

UNIVERSIDADE DE LISBOA

FACULDADE DE PSICOLOGIA
FACULDADE DE CIÊNCIAS
FACULDADE DE MEDICINA
FACULDADE DE LETRAS



**MODELO COMPUTACIONAL DE ORGANIZAÇÃO
HIERÁRQUICA E CATEGORIZAÇÃO DA MEMÓRIA
SEMÂNTICA:**

**IDENTIFICAÇÃO DO NÍVEL HIERÁRQUICO DO CONCEITO A PARTIR DO
GRAU DE PARTILHA DOS SEUS ATRIBUTOS.**

Ana Teresa Santos

MESTRADO EM CIÊNCIA COGNITIVA

2011

MODELO COMPUTACIONAL DE ORGANIZAÇÃO HIERÁRQUICA E CATEGORIZAÇÃO DA MEMÓRIA SEMÂNTICA:

**IDENTIFICAÇÃO DO NÍVEL HIERÁRQUICO DO CONCEITO A PARTIR DO GRAU DE
PARTILHA DOS SEUS ATRIBUTOS.**

Ana Teresa Fernandes Santos

Dissertação submetida para obtenção do grau de
MESTRE EM CIÊNCIA COGNITIVA

PELA
UNIVERSIDADE DE LISBOA

FACULDADE DE PSICOLOGIA
FACULDADE DE CIÊNCIAS
FACULDADE DE MEDICINA
FACULDADE DE LETRAS

Orientador:

José Frederico Marques da Faculdade de Psicologia

Co-Orientador:

Luís Miguel Correia da Faculdade de Ciências

Outubro de 2011

Abstract

The computational modeling of semantic memory dates from about the 1960's since it was created the first computational model for the understanding of its organization and structure. The several theories concerning the organization of semantic memory conducts to a paradox where the basic level of categorization presents advantage by healthy subjects in semantic tasks, but in a situation of semantic dementia, the superordinate level is more easily identifiable or accessible.

Recently it was discovered that the feature sharedness of the concepts contributed to the differentiation of their hierarchical level. Based on this parameter, it was constructed a computational neural network model in a connectionist perspective, that was able to correctly identify the hierarchical level of a concept by analyzing the degree of feature sharedness.

The second objective of the model was to create categories on the basis of similarities of patterns created by the set of the concepts attributes in different domains. The results observed confirmed that the feature sharedness parameter contributes to the hierarchical differentiation of the concepts, but perhaps due to the limited number of concepts and their attributes, we could not confirm the hypothesis of categorization and clustering of domain concepts.

The third objective of the model was to verify the behavior of a lesioned network and compare its results with the observed in real patients. After conducting the learning process of the network and analyzed the results for a healthy simulation, several lesions were made on the original network and compared the results. Lesions were made at the connections level and the neurons level. The connections lesions resulted in a worst performance network for the superordinate concepts. By injuring the network connections and limiting its processing capacity we can make a parallel of these results with the need of higher processing for superordinate concepts due to the increased difficulty to coordinate information less shared. The (artificial) neuronal lesions produced symptoms similar to those found in real patients. The network performance decreases deeply for basic level concepts, but remained satisfactory for the superordinate level concepts still able to identify those at this level.

Keywords: Semantic memory, feature sharedness, deterioration of memory, connectionist models, neural networks.

Resumo

A modelação computacional da memória semântica remonta aproximadamente a partir da década de 60 desde que foi criado o primeiro modelo computacional com vista à compreensão da sua organização e estrutura. As várias teorias sobre a organização da memória semântica resultam num paradoxo de categorização onde o nível básico apresenta vantagem em tarefas semânticas em sujeitos saudáveis, mas numa situação de demência semântica, é o nível sobreordenado que se mostra mais facilmente identificável ou acessível.

Descobriu-se recentemente que o grau de partilha dos atributos de um conceito contribuí para a diferenciação do seu nível hierárquico. Com base neste parâmetro, foi construído um modelo computacional de redes neuronais numa perspectiva conexionista, com o objectivo de identificar corretamente o nível hierárquico de um conceito a partir do valor de partilha dos seus atributos. Como segundo objectivo, pretendia-se que o modelo fosse capaz de criar categorias a partir das semelhanças de padrões criadas pelo conjunto de atributos dos conceitos para diferentes domínios. Os resultados obtidos confirmaram que o parâmetro 'partilha' contribui para a diferenciação hierárquica dos conceitos. No entanto, devido ao pouco número de conceitos e respectivos atributos, não foi possível confirmar a hipótese de categorização e agrupamento de conceitos por domínio.

Como terceiro objectivo, pretendia-se verificar o comportamento de uma rede lesionada e comparar os seus resultados com o observado em pacientes reais. Uma vez treinada a rede e analisados os resultados para uma simulação de uma rede saudável, foram feitas várias lesões sobre a rede original e comparados os seus resultados. Foram simuladas lesões ao nível das conexões e ao nível dos neurónios. As lesões ao nível das conexões resultaram num pior desempenho da rede para os conceitos do nível sobreordenado. Ao lesionar as conexões da rede, limitámos a sua capacidade de processamento podendo fazer um paralelismo destes resultados com a necessidade de maior processamento para conceitos de nível sobreordenado devido à maior dificuldade de coordenação de informação menos partilhada. As lesões neuronais (artificiais) produziram os sintomas análogos aos encontrados em pacientes reais. O desempenho da rede diminuiu muito para os conceitos de nível básico, mas manteve-se satisfatória para os conceitos de nível sobreordenado conseguindo ainda identificá-los a este nível.

Palavras chave: Memória semântica, Partilha de atributos, Deterioração da memória, Modelos conexionistas, Redes Neuronais.

Agradecimentos

Nenhum projecto é possível de concretizar sem o apoio dos que nos rodeiam, fazem parte do nosso dia a dia e daqueles que sabem mais que nós.

Ao longo destes dois anos fui encontrando dificuldades que fui ultrapassando com ajuda de várias pessoas que contribuíram cada uma à sua maneira e no seu domínio para que este projecto fosse realizado.

Nunca poderia ter conseguido acabar o mestrado e a tese no prazo desejado se continuasse a trabalhar a tempo inteiro, por isso agradeço à NOESIS e em particular ao Nelson Pereira e Pedro Gonçalves por terem permitido que passasse a regime de tempo parcial e por toda a disponibilidade e boa vontade que demonstraram sempre que pedia para fazer trocas e baldrocas nos dias de trabalho porque precisava de mais tempo para estudar para exames, fazer trabalhos ou acabar a tese.

Agradeço aos meus orientadores, Frederico Marques e Luís Correia, por toda a ajuda que me deram, pela sua orientação e pela paciência que às vezes é preciso ter quando enviava versões atrás de versões, dúvidas atrás de dúvidas e sempre se mostraram disponíveis para mim.

Logicamente deixo grande agradecimento à minha família que me apoia em todos os momentos da minha vida. A minha mãe é e sempre foi o meu pilar e está sempre comigo nem que seja para dizer, “Vai tudo correr bem!”. O meu irmão é meu professor de estatística e está sempre disponível para me ajudar no que for necessário, e o meu namorado é uma peça fundamental para a minha serenidade e bem estar, que sem isso não se consegue fazer nada.

Não me esqueço dos meus colegas do mestrado, das opiniões que trocávamos e do apoio que íamos dando uns aos outros que penso que nos ajudou a todos a continuar e a chegar onde estamos.

E por fim, mas não em último, agradeço a todos os meus amigos que demonstraram interesse pelo meu projecto, porque isso dá-me apoio, estímulo e força para continuar.

As palavras pouco valem, vale o sentimento. E os sentimentos espelham-se nos nossos actos, num sorriso ou num olhar. De certeza que a todos os que já agradei agora com palavras já agradei antes com um sorriso ou um abraço e sei que também sabem o quão importantes são para mim.

