAquosaComRegimeDeFluxoSuperior(?f),  
geradaPor(?f, ?p) ->  
CorrenteTrativaSubAquosaComRegimeDeFluxoSuperior(?p)
```

Rule:

```
FaciesGeradaPorCorrenteTrativaSubAquosaMovendoAreiaESilte(?f),  
geradaPor(?f, ?p) ->  
CorrenteTrativaSubAquosaMovendoAreiaESilte(?p)
```

Rule:

```
FaciesGeradaPorCorrenteTrativaSubAquosaMovendoCascalho(?f),  
geradaPor(?f, ?p) ->  
CorrenteTrativaSubAquosaMovendoCascalho(?p)
```

Rule:

```
FaciesGeradaPorFluxoGravitacional(?f),  
geradaPor(?f, ?p) ->  
FluxoGravitacional(?p)
```

Rule:

FaciesGeradaPorMigracaoDeAntiDunas (?f),  
geradaPor (?f, ?p) ->  
MigracaoDeAntiDunas (?p)

Rule:

FaciesGeradaPorMigracaoDeDunas2D (?f),  
geradaPor (?f, ?p) ->  
MigracaoDeDunas2D (?p)

Rule:

FaciesGeradaPorMigracaoDeDunas3D (?f),  
geradaPor (?f, ?p) ->  
MigracaoDeDunas3D (?p)

Rule:

FaciesGeradaPorMigracaoDeDunasLinguoides (?f),  
geradaPor (?f, ?p) ->  
MigracaoDeDunasLinguoides (?p)

Rule:

FaciesGeradaPorMigracaoDeDunasLongitudinais (?f),  
geradaPor (?f, ?p) ->  
MigracaoDeDunasLongitudinais (?p)

Rule:

FaciesGeradaPorMigracaoDeDunasTransversais (?f),  
geradaPor (?f, ?p) ->  
MigracaoDeDunasTransversais (?p)

Rule:

FaciesGeradaPorMigracaoDeFormasDeLeitoPlanos (?f),  
geradaPor (?f, ?p) ->  
MigracaoDeFormasDeLeitoPlanos (?p)

Rule:

FaciesGeradaPorMigracaoDeRipples (?f),  
geradaPor (?f, ?p) ->  
MigracaoDeRipples (?p)

Rule:

FaciesGeradaPorPreenchimentoDePequenosCanais(?f),  
geradaPor(?f, ?p) ->  
PreenchimentoDePequenosCanais(?p)

Rule:  
FaciesGeradaPorProcessoOscilatorio(?f),  
geradaPor(?f, ?p) ->  
ProcessoOscilatorio(?p)

Rule:  
FaciesGeradaPorProcessoSuspensivo(?f),  
geradaPor(?f, ?p) ->  
ProcessoSuspensivo(?p)

Rule:  
FluxoGravitacional(?p),  
geradaPor(?f, ?p) ->  
FaciesGeradaPorFluxoGravitacional(?f)

Rule:  
MigracaoDeAntiDunas(?p),  
geradaPor(?f, ?p) ->  
FaciesGeradaPorMigracaoDeAntiDunas(?f)

Rule:  
MigracaoDeDunas2D(?p),  
geradaPor(?f, ?p) ->  
FaciesGeradaPorMigracaoDeDunas2D(?f)

Rule:  
MigracaoDeDunas3D(?p),  
geradaPor(?f, ?p) ->  
FaciesGeradaPorMigracaoDeDunas3D(?f)

Rule:  
MigracaoDeDunasLinguoides(?p),  
geradaPor(?f, ?p) ->  
FaciesGeradaPorMigracaoDeDunasLinguoides(?f)

Rule:  
MigracaoDeDunasLongitudinais(?p),

geradaPor(?f, ?p) ->  
FaciesGeradaPorMigracaoDeDunasLongitudinais(?f)

Rule:  
MigracaoDeDunasTransversais(?p),  
geradaPor(?f, ?p) ->  
FaciesGeradaPorMigracaoDeDunasTransversais(?f)

Rule:  
MigracaoDeFormasDeLeitoPlanos(?p),  
geradaPor(?f, ?p) ->  
FaciesGeradaPorMigracaoDeFormasDeLeitoPlanos(?f)

Rule:  
MigracaoDeRipples(?p),  
geradaPor(?f, ?p) ->  
FaciesGeradaPorMigracaoDeRipples(?f)

Rule:  
PreenchimentoDePequenosCanais(?p),  
geradaPor(?f, ?p) ->  
FaciesGeradaPorPreenchimentoDePequenosCanais(?f)

Rule:  
ProcessoOscilatorio(?p),  
geradaPor(?f, ?p) ->  
FaciesGeradaPorProcessoOscilatorio(?f)

Rule:  
ProcessoSuspensivo(?p),  
geradaPor(?f, ?p) ->  
FaciesGeradaPorProcessoSuspensivo(?f)



## APÊNDICE C — CONJUNTO DE DADOS SOBRE FÁCIES SEDIMENTARES

A seguir, apresenta-se o conjunto de dados<sup>1</sup> sobre fácies sedimentares utilizado nos experimentos realizados no Capítulo 4 para avaliar a performance do sistema para interpretação automática de processos deposicionais. Os conjunto de dados está representado no formato ARFF.