Índice

1.	Introdução	13
1.1.	Memória semântica.....	15
1.2.	Modelos Hierárquicos	19
1.3.	Modelos Conexionistas.....	21
1.4.	Modelos computacionais da memória semântica	26
1.4.1.	Modelos Semânticos Hierárquicos / Baseados em Categorias	26
1.4.1.1.	Modelos hierárquicos	26
1.4.1.2.	Modelos baseados em categorias / protótipos	28
1.4.1.3.	Questões / Limitações	28
1.4.2.	Modelos Semânticos Distribuídos	29
1.4.2.1.	Modelo de Hinton (1981)	29
1.4.2.2.	Modelo de Rumelhart.....	30
1.4.2.3.	Modelo de Rogers e colegas (2004).....	34
1.5.	Paradoxo vantagem Nível Básico vs Nível Sobreordenado.....	36
2.	Apresentação da proposta	38
2.1.	Modelo	39
2.1.1.	Seleção dos dados.....	39
2.1.2.	Análise dos dados	40
2.1.3.	Arquitectura	42
2.1.4.	Aprendizagem da Rede Neuronal	44
2.1.5.	Lesionar a rede	48
3.	Resultados.....	51
3.1.	Identificação do nível hierárquico dos conceitos	51
3.2.	Categorização de conceitos	53
3.3.	Rede lesionada	57
3.3.1.	Lesões ao nível das conexões	57

3.3.2.	Lesões ao nível dos neurónios	62
4.	Conclusão	68
4.1.	Discussão	68
4.2.	Trabalho futuro	71
5.	Referências	72
Anexos	75	
I.	Rede Neuronal	75
II.	Padrão Treino	80
III.	Padrão Teste	83
IV.	Seleção dos Dados	84

Índice de figuras

<i>Figura 1:</i> Estrutura Hierárquica da Memória Semântica segundo o modelo de Collins e Quillian (1969).....	19
<i>Figura 2:</i> Representação semântica de um conceito segundo os modelos conexionistas (adaptado de Rogers & Patterson, 2007).	22
<i>Figura 3:</i> Representação organização de informação em níveis de especificidade. (adaptado de Rogers & Patterson, 2007).	24
<i>Figura 4:</i> Representação das ligações ‘é um’, ‘pode’ e ‘tem’ que relacionam conceitos e atributos segundo o modelo de Collins e Quillian (1969).....	26
<i>Figura 5:</i> Esquema da teoria de propagação da activação (adaptado de Collins & Loftus, 1975).	27
<i>Figura 6:</i> Arquitectura do modelo de Hinton (adaptado de Hinton G. E., 1981).	29
<i>Figura 7:</i> Modelo de Rumelhart (adaptado de Rumelhart, 1990; Rumelhart & Todd, 1993)	32
<i>Figura 8:</i> Padrões de activação ao longo do processo de aprendizagem de conceitos de diferentes categorias. (adaptado de Rogers & McClelland, 2004)	33
<i>Figura 9:</i> Arquitectura do modelo computacional da memória semântica de Rogers e colegas	35
<i>Figura 10:</i> Relação Nível-Partilha por Nível Hierárquico para a média de valores de partilha dos dados seleccionados.	40
<i>Figura 11:</i> Relação Nível-Partilha por conceito para a média de valores de partilha dos dados seleccionados.	41
<i>Figura 12:</i> Arquitectura do modelo	42
<i>Figura 13:</i> Simulações da rede neuronal com uma camada escondida de 6 a 15 neurónios. Para cada simulação é apresentado o erro mínimo obtido pelo extremo do traço vertical inferior, erro máximo representado pelo extremo do traço vertical superior, o 1º e 4º quartis pelos contornos inferior e superior da caixa azul e a mediana representada pelo traço horizontal existente na caixa azul.	43
<i>Figura 14:</i> Aprendizagem da rede. A linha vermelha representa o erro do conjunto de validação e a linha preta o erro do conjunto de treino.	46
<i>Figura 15:</i> Resultados do registo de experiências da rede N10. A linha azul representa os erros obtidos em cada simulação e a linha preta a média dos erros de validação.	47
<i>Figura 16:</i> Activação dos conceitos do conjunto de treino. Todos os conceitos de nível básico tiveram uma activação do neurónio representativo do nível básico na ordem dos 0,9 ou	

superior representado pelas barras vermelhas, dado que o valor máximo seria 1. O mesmo se verificou para os conceitos de nível sobreordenado em que a activação do neurónio representativo do nível sobreordenado rondou também os 0,9 ou superior representado pelas barras roxas.....52

Figura 17: Activação dos conceitos do conjunto de teste. Todos os conceitos de nível básico tiveram uma activação do neurónio representativo do nível básico na ordem dos 0,84 ou superior representado pelas barras vermelhas, dado que o valor máximo seria 1. O mesmo se verificou para os conceitos de nível sobreordenado em que a activação do neurónio representativo do nível sobreordenado rondou também os 0,84 ou superior representado pelas barras roxas.53

Figura 18: Padrões de activação por conceito – categoria. As várias cores representam o valor de activação dos 10 neurónios da camada escondida para cada conceito.54

Figura 19: Padrão de activação de cão e toupeira. As várias cores representam o valor de activação dos 10 neurónios da camada escondida para cada conceito.55

Figura 20: Correlação dos vários conceitos-categorias. Conceitos altamente correlacionados apresentam uma cor verde (conceitos com as mesmas características) ou cor vermelha (conceitos com características opostas).....55

Figura 21: Identificação dos conceitos do conjunto de treino das redes lesionadas ao nível das conexões. As linhas vermelhas correspondem aos resultados da rede saudável e as linhas azuis aos resultados das redes lesionadas, em que o azul mais escuro representa a lesão mais leve (lesão 1) e o azul mais claro a lesão mais severa (lesão 5).58

Figura 22: Média da identificação dos conceitos do conjunto de treino das redes lesionadas ao nível das conexões.60

Figura 23: Identificação dos conceitos do conjunto de teste das redes lesionadas ao nível das conexões.61

Figura 24: Média da identificação dos conceitos do conjunto de teste das redes lesionadas ao nível das conexões.61

Figura 25: Identificação dos conceitos do conjunto de treino das redes lesionadas ao nível dos neurónios. A barra vermelha representa a simulação saudável e as lesões são representadas pelas barras azuis, dado que o azul mais escuro representa a lesão mais superficial (lesão 1) e o azul mais claro a lesão mais severa (lesão 5).63

Figura 26: Média da identificação dos conceitos do conjunto de treino das redes lesionadas ao nível dos neurónios.65

Figura 27: Identificação dos conceitos do conjunto de teste das redes lesionadas ao nível dos neurónios.66

Figura 28: Média da identificação dos conceitos do conjunto de teste das redes lesionadas ao nível dos neurónios.66

Figura 29: Comparação entre as simulações de lesão de nível 5. Dados do conjunto de treino e teste.67

Índice de tabelas

Tabela 1: <i>Exemplos de tarefas semânticas executadas em pacientes com demência semântica.</i>	17
Tabela 2: <i>Seleção dos conceitos utilizados para a construção do modelo computacional. Conceitos distribuídos por 3 categorias, cada uma com conceitos do nível básico e correspondente nível sobreordenado.</i>	39
Tabela 3: <i>Padrões de Teste e Treino da Rede Neuronal.</i>	44
Tabela 4: <i>Output geral da rede neuronal.</i>	51
Tabela 5: <i>Plano de lesões ao nível das conexões</i>	57
Tabela 6: <i>Activação do conceito de nível básico do conjunto de treino das redes lesionadas ao nível das conexões</i>	59
Tabela 7: <i>Activação do conceito de nível sobreordenado do conjunto de treino das redes lesionadas ao nível das conexões</i>	60
Tabela 8: <i>Plano de lesões ao nível dos neurónios</i>	62
Tabela 9: <i>Activação do conceito de nível básico do conjunto de treino das redes lesionadas ao nível dos neurónios.</i>	64
Tabela 10: <i>Activação do conceito de nível sobreordenado do conjunto de treino das redes lesionadas ao nível dos neurónios.</i>	65

1. Introdução

A modelação cognitiva ocupa um papel central na ciência cognitiva para o estudo e representação da estrutura dos fenómenos inerentes à cognição humana.

Na investigação dos fenómenos psicológicos e biológicos, têm sido usados modelos computacionais com o objectivo de melhor compreender processos cognitivos como a atenção, memória, linguagem e raciocínio. Na construção computacional dos modelos são seguidas principalmente duas abordagens, os modelos conexionistas (redes neuronais) e modelos simbólicos (manipulação de símbolos e conjunto de regras computacionais) (Polk & Seifert, 2002). Os modelos computacionais simbólicos estão habitualmente relacionados com a funções cognitivas como o raciocínio ou planeamento, enquanto que os modelos conexionistas, por terem uma estrutura mais semelhante ao cérebro humano, tentam modelar os aspectos da cognição humana como a memória ou atenção.