---

<sup>1</sup>Este conjunto de dados está disponível no formato ARFF em <[http://www.inf.ufrgs.br/~jlcarbonera/?page\\_id=151](http://www.inf.ufrgs.br/~jlcarbonera/?page_id=151)>

```

@relation faciesSedimentares

@attribute esfericidade { Alta, Media, Baixa }
@attribute selecao { MaisSelecionado, ModeradamenteSelecionado, MuitoMalSelecionado, MuitoBemSelecionado, BemSelecionado }
@attribute arredondamento { SubArredondado, MuitoAngular, BemArredondado, SubAngular, Arredondado, Angular }
@attribute cor { LaranjaEscuroAmarelado, CinzaClaroMedio, AmareloCrepusculo, RoxoAcinzentado,
VerdeAmareladoEscuro, LaranjaAcinzentado, VerdeEscuro, LaranjaAmareladoPalido,
VerdeAzulModerado, AzulMuitoPalido, VermelhoMuitoCrepusculo, VerdeModerado,
OliveAcinzentado, AzulVerdeEscuro, CinzaAzuladoMedio, VerdeAmareladoCrepusculo,
PretoAcastanhado, RosaPalido, AmareloEsverdeadoModerado, AzulDesbotado,
MarromAmareladoEscuro, VermelhoNegrecido, AmareloEsverdeadoEscuro, MarromAmareladoCrepusculo,
RoxoVermelhoMuitoCrepusculo, MarromAvermelhadoPalido, MarromEscuroAvermelhado,
MarromAmareladoPalido, VerdeOlivePalido, RosalaranjaModerado, VerdeAmareloCrepusculo,
PretoEsverdeado, MarromModerado, MarromPalido, VermelhoAcinzentado, AzulPalido,
CorDeRosaAlaranjadaModerada, CinzaEsverdeadoEscuro, CorDeRosaModerado, LaranjaRosaAcinzentado,
RosaModerado, CinzaEscuroMedio, VermelhoModerado, MarromEscuro, RoxoVermelhoPalido,
CastanhoClaro, OlivePalido, VerdeBrilhante, AzulCrepusculo, BrancoAzulado,
VerdeAcinzentado, VerdeClaro, CorDeRosaLaranjaModerado, AmareloVerdeAcinzentado,
VermelhoPalido, VerdeAzulClaro, MarromAmareladoModerado, CinzaAmarronado,
CorDeRosaAcinzentado, VerdePalido, LaranjaMuitoPalido, CinzaOliveClaro,
VerdeAmareladoPalido, AmareloEsverdeadoPalido, VerdeAmareloEscuro, MarromAvermelhadoModerado,
AzulModerado, AzulClaro, CinzaOlive, PretoAmarronado, MarromAvermelhadoEscuro,
VerdeMuitoPalido, Preto, CinzaEscuro, VerdeAmareloAcinzentado, LaranjaAmareladoEscuro,
VerdeAmareloModerado, MarromClaro, OliveClaro, CinzaMuitoClaro, VermelhoRoxoAcinzentado,
VermelhoCrepusculo, RoxoMuitoCrepusculo, AzulAcinzentado, VerdeOliveClaro,
CinzaClaroAmarronado, AmareloEscuro, AzulDesbotadoOuPalido, VerdeOliveAcinzentado,
CinzaEsverdeado, MarromOliveClaro, VermelhoPurpuraPalido, VerdeAzulPalido,
PretoAcinzentado, VerdeCrepusculo, CinzaEsverdeadoClaro, RoxoPalido,
LaranjaAvermelhadoModerado, VerdeAzulCrepusculo, CinzaMedio, CorDeRosaLaranjaAcinzentado,
VermelhoMuitoEscuro, AzulVerdeAcinzentado, CorDeRosaAlaranjadaCinzenta, MarromEscuroAmarelado,
Branco, MarromAcinzentado, CinzaRosado, RoxoVermelhoCinzento, CinzaAcastanhadoClaro,