No projecto que em seguida apresento, pretendo estudar e investigar os processos e estrutura da memória semântica, através de um modelo computacional de redes neuronais. Tendo por base os atributos dos conceitos e o grau em que estes são partilhados pelas suas instâncias, procurei conceber um modelo capaz de identificar o nível hierárquico dos conceitos, avaliando se o grau de partilha contribui para a categorização e diferenciação do nível dos mesmos. É uma questão importante em várias áreas, nomeadamente nos estudos de demência semântica onde se observou que o conhecimento do nível sobreordenado se mostra mais robusto que o conhecimento do nível básico. Para além de identificar corretamente o nível hierárquico dos conceitos através do valor de partilha dos seus atributos, também analisei se através do conjunto de atributos de cada conceito se conseguem formar padrões de categorização identificando vários domínios como animais, plantas e objectos.

Depois de se conseguir identificar correctamente o nível hierárquico de cada conceito analisando o valor de partilha dos seus atributos, pretendi verificar qual o desempenho da rede quando criadas lesões na sua estrutura. Para isso criaram-se lesões de vários níveis e várias gravidades, com o objectivo de comparar o desempenho da rede com o comportamento de pacientes reais fazendo um paralelismo entre o funcionamento de uma estrutura lesionada artificial e real.

De entre os diversos estudos e modelos computacionais que abordam a estrutura da memória semântica, o estudo da partilha dos atributos e o seu impacto para a identificação do nível hierárquico dos conceitos ainda não tinha sido tido em consideração neste tipo de modelos, razão pela qual esta constitui a principal questão de investigação do presente trabalho.

O trabalho está organizado e estruturado da seguinte forma:

1. Apresentação das teorias e modelos que servem como base para a modelação computacional da memória semântica, onde são apresentadas as correntes hierárquicas e conexionistas e os modelos computacionais que já foram criados para a sua representação. Seguidamente é descrito o paradoxo de categorização da memória semântica em que o nível

básico apresenta vantagem em tarefas semânticas para sujeitos saudáveis, mas numa situação de demência semântica, é o nível sobreordenado que se mostra mais facilmente identificável ou acessível.

2. Na 'Apresentação da Proposta' é feita uma descrição do método de selecção de dados para a criação do modelo, arquitectura e aprendizagem. Nesta secção foi incluída uma subsecção onde é feita uma revisão da literatura relacionada com simulações de lesões neuronais em modelos computacionais semelhante ao que foi aqui criado.

3. Na secção dos Resultados é inicialmente apresentada a simulação da rede saudável e resultados inerentes à tarefa de identificação do nível hierárquico dos conceitos e da formação de categorias por domínio. Depois são apresentadas as alterações à rede para simular lesões ao nível das conexões e dos neurónios e respectivos resultados.

4. Finalmente na Conclusão é feita a discussão dos resultados obtidos, críticas e sugestões de trabalho futuro.

1.1. Memória semântica

Tulving (como citado em Schacter, Wagner, & Buckner, 2000) descreveu a memória semântica como o sistema que processa, armazena e recupera conhecimento geral sobre o mundo. O conhecimento semântico engloba um conjunto variado de informação organizada acerca do significado das palavras, conceitos e factos, incluindo o nome dos objectos, a definição das palavras e a fluência verbal. O conhecimento semântico é organizado numa rede de associações que nos ajudam a codificar um conceito. Devido à rica representação de um conceito que é feita com base nas suas muitas características, o conhecimento semântico não está localizado numa única região cerebral. Estudos em pacientes com lesões corticais tornaram claro que é possível recuperar certas informações sobre um conceito em detrimento de outras, provando que o conhecimento semântico não é guardado como um todo numa única região, mas distribuído consoante a sua categoria (Kandel, Kupfermann, & Iversen, 2000).

Embora tanto a memória semântica e episódica sejam sistemas de memória explícita e declarativa, estas distinguem-se pelo seu tipo de conhecimento. A memória episódica está relacionada com experiências individuais e recordação de eventos ocorridos com o mesmo. O tipo de informação presente e guardado na memória semântica caracteriza-se por ser conhecimento não individual e único ao indivíduo, mas conhecimento comum aos indivíduos em geral (Warrington, 1975), como factos, conceitos e conhecimento geral. O comprometimento da memória episódica não compromete necessariamente a memória semântica e vice-versa, dado que é possível que um paciente não se consiga lembrar quando visitou o mosteiro da Batalha, mas saiba em que ano foi construído e qual a sua história ou vice-versa. Ao contrário da memória semântica que não está localizada numa região cerebral, as áreas do neocortex que parecem estar relacionadas com a memória episódica são as áreas associativas do lobo frontal. Estas áreas pré-frontais cooperam com outras áreas do neocortex para possibilitar a recuperação de memórias de quando e onde um evento passado ocorreu (Kandel, Kupfermann, & Iversen, 2000).

Relativamente ao aspecto funcional e organizacional da memória semântica, Rosch e colegas (Rosch et al, 1976; Rosch, 1978) propõem que o conhecimento do mundo está organizado em categorias, sendo uma categoria um conjunto de objectos considerados equivalentes. O principal objectivo de um sistema de categorias é fornecer o máximo de informação com o mínimo esforço cognitivo. O segundo objectivo é conseguir criar uma estrutura do conhecimento do mundo de uma forma estruturada em vez de um conjunto arbitrário ou imprevisível de atributos.

O sistema de categorias pode ser organizado numa dimensão vertical e horizontal. A dimensão vertical corresponde à relação das categorias entre si em vários níveis de inclusão, como: dalmata, cão, mamífero, animal e ser vivo. A dimensão horizontal corresponde à segmentação de categorias que se encontram no mesmo nível de inclusão, como: cão, gato, carro, ou cadeira. A dimensão vertical do sistema de categorias forma taxonomias. Uma taxonomia é um sistema onde categorias estão relacionadas umas com as outras em classes de inclusão. Conceitos do nível básico (ex: cão, cadeira) estão no nível mais inclusivo onde existem

atributos comuns à maior parte dos membros da categoria. Em conceitos do nível sobreordenado (ex: animal, mobília) os seus membros partilham apenas uma pequena quantidade de atributos entre si. Exemplos das categorias do nível subordinado (ex: dalmata, cadeira de jardim) são compostos por uma grande variedade de atributos comuns entre si criando mesmo algumas situações de sobreposição de atributos. Em sujeitos saudáveis, o nível intermédio de conhecimento, o chamado nível básico, está mais acessível, o que faz com que este nível de conceitos (ex: cão, carro, etc.) seja o mais utilizado no discurso livre e na categorização de objectos (Rosch, 1978; Rosch et al, 1976), a chamada vantagem do nível básico.

Murphy e Brownell na *Teoria da Diferenciação* (Murphy & Brownell, 1985) argumentam que os níveis das categorias de conceitos diferenciam-se através da distinção e informação dos seus atributos. Categorias do nível sobreordenado, têm informação mais generalizada, logo menos informativa acerca das características idiossincráticas do conceito, mas tal torna os conceitos mais distintos entre si porque existem menos atributos comuns entre categorias sobreordenadas. Ou seja, comparando por exemplo, os conceitos mobília e animal (conceitos do nível sobreordenado), existirão muito poucos atributos partilhados entre os dois conceitos, o que faz com o que as categorias mais gerais tenham um nível de distinção mais elevado. Por sua vez conceitos mais específicos, como por exemplo Dalmata e Dobermann (conceitos do nível subordinado), partilham muitos atributos (todos os atributos comum a cão). Apesar dos conceitos do nível subordinado serem altamente informativos, uma maior partilha de atributos faz com que estes se tornem muito pouco distintivos. O ponto de equilíbrio dá-se ao nível intermédio. O nível básico consegue ser informativo e distintivo, porque em categorias como cadeira e cão o próprio conceito consegue fornecer já alguma informação específica sobre os seus atributos, mas não existe uma partilha de atributos suficiente para que estes possam ser confundidos, tornando este nível de categorização informativo e distintivo, dando-lhe vantagem de acesso (Murphy & Brownell, 1985; Rosch et al, 1976).

Segundo a Teoria da Diferenciação, conceitos subordinados atípicos, como pinguim ou luvas de boxe, partilham das mesmas características que conceitos de nível básico típicos, o que os torna distintivos e informativos e explica o seu rápido acesso e diferenciação como os conceitos típicos do nível básico. Esta teoria foi confirmada em estudos onde era comparada a categorização de conceitos entre sujeitos leigos e especialistas, onde os especialistas categorizavam tão rapidamente conceitos do nível subordinado e conceitos de nível básico em contraste com os leigos que categorizavam mais rapidamente conceitos do nível básico. Os especialistas listavam mais atributos para os conceitos do nível subordinado o que os tornava mais distintivos por terem um maior número de características que os definem, tornando a sua informação mais completa e específica, o que faz com que tais conceitos se tornem mais distintivos entre si e melhor diferenciados (Tanaka & Taylor, 1991; Johnson & Mervis, 1997).