CinzaClaro, AmareloAcinzentado, CinzaAmarelado, VerdeAzulAcinzentado, CinzaAzuladoClaro,
PretoLiva, VerdeAmareladoModerado, VermelhoClaro, AmareloModerado, MuitoEscuroVermelhoRoxo,
RosaAcinzentado, MarromOliveModerado }
@attribute gradacaoDeLamina { Inversa, Ausente, Normal }
@attribute gradacaoDeCamada { Inversa, Ausente, Normal }

```







?, MalSelecionado, ?, ?, Ausente, ?, ?, ?, ?, Arenito, T, F, F, F, F, F, F, F, F, F, F, MigracaoDeFormasDeLeitoPlanos  
 ?, MalSelecionado, ?, ?, Ausente, ?, ?, ?, ?, Arenito, F, F, F, F, F, F, F, T, F, F, MigracaoDeDunas3D  
 ?, MalSelecionado, ?, ?, Ausente, ?, ?, ?, ?, Arenito, F, F, F, F, F, F, F, F, T, F, F, MigracaoDeDunas2D  
 ?, ?, ?, Ausente, ?, ?, ?, ?, Arenito, F, F, F, T, F, F, F, F, F, F, MigracaoDeRipples  
 ?, ?, ?, Inversa, ?, ?, ?, ?, Arenito, F, T, F, F, F, F, F, F, F, F, F, CorrenteTratativaSubAerea  
 ?, ?, ?, ?, ?, ?, ?, Conglomerado, F, F, F, T, F, F, F, F, F, F, FluxoGravitacional  
 ?, ?, ?, Ausente, ?, ?, ?, SuportadoPelaMatriz, Conglomerado, T, F, F, F, F, F, F, F, F, F, F, CorrenteTratativa  
 ?, MalSelecionado, ?, ?, Ausente, ?, ?, ?, ?, Arenito, T, F, F, F, F, F, F, F, F, F, F, MigracaoDeFormasDeLeitoPlanos  
 ?, MalSelecionado, ?, ?, Ausente, ?, ?, ?, ?, Arenito, F, F, F, F, F, F, F, T, F, F, MigracaoDeDunas3D  
 ?, MalSelecionado, ?, ?, Ausente, ?, ?, ?, ?, Arenito, F, F, F, F, F, F, F, T, F, F, MigracaoDeDunas2D  
 ?, ?, ?, Ausente, ?, ?, ?, ?, Arenito, F, F, F, T, F, F, F, F, F, F, MigracaoDeRipples  
 ?, ?, ?, Ausente, ?, ?, ?, ?, Arenito, F, F, F, T, F, F, F, F, F, F, MigracaoDeRipples  
 ?, ?, ?, Inversa, ?, ?, ?, ?, Arenito, F, T, F, F, F, F, F, F, F, F, F, CorrenteTratativaSubAerea  
 ?, ?, ?, Ausente, ?, ?, ?, ?, Conglomerado, T, F, F, F, F, F, F, F, F, F, F, F, MigracaoDeDunasLongitudinais  
 ?, ?, ?, Ausente, ?, ?, ?, ?, Arenito, T, F, F, F, F, F, F, F, F, F, F, MigracaoDeFormasDeLeitoPlanos  
 ?, ?, ?, Ausente, ?, ?, ?, ?, Arenito, F, F, F, F, F, F, F, T, F, F, MigracaoDeDunas3D  
 ?, ?, ?, Ausente, ?, ?, ?, ?, Arenito, F, F, F, F, F, F, F, T, F, F, MigracaoDeDunas2D  
 ?, ?, ?, Ausente, ?, ?, ?, ?, Arenito, F, F, F, T, F, F, F, F, F, F, MigracaoDeRipples  
 ?, ?, ?, Ausente, ?, ?, ?, ?, Arenito, F, F, F, T, F, F, F, F, F, F, MigracaoDeRipples  
 ?, ?, ?, Ausente, Ausente, ?, ?, SuportadoPelosGraos, Conglomerado, F, F, F, T, F, F, F, F, F, F, FluxoGravitacional  
 ?, ?, ?, Inversa, ?, ?, ?, SuportadoPelosGraos, Conglomerado, F, F, F, F, F, F, F, F, F, F, FluxoGravitacional  
 ?, ?, ?, Normal, ?, ?, ?, SuportadoPelosGraos, Conglomerado, F, F, F, F, F, F, F, F, F, F, FluxoGravitacional  
 ?, ?, ?, ?, ?, ?, SuportadoPelosGraos, Conglomerado, F, F, F, F, F, F, F, F, F, F, FluxoGravitacional  