A vantagem do nível básico foi comprovada em vários estudos, sendo dos fenómenos mais robustos no estudo da categorização humana (Murphy & Brownell, 1985; Rogers & Patterson, 2007; Rosch et al, 1976; Jolicoeur, Gluck, & Kosslyn, 1984). Por sua vez, pacientes com danos ao nível da memória semântica, em particular com demência semântica mostram uma vantagem do nível sobreordenado, demonstrando uma preservação de acesso a informação

mais geral dos conceitos e uma perda de conhecimento mais específico (Warrigton, 1975; Hodges, Graham, & Patterson, 1995). Na Tabela 1 são apresentados alguns exemplos de pacientes em que foram executadas algumas tarefas semânticas e respectivos resultados.

Tabela 1: *Exemplos de tarefas semânticas executadas em pacientes com demência semântica.*

Pacientes	Tarefas	Resultados	Referência
AB; EM; CR Pacientes diagnosticados com demência semântica	Reconhecimento de figuras e palavras	Pacientes descreviam os itens em termos da sua categoria sobreordenada (ex: animal) ou classe geral (ex: contentor), não sendo capazes de dar descrições mais detalhadas ou uma definição do item.	(Warrigton, 1975)
	Reconhecimento visual por escolha múltipla	Desempenho relativamente bom para itens do nível sobreordenado; boa capacidade de diferenciação de plantas e animais. Pássaros, insectos, etc. conseguiam ser diferenciados uns dos outros dentro das categorias da classe animal; Capacidade para diferenciar animais a partir dos seus atributos e associações era muito pobre.	
	Reconhecimento visual através de questão semântica como: “É um animal?”	Desempenho relativamente à questão “É um pássaro?” para figuras de animais e “É encontrado em espaços fechados?” para figuras de objectos foi mau, mas ainda assim acima da resposta ao acaso, enquanto que questões mais associativas como “É Inglês?” ou comparações sobre atributos como “É mais pesado que uma lista telefónica?” decaiu para o nível da resposta ao acaso.	
	Reconhecimento auditivo de palavras conhecidas e desconhecidas	Conhecimento de categorias do nível sobreordenado muito mais intacto do que conhecimento de categorias do nível subordinado. Nas categorias classificadas como “conhecidas” verificou-se uma quantidade mínima de erros para as opções de nível sobreordenado e uma quantidade significativamente maior de erros para as opções de nível básico	
JL Paciente com indícios de demência semântica. Paciente acompanhado ao longo de 2 anos enquanto se ia agravando o seu estado.	Testes de fluência verbal em categorias	Numa fase inicial da doença, os testes estavam dentro dos limites nas categorias gerais de animais e objectos, mas não conseguia produzir instâncias de categorias específicas como raças de cães ou instrumentos musicais. Categorias mais comuns como cão, cavalo ou gato foram mantidas até uma fase mais severa da doença, mas como protótipos de instâncias da categoria animal.	(Hodges, Graham, & Patterson, 1995)
	Testes de ordenação	Descriminação entre seres vivos e seres não vivos foi mantida por um período de tempo substancial. Em paralelo foi observado um declínio acentuado na ordenação de categorias específicas e particularmente em características ou atributos	
	Nomeação de figuras	Progressiva perda das características das representações semânticas que permitem a discriminação entre as instancias de categorias específicas. Exemplo da nomeação de 2 animais ao longo das 4 sessões. Elefante: (1) elefante, (2) cavalo, (3) cavalo, (4) animal; Rinoceronte: (1) elefante, (2) cavalo, (3) cavalo, (4) cão.	

A demência semântica é uma doença neurológica que se caracteriza por um grave comprometimento da memória semântica, causando anomia e outras disfunções ao nível da linguagem, mas uma relativa preservação da memória episódica. Estudos em doentes com demência semântica demonstraram que estes não conseguem executar testes tradicionais de conhecimento público remoto, mas continuam a conseguir aceder facilmente a memórias autobiográficas (Hodges & McCarthy, 1996). Quando são feitas questões por exemplo sobre um elefante, este tipo de pacientes são capazes de dizer corretamente que é um animal, mas são incapazes de fornecer informação mais específica, como o habitat, forma, hábitos, etc. (Hodges, Graham, & Patterson, 1995). Warrigton (1975) foi pioneira em estudos de demência

semântica. Os seus resultados confirmam a facilidade dos doentes em aceder ao conhecimento do nível sobreordenado em detrimento do conhecimento do nível básico. Existindo danos das estruturas cerebrais ao nível da memória semântica, os pacientes já não conseguiam aceder a conhecimento mais específico mas ainda seria possível aceder a conhecimento mais geral.

1.2. Modelos Hierárquicos

Nesta secção apresento as correntes hierárquicas que dão origem a uma modelização computacional da memória semântica.

Considerando a organização hierárquica da memória semântica Collins e Quillian (1969) criam um modelo que descreve a organização do conhecimento semântico numa hierarquia vertical. Cada palavra é guardada com uma configuração de ponteiros para outras palavras em memória, criando uma configuração de ligações que representa o significado da palavra. A representação do conceito Dálmata como “um cão grande com manchas pretas” consiste na palavra Dálmata com um ponteiro para o nó cão que representa a categoria superior de Dálmata, e ponteiros para as suas propriedades ‘é grande’ e ‘tem manchas pretas’ como esquematizado na Figura 1. Informação geral a todos os cães “como ladrar” e “ter 4 patas”, não necessita de ser associada a cada nó representativo de cada tipo de cão, mas apenas ao nó cão, sendo os seus atributos herdados pelos nós inferiores. Deste modo é generalizada a informação aos conceitos dos nós inferiores, sendo inferido pelo facto de Dálmata ser um cão que este ladra e tem 4 patas, facilitando assim a generalização de informação de uma forma económica. Avaliando o tempo de processamento de frases verdadeiras e falsas, Collins e Quillian defenderam que a hierarquia de conceitos poderia ser percorrida em ambos os sentidos (de baixo para cima e vice-versa). No entanto consideram que seria mais eficiente verificar primeiro os conceitos mais específicos (nível inferior da hierarquia) pois as suas propriedades já lhes estão diretamente associadas não sendo necessário percorrer uma série de conexões para ter informação detalhada de um conceito.

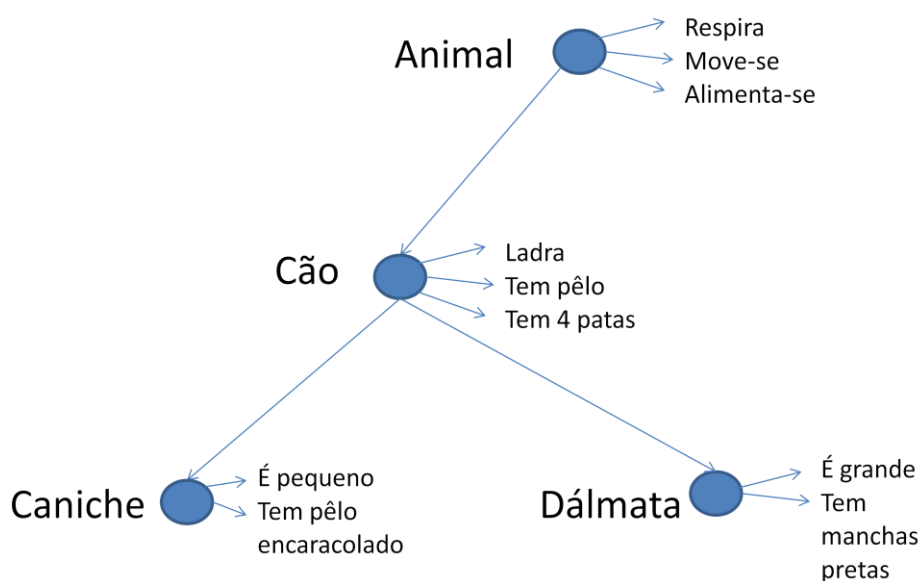


Figura 1: Estrutura Hierárquica da Memória Semântica segundo o modelo de Collins e Quillian (1969)

Uma das explicações hierárquicas para a vantagem semântica do nível básico, seria que o acesso à informação era feito inicialmente sempre a este nível e só depois é que a hierarquia semântica era percorrida para se aceder aos outros níveis de conhecimento. Desta forma, o ponto de entrada da hierarquia do conhecimento semântico não estaria no topo (nível sobreordenado) nem na base (nível subordinado) mas sim ao nível básico. O nível básico funcionaria como nível de entrada em resposta a um estímulo e para se aceder a um nível mais específico ou geral de informação seria necessário subir ou descer na hierarquia (Jolicoeur, Gluck, & Kosslyn, 1984; Rosch et al, 1976). Esta teoria foi rejeitada por Murphy e Brownell que justificam a vantagem do nível básico pelo facto dos conceitos a este nível serem mais distintivos e informativos assim como acontece para o nível subordinado de conceitos atípicos (Murphy & Brownell, 1985). Já Warrington (1975) analisando a robustez do conhecimento do nível sobreordenado em pacientes com demência semântica conclui que o acesso ao conhecimento semântico era feito numa perspectiva top-down, partindo do conhecimento mais abstracto e geral ao nível sobreordenado e só depois era feito o acesso ao conhecimento mais específico. Esta conclusão contradiz as teorias de entrada do acesso ao nível básico (Rosch et al, 1976; Jolicoeur, Gluck, & Kosslyn, 1984) e a rapidez de verificação das propriedades intrínsecas de um conceito devido ao acesso numa perspectiva bottom-up (Collins & Quillian, 1969). Este fenómeno criou um paradoxo relativamente ao acesso à memória semântica que será discutido em maior detalhe na secção '1.5 Paradoxo vantagem Nível Básico vs Nível Sobreordenado'.

1.3. Modelos Conexionistas

Além das várias questões que os modelos hierárquicos levantam quanto ao ponto de entrada do nível hierárquico, também é deixado em aberto como serão tratadas exceções no que trata à generalização de conhecimento. Se tomarmos como exemplo que o atributo “voar” é inerente ao conceito pássaro (válido para todos os pássaros), como se pode representar que a avestruz é um pássaro e não voa? Uma forma proposta por Collins e Quillian (1969) para responder a este tipo de exceções, seria introduzir no nó avestruz a informação que não voa, mas uma vez que este herdaria todos os atributos de pássaro, ficaria no mesmo nó informação contraditória, o que compromete a generalização de propriedades a conceitos. Outra questão problemática é a atribuição de categorias de um conceito. Por exemplo, os sujeitos identificam mais rapidamente que uma galinha é um animal do que galinha é um pássaro. Isto acontece porque galinha não é um caso típico de pássaro com o tipo de características que normalmente os caracterizam (tal como acontece com o pinguim ou avestruz). O que sugere que modelos que comparam representações de um item com categorias baseando-se na sua familiaridade fazem mais sentido do que modelos que apenas seguem uma hierarquia (McClelland & Rogers, 2003). Mas mesmo os modelos baseados em categorias, falham na generalização destes conceitos atípicos, porque apesar de melhor tolerarem exceções que desviam os conceitos da descrição típica que os caracteriza, coloca-os em classes (categorias) equivalentes onde essas exceções não são evidentes como por exemplo, tanto o conceito galinha como periquito são categorizados como um pássaro. Baseando-se nestas considerações, Rumelhart e colegas (1986) argumentaram que uma melhor caracterização do conhecimento não seria baseada numa entidade cognitiva pré-especificada (como um conceito ou categoria) mas como um padrão de características que emerge de um sistema cognitivo conexionista (Rogers & McClelland, 2004).

Numa avaliação da estrutura hierárquica de organização da memória semântica, Rapp e Caramazza (1989), sugeriram que a preservação do conhecimento sobreordenado numa situação de demência semântica seria justificada por uma “ativação semântica parcial”. Na procura do conhecimento semântico que caracteriza um conceito, apenas algumas das suas características se encontram preservadas (devido à deterioração das estruturas cerebrais envolvidas na recuperação de informação). As características semânticas que se mantêm activas, são aquelas mais gerais e por o conhecimento sobreordenado ser mais distintivo, esta informação é suficiente para corretamente identificar e categorizar os conceitos a este nível. Esta explicação vai de encontro ao observado no estudo de Hodges e colegas (1995) onde o paciente observado utilizou protótipos para a identificação dos animais (todos os animais grandes eram identificados como sendo um cavalo, animais médios como cão e aos animais pequenos chamava de gatos). Desta forma, Hodges e colegas propõem que a perda de acesso a conhecimento semântico mais específico deve-se à perda das suas ligações. Estes efeitos de prototipicidade normalmente são mais compatíveis com redes semânticas distribuídas do que com organizações hierárquicas, sendo esta afirmação apoiada por outros estudos (McClelland & Rogers, 2003; Rapp & Caramazza, 1989). Como alternativa aos modelos hierárquicos surgiram os modelos conexionistas distribuídos.

Nos modelos conexionistas da memória semântica, o processamento da informação faz-se através da propagação da activação entre unidades semânticas que se comportam como neurónios numa rede de processamento paralelo e distribuído. A informação semântica não é guardada num sítio específico, mas reconstruída em resposta a estímulos e criando padrões de activação (McClelland & Rogers, 2003; 2004). O conhecimento semântico é guardado e processado pelo conjunto de unidades semânticas e respectivos pesos, mas ao contrário dos modelos baseados em categorias que necessitam por vezes da criação de novas categorias para novo conhecimento, nos modelos conexionistas toda a informação semântica é guardada e processada nas mesmas estruturas. A generalização de conhecimento a novos conceitos resulta naturalmente como consequência das semelhanças entre os novos conceitos e os já existentes na rede e não de operações de categorização ou através de uma hierarquia (Rogers & McClelland, 2004). O significado de cada conceito é formado por diferentes representações (perceptual, visual, motor e linguística) mapeadas em diferentes regiões cerebrais como se pode ver esquematizado na Figura 2.

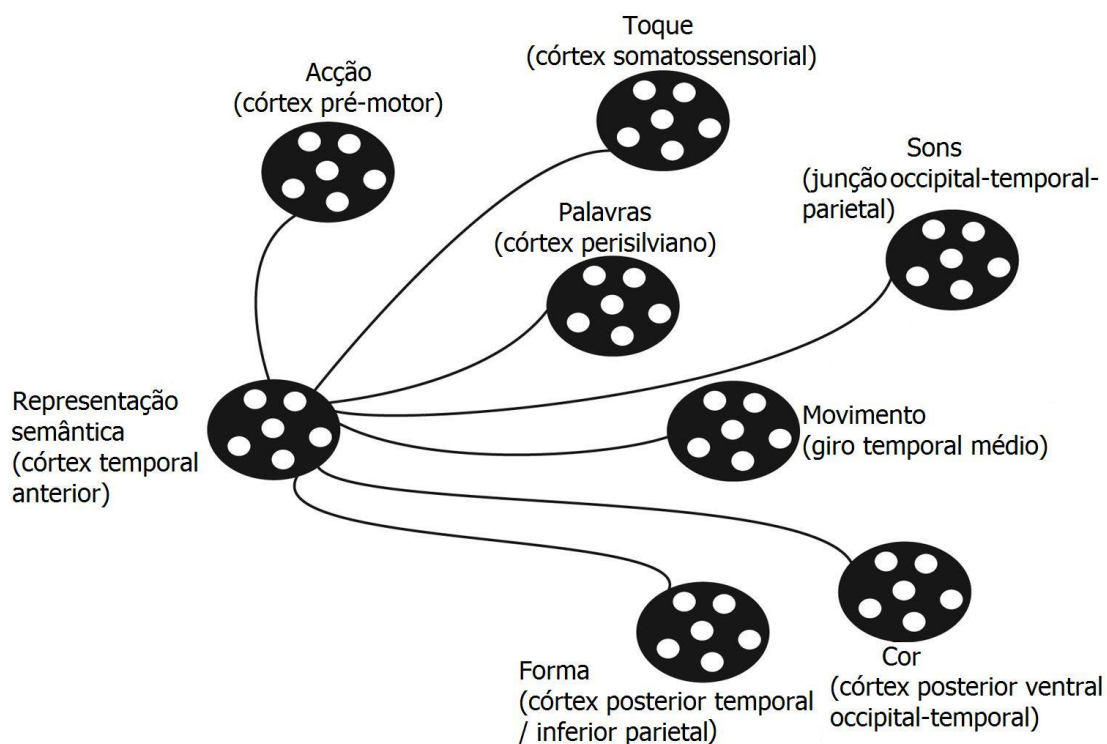


Figura 2: Representação semântica de um conceito segundo os modelos conexionistas (adaptado de Rogers & Patterson, 2007).