 ?, ?, ?, ?, ?, ?, SuportadoPelosGraos, Conglomerado, F, F, F, F, F, F, F, F, F, F, FluxoGravitacional  
 ?, ?, ?, ?, ?, ?, SuportadoPelosGraos, Conglomerado, F, F, F, F, F, F, F, F, F, F, FluxoGravitacional  
 ?, ?, ?, Ausente, ?, ?, ?, Arenito, T, F, F, F, F, F, F, F, F, F, F, MigracaoDeFormasDeLeitoPlanos  
 ?, ?, ?, Ausente, ?, ?, ?, Arenito, F, F, F, F, F, F, F, T, F, F, MigracaoDeDunas3D  
 ?, ?, ?, Ausente, ?, ?, ?, Arenito, F, F, F, F, F, F, F, T, F, F, MigracaoDeDunas2D  
 ?, ?, ?, ?, ?, ?, ?, Arenito, F, F, F, F, F, F, F, F, F, F, FluxoGravitacional  
 ?, ?, ?, Inversa, Normal, ?, ?, ?, Arenito, F, F, F, F, F, F, F, F, F, F, F, CorrenteTratativaSubAerea  
 ?, ?, ?, ?, ?, ?, ?, Arenito, T, F, F, F, F, F, F, F, F, F, F, CorrenteTratativa  
 ?, BenSelecionado, ?, ?, ?, ?, ?, Arenito, T, F, F, F, F, F, F, T, T, F, CorrenteTratativa  
 ?, BenSelecionado, ?, ?, ?, ?, ?, Arenito, F, F, T, F, F, T, F, F, T, F, F, T, ProcessoOscilatorio  
 ?, ?, ?, ?, ?, ?, ?, Arenito, F, T, F, F, T, F, F, F, T, ProcessoOscilatorio  
 ?, ?, ?, ?, ?, ?, ?, Silito, F, F, F, F, F, F, F, F, F, FluxoGravitacional  
 ?, ?, ?, ?, Ausente, ?, ?, Imbricada, SuportadoPelosGraos, Conglomerado, T, F, F, F, F, F, F, F, F, F, MigracaoDeDunasLongitudinais

? , ? , ? , Ausente , ? , ? , SuportadoPelosGraos, Conglomerado, F, F, F, F, F, T, F, F, F, PreenchimentoDePequenosCanais  
 ? , ? , ? , Ausente, ? , ? , ? , Arenito, F, F, F, T, F, F, F, F, F, FluxoGravitacional  
 ? , ? , ? , Ausente, ? , ? , ? , Arenito, T, F, F, F, F, F, F, F, F, MigracaoDeFormasDeLeitoPlanos  
 ? , ? , ? , Ausente, ? , ? , ? , Arenito, F, F, F, F, F, F, T, F, F, F, MigracaoDeDunas3D  
 ? , ? , ? , Ausente, ? , ? , ? , Arenito, F, F, F, F, F, F, T, F, F, MigracaoDeDunas2D  
 ? , ? , ? , Ausente, ? , ? , ? , Arenito, F, F, F, T, F, F, F, F, F, MigracaoDeRipples  
 ? , MuitoMalSelecionado, ? , ? , Ausente, ? , ? , ? , Arenito, F, F, F, T, F, F, F, F, FluxoGravitacional  
 ? , ? , ? , Ausente, ? , ? , ? , Argillito, F, F, F, T, F, F, F, F, F, ProcessoSuspensivo  
 ? , ? , ? , Ausente, ? , ? , ? , Argillito, F, F, F, T, F, F, F, F, F, ProcessoSuspensivo  
 ? , MalSelecionado, ? , ? , Ausente, ? , ? , ? , Argillito, F, F, F, T, F, F, F, F, F, ProcessoSuspensivo  
 ? , ? , ? , Ausente, ? , ? , ? , Arenito, F, F, F, F, F, F, T, F, F, F, CorrenteTrativaSubAguosaComRegimeDeFluxoInferior  
 ? , ? , ? , Ausente, ? , ? , ? , Arenito, F, F, F, F, F, F, T, F, F, F, F, F, MigracaoDeRipples  
 ? , ? , ? , Ausente, ? , ? , ? , Argillito, F, F, T, F, F, F, F, F, F, ProcessoSuspensivo  
 ? , ? , ? , Ausente, ? , ? , ? , Argillito, F, F, T, F, F, F, F, F, F, ProcessoSuspensivo