Em cada região estão instanciados diferentes padrões de actividade distribuídos pelos mesmos neurónios. É essa representação distribuída que define o significado de um conceito. Diferentes conceitos podem partilhar algumas características e respectivas representações neuronais, mas diferem em outras criando padrões de representação distintos porque a representação do conhecimento semântico está dependente do contexto. O contexto em que a informação está inserida tem um papel importante para o modo como será feita a

generalização da informação guardada a novos conceitos (Rogers & McClelland, 2004). Por exemplo, uma lâmpada e uma pêra têm uma forma semelhante, logo partilhariam essa representação de forma, mas todo o resto das suas características como funcionalidade, cor ou categoria são muito diferentes, activando zonas diferentes e assim criando padrões de activação bastante distintos (Rogers & Patterson, 2007). Conceitos da mesma categoria têm um padrão de activação semelhante mesmo diferindo em algumas características (como a forma no caso de uma pêra e banana) e conceitos de categorias diferentes produzem padrões distintos mesmo que algumas características sejam semelhantes (como a forma no caso de uma pêra e lâmpada). Assim se consegue fazer uma generalização da informação, ou seja, através do padrão de activação que representa a informação acerca de uma pêra, o sistema aprende que uma pêra tem sementes, come-se, etc. e tende a generalizar essa informação para outros tipos de fruta porque estes estão representados com padrões semelhantes de activação. Esta semelhança de padrões forma-se através do agrupamento das características e semelhanças de cada conceito com base nas suas várias representações (visual, motor, linguagem, etc.), portanto, itens que tenham várias características em comum serão representados como conceitos semelhantes (Rogers & McClelland, 2004; Rogers & Patterson, 2007).

Os conceitos são categorizados e diferenciados não só segundo o conjunto das suas características mas também consoante sua partilha de atributos. De acordo com a Teoria da diferenciação (Murphy & Brownell, 1985), também os modelos conexionistas defendem que os conceitos do nível básico tendem a ter uma maior partilha de atributos entre membros da mesma categoria e uma partilha menor entre categorias do mesmo nível. Por exemplo: diferentes tipos de cães são representados com padrões muito semelhantes (partilha de atributos entre membros da mesma categoria), mas outros animais como pássaros e répteis criam padrões mais distintos (partilha entre categorias do mesmo nível) e seres vivos e não vivos ainda mostram uma maior distinção de padrões. Conceitos sobreordenados são representados em padrões mais inclusivos e esparsos no espaço, bastante distintivos mas não informativos. Conceitos básicos correspondem a padrões mais estreitos e amplamente separados com uma representação relativamente informativa e distintiva. Finalmente, conceitos subordinados correspondem a padrões mais pequenos e menos separados correspondendo a informação mais detalhada mas menos distintiva (Rogers & Patterson, 2007). Esta inclusão de níveis e organização de informação em padrões está esquematizada na Figura 3.

O conhecimento semântico é guardado nos pesos que permitem ao sistema construir outputs apropriados em determinados contextos. Os pesos que codificam este conhecimento vão sendo gradualmente adaptados com a experiência de modo a melhorar o funcionamento do sistema.

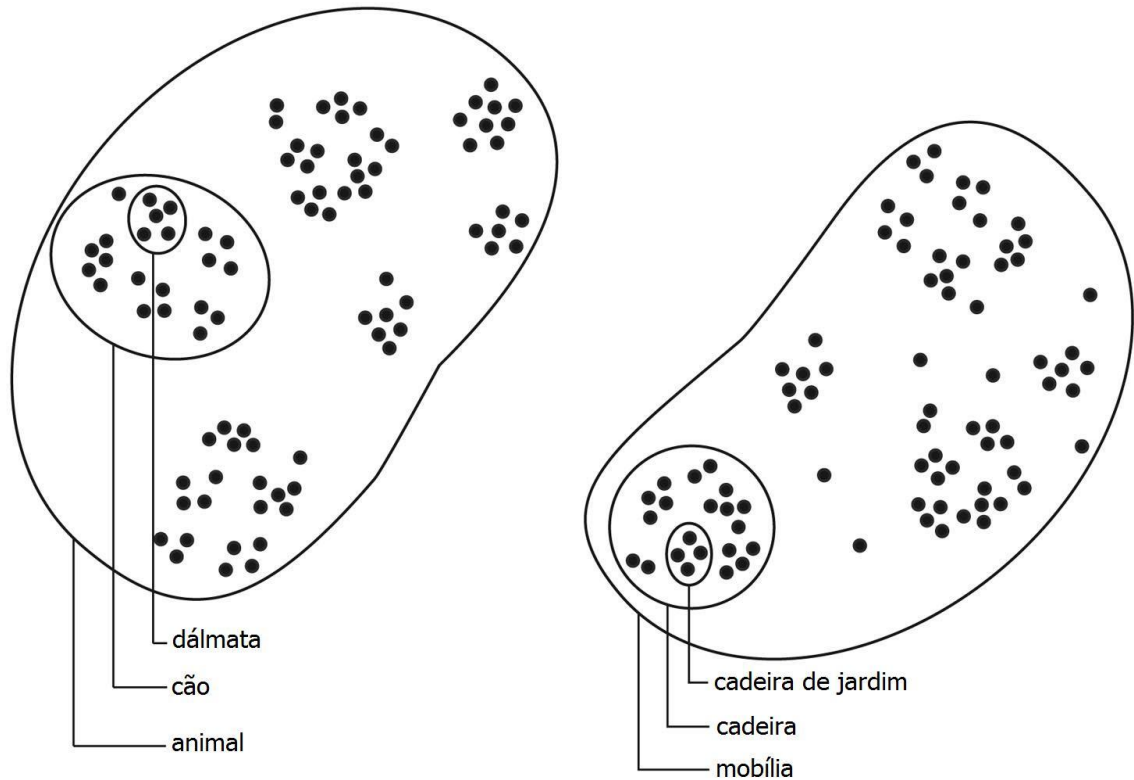


Figura 3: Representação organização de informação em níveis de especificidade. (adaptado de Rogers & Patterson, 2007).

Os modelos conexionistas explicam a vantagem do nível básico com a generalização de padrões no processo de aprendizagem. A semelhança de padrões constitui a base da generalização. É a partir deste mecanismo que o sistema adquire conhecimento de um objecto particular e das suas propriedades e, porque esse conhecimento é generalizado a outros itens com representações semelhantes, as propriedades partilhadas por um grupo de itens com representações semelhantes são aprendidas mais rapidamente que as propriedades que os distinguem (Rogers & McClelland, 2004). Tomando como exemplo a aprendizagem do conceito Dálmata. Sendo Dálmata um cão, serão activadas as unidades semânticas correspondentes a cão. Quando a rede procede à aprendizagem doutro conceito subordinado de cão, como por exemplo o dobermann, o processo de aprendizagem anterior tem de ser revisto e alterados os pesos das suas conexões de modo a diminuir a activação de dálmata e aumentar a activação de dobermann. Dados que ambos os conceitos (embora com algumas características diferentes) activam as unidades semânticas relativas a cão, esta alteração de pesos será generalizada a todos os cães. Sempre que é activado/aprendido um tipo de cão como dálmata ou dobermann, a resposta é fortemente generalizada a todos os tipos de cães acelerando a aprendizagem do conceito do nível básico cão e não de outros de conceitos (que não sejam cães) porque o conjunto de unidades activadas são tão diferentes que não existe uma generalização para esses conceitos por não haver interferência suficiente. A activação de conceitos como dálmata ou dobermann também activa o conceito animal, mas não tão fortemente porque apenas um conjunto de características de animal é activada não criando conexões tão fortes para o conceito animal, como para o conceito cão. Portanto a

generalização dos conceitos básicos é activada mais frequentemente e a sua aprendizagem mais rápida criando conexões mais fortes (Rogers & Patterson, 2007).

Devido à maior generalização de conceitos do nível básico, sujeitos saudáveis mostram uma vantagem de acesso a conceitos a este nível mas, numa situação de demência semântica, a informação está distorcida e a resposta ao estímulo activa padrões distorcidos devido aos neurónios que codificam o padrão correcto estarem danificados produzindo respostas potencialmente incorrectas. Numa situação de demência semântica pouco severa, poderá ser activado um padrão semelhante ao de um dálmata (outra raça de cão), mas numa situação mais severa o padrão activado poderá ser mais distorcido, contendo só algumas das características mais gerais de dálmata comuns a todos os animais (unidades semânticas mais vezes activadas), com conexões mais fortes o que será suficiente para ainda activar o padrão animal (Rogers & Patterson, 2007; Rogers & McClelland, 2004).

1.4. Modelos computacionais da memória semântica

1.4.1. Modelos Semânticos Hierárquicos / Baseados em Categorias

1.4.1.1. Modelos hierárquicos

A investigação computacional da memória semântica começou com a implementação de um modelo da memória semântica baseada na estrutura hierárquica da memória de Collins e Quillian (Collins & Quillian, 1969). Tal como descreve a teoria, a memória semântica era representada no modelo como um vasto conjunto de proposições simples (ex: “gatos têm pelos”, “canários podem cantar”, etc.). O modelo inicial de Collins e Quillian usa silogismos como base da organização do conhecimento e sua generalização. Tal como já explicado anteriormente, os conceitos são guardados em nós numa rede vertical e as relações entre conceitos estabelecidas por ligações entre os nós que os representam. Associado a cada nó existem as ligações ‘é um’, ‘pode’ e ‘tem’ que definem o tipo de ligação entre um conceito e atributo ou entre dois conceitos. A relação “um canário é um pássaro” é representada pela ligação ‘é um’ entre os nós pássaro e canário. A relação “um pássaro pode voar” é representada pela ligação ‘pode’ entre o conceito ‘pássaro’ e o atributo ‘voar’ como representado na Figura 4.

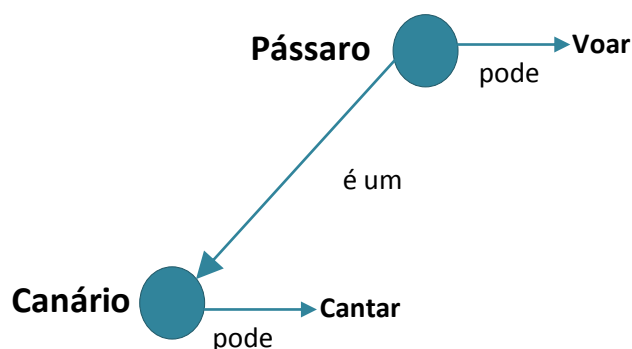


Figura 4: Representação das ligações ‘é um’, ‘pode’ e ‘tem’ que relacionam conceitos e atributos segundo o modelo de Collins e Quillian (1969).

Seguindo esta estrutura, os autores observaram que a partir deste sistema de ligação de proposições é possível criar um sistema económico de armazenamento e generalização de conhecimento. Para fazer inferências acerca de um conceito como canário, primeiro o modelo deve procurar os predicados associados ao seu nó (pode cantar), mas depois a procura segue a ligação para o(s) nó(s) superior(es) (pássaro) herdando os predicados que lhe(s) estão associados (pode voar). Na análise do tempo de verificação dos atributos de um conceito, os

autores observaram que os sujeitos em geral eram mais rápidos a verificar as propriedades directamente ligadas a um conceito do que as herdadas pelos conceitos dos nós superiores.

Em estudos posteriores verificou-se que os sujeitos acedem mais facilmente a conceitos mais gerais do que mais específicos e que a relação com a categoria influenciava o tempo de verificação das características de um conceito como acontece com os conceitos típicos e atípicos já explicado anteriormente. Esta e outras críticas levaram à reformulação do modelo original dando lugar a um novo modelo que se designou de 'Modelo de Propagação da Activação' (Collins & Loftus, 1975). Neste novo modelo o processo de procura das características de um conceito em vez de começar na base da hierarquia e ir subindo através das ligações de inclusão, é feito através de um mecanismo onde a activação de um conceito se propaga pelas várias ligações activando nós que estão relacionados com o nó ao qual se pretende definir como está representado na Figura 5.

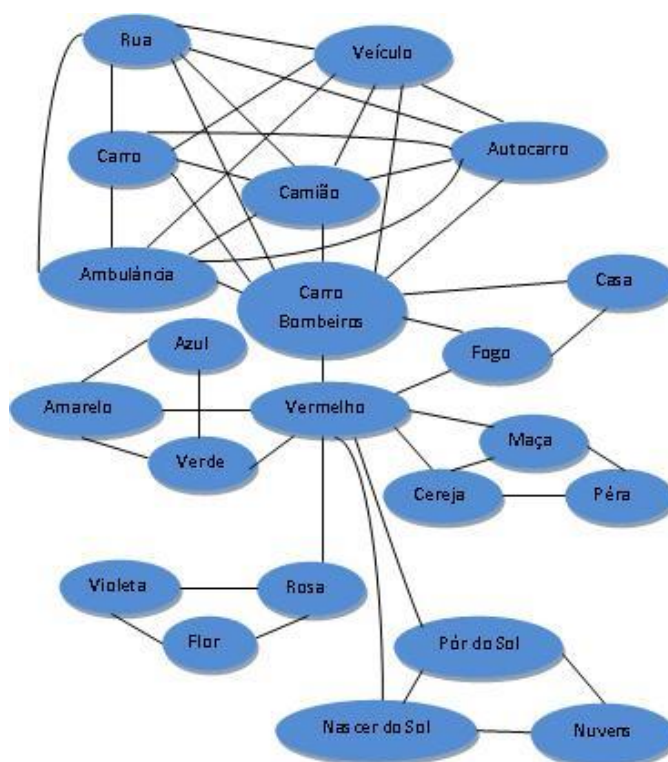


Figura 5: Esquema da teoria de propagação da activação (adaptado de Collins & Loftus, 1975).

Nesta nova teoria, a rigidez da hierarquia vertical original foi abandonada permitindo que se possam estabelecer ligações entre quaisquer pares de conceitos. O peso das conexões entre conceitos varia consoante o nó a que se está ligado, variando assim a rapidez com que identificam certas características de dado conceito. Desta forma, é possível justificar que é mais rápida a identificação de propriedades de conceitos típicos, porque estes estão ligados a itens mais gerais (com conexões mais fortes e mais activadas) que os conceitos atípicos e o sistema é mais rápido a determinar que um pinguim é um animal, estabelecendo a relação

directa entre pinguim e animal sem forçosamente o deduzir a partir da ligação pinguim -> pássaro -> animal.

Com esta reformulação à teoria original, o modelo corrigiu alguns problemas mas introduziu outros. Como todos os nós podem estar ligados entre si com diferentes pesos face a um item, não é claro qual o limite para a caracterização do mesmo, ou seja, quais os itens realmente necessários para a sua definição. Por exemplo, considerando a proposição “todas as bicicletas têm rodas”, esta afirmação relaciona os itens ‘bicicleta’ e ‘roda’, mas por sua vez a proposição “todas as rodas são redondas” relaciona os itens ‘roda’ e ‘redondo’. Como irá a rede evitar a activação do conceito ‘redondo’ quando o estímulo for bicicleta? Perdeu-se assim a generalização de informação de forma económica que era das principais vantagens do modelo original.

1.4.1.2. Modelos baseados em categorias / protótipos

Tal como já foi explicado anteriormente, a organização do conhecimento pode ser organizada em categorias como proposto por Rosch e colegas (Rosch, 1978; Rosch et al, 1976). Num processo de identificação e caracterização de um estímulo, o item é categorizado por comparação às categorias que servem como protótipos guardados no sistema. O item é relacionado com o protótipo que melhor se identifica e as características do protótipo atribuídas ao item em questão. A caracterização de um conceito depende principalmente das semelhanças entre o item e a categoria que serve de protótipo numa base de tudo ou nada (Rogers, 2008).

Rosch nunca mostrou interesse em fazer um modelo computacional com base nas suas teorias, mas estas serviram como base para a investigação e construção de modelos computacionais baseados na categorização de conceitos. Nos modelos baseados em categorias, a generalização de informação ocorre como consequência das semelhanças entre os conceitos e não como um processo de indução sobre proposições guardadas no sistema como é o caso da teoria de propagação da activação.

1.4.1.3. Questões / Limitações

Ambos os tipos de modelos apresentados levantam algumas questões e limitações relativamente a uma modelação da estrutura da memória semântica (Rogers, 2008):

1. Porque alguns conjuntos de itens formam categorias mais coerentes que outras e como o sistema semântico “sabe” que representações categoriais formar?
2. Porque algumas propriedades são mais importantes para a generalização de conhecimento e processo de indução de informação que outras, e como o sistema “sabe” quais as propriedade importantes para os conceitos?
3. Como o contexto pode ser representado, e como funciona para restringir que informação activar em determinada situação?

4. Como conceitos e propriedades abstractas são adquiridas?
5. Como pode o sistema combinar múltiplos conceitos de forma a representar eventos, cenas e relações entre objectos?

Veremos como os modelos semânticos distribuídos respondem a estas questões.

1.4.2. Modelos Semânticos Distribuídos

Modelos semânticos distribuídos baseiam-se nos modelos conexionistas já apresentados onde o conhecimento semântico é organizado numa rede distribuída de informação. A informação acerca dos conceitos é representada como um padrão de activação através de um conjunto de unidades semânticas semelhantes aos neurónios, onde o processamento da informação envolve uma conexão entre as várias unidades semânticas numa corrente de activações semelhantes às sinapses estabelecendo-se pesos associados às unidades activadas e às suas conexões. O armazenamento de nova informação na rede, não necessita de adicionar novos elementos à arquitectura estabelecida, precisando apenas de ajustar os pesos de forma a acomodar e reflectir o novo conhecimento (Rogers, 2008).

1.4.2.1. Modelo de Hinton (1981)

O primeiro modelo a seguir a teoria conexionista distribuída foi o modelo proposto por Hinton (1981). O modelo era organizado numa hierarquia com uma estrutura de proposições na forma Item-Relação-Atributo onde existe um conjunto de unidades semânticas para cada parte da proposição.

Cada uma destas camadas está recorrentemente ligada a uma quarta camada (camada PROP - Proposição) que não recebe estímulos do exterior, servindo esta camada apenas para processamento. Um esquema da arquitectura deste modelo pode ser visto na Figura 6.

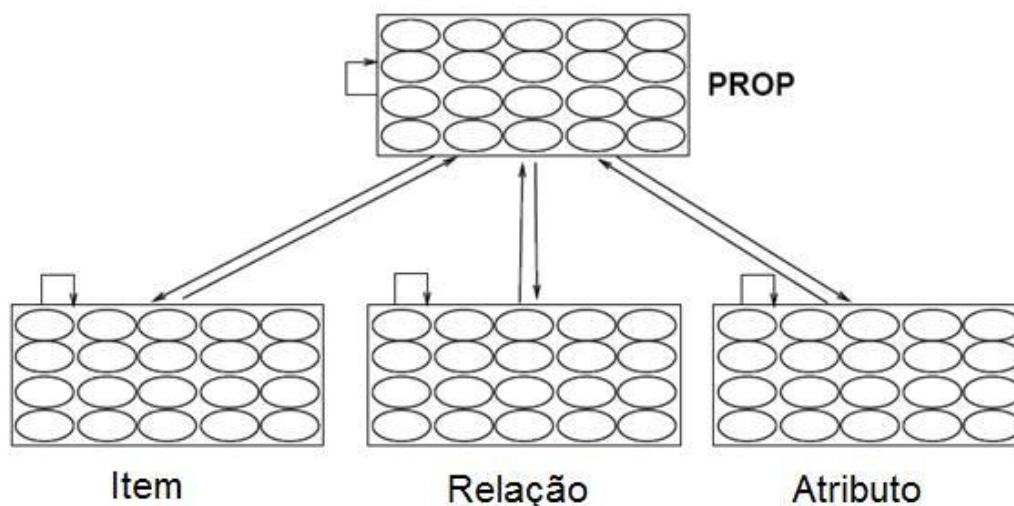


Figura 6: Arquitectura do modelo de Hinton (adaptado de Hinton G. E., 1981).

Diferentes pesos para cada camada são representados como padrões de activação diferentes através das unidades correspondentes. Por exemplo a representação da proposição “Clyde é cinzento” corresponde a um padrão de activação através das três camadas de input da rede. Item -> Clyde; Relação -> é; Atributo -> cinzento. O input gerado por estas três camadas irá gerar um input único na camada PROP para esta proposição, que por sua vez enviará novos sinais às camadas Item, Relação e Atributo para actualizarem os seus estados de acordo com os novos inputs. Este processo iterará até os estados da unidades pararem de sofrer actualizações, chegando a um ponto em que a rede estabiliza.

O modelo proposto por Hinton trouxe uma grande evolução face aos modelos existentes. Primeiro demonstrou a capacidade de completar uma proposição tendo apenas 2 termos como input. Face à proposição “Clyde é”, o modelo estando num estado estável depois de ter aprendido, com a representação da proposição correcta, é capaz de completar a proposição “cinzento” de acordo com o padrão guardado e a informação presente na camada Atributo. Segundo, várias proposições podem ser guardadas no mesmo conjunto finito de unidades e pesos, respeitando o princípio de economia. Terceiro, quando escolhidas representações de informação apropriadas, a rede fornece um mecanismo natural de generalização. Apresentado um sistema económico de armazenamento de informação e capacidade de generalização de informação guardada a novos estímulos, este modelo foi colmatar as falhas deixadas pelos modelos hierárquicos e baseados em categorias.

Em relação à questão 1 apresentada na secção anterior “Como o sistema semântico sabe que representações categoriais formar”, no modelo de Hinton não existem representações de categorias discretas, ou seja, não existe um conceito representado num nó ou num protótipo como nos modelos hierárquicos ou baseados em categorias. O conhecimento semântico é representado através de padrões de activação distribuídos nos mesmos conjuntos de unidades de processamento. Não existindo categorias coerentes e não coerentes, esta questão deixa de ser uma limitação para a implementação de um modelo computacional da memória semântica.

Contudo o modelo de Hinton levantou algumas questões relativamente à capacidade de aprender sem interferência e a generalização depende inteiramente de padrões de activação específicos. O modelo de Hinton está limitado às proposições inseridas nas camadas Item, Relação e Atributo e à combinação entre estas. Depois do processo de aprendizagem, cada proposição guardada é representada na rede por um único padrão de activação nas unidades da camada PROP. Levando a crer que teria uma capacidade algo limitada de representação de informação (Rogers, 2008).

1.4.2.2. Modelo de Rumelhart

Rumelhart (Rumelhart, 1990; Rumelhart & Todd, 1993) tentou ultrapassar a limitação da rede de Hinton provocado pela aprendizagem com padrões únicos e demasiado específicos, criando um modelo computacional baseado na estrutura hierárquica de Collins e Quillian (1969), com um sistema de treino e aprendizagem de uma rede conexionista treinada com o algoritmo de

aprendizagem retro-propagação do erro. O algoritmo calcula cada EW (Erro derivado dos pesos das conexões) começando por calcular o EA (diferença entre o output actual e o output desejado). Para calcular o EA para a camada escondida imediatamente anterior à camada de output, primeiro são identificados todos os pesos entre os neurónios da camada escondida e os neurónios da camada de saída à qual estão conectados. Estes pesos são então multiplicados pelos EAs das unidades de saída e são adicionados os produtos. Esta soma representa o valor do EA para as unidades da camada escondida que antecede a camada de saída. Depois de calculado o valor de EA da camada escondida anterior à camada de saída, é feito o mesmo cálculo para as outras camadas, passando de camada em camada na direcção oposta à direcção de activação. Este movimento retrógrado é o responsável pelo nome do algoritmo retro-propagação do erro (backpropagation) (Hinton G. E., *How Neural Networks Learn from Experience*, 2002; Haykin, 1994).

O modelo de Rumelhart consiste numa adaptação do modelo de Hinton, onde continuam a existir as camadas 'Item', 'Relação' e 'Atributo' e camadas escondidas de processamento mas com uma organização e conexão diferente. As várias camadas ligam-se entre si e comunicam numa organização feed-forward (ligação unilateral em que a camada anterior se conecta com a camada em frente) como representado na Figura 7. As camadas à esquerda (Item e Relação) recebem estímulo do exterior (camada de input).

Numa comparação do modelo hierárquico de Collins e Quillian, a camada Item representa os nós inferiores da base da hierarquia e a camada Relação representa as ligações entre os vários nós. Na camada Atributo (camada de output) são representadas todas as possíveis combinações das proposições de três termos considerados verdadeiros para os conceitos (McClelland & Rogers, 2003).

Os padrões de activação são iniciados nas unidades das camadas Item e Relação, propagando-se pelo resto da rede activando as unidades das outras camadas através dos pesos das suas conexões. Para um bom desempenho, a rede precisa de encontrar uma configuração de pesos que produza os estados correctos das unidades da camada de output para o input recebido. Para encontrar o valor apropriado para os pesos das conexões, o modelo é treinado com o algoritmo de aprendizagem retro-propagação do erro (backpropagation), onde inicialmente os pesos são inicializados com valores aleatórios e em cada iteração os pesos são comparados com os valores desejados e ajustados de modo a diminuir a distância entre o observado e o desejado.

Tal como no modelo de Hinton (1981), a semelhança entre as relações aprendidas e guardadas na rede, é a base para a generalização de conhecimento e informação semântica a novos conceitos. Inicialmente, devido aos valores aleatórios dos pesos (que são bastante aproximados) as representações de todos os padrões que representam os conceitos são semelhantes. Contudo, à medida que o modelo vai sendo iterado e os pesos ajustados, algumas representações vão sendo diferenciadas, enquanto que outras se manterão semelhantes de acordo com a partilha de atributos que definem os conceitos e formam os padrões de activação e categorias através das unidades de Representação (Rumelhart & Todd, 1993).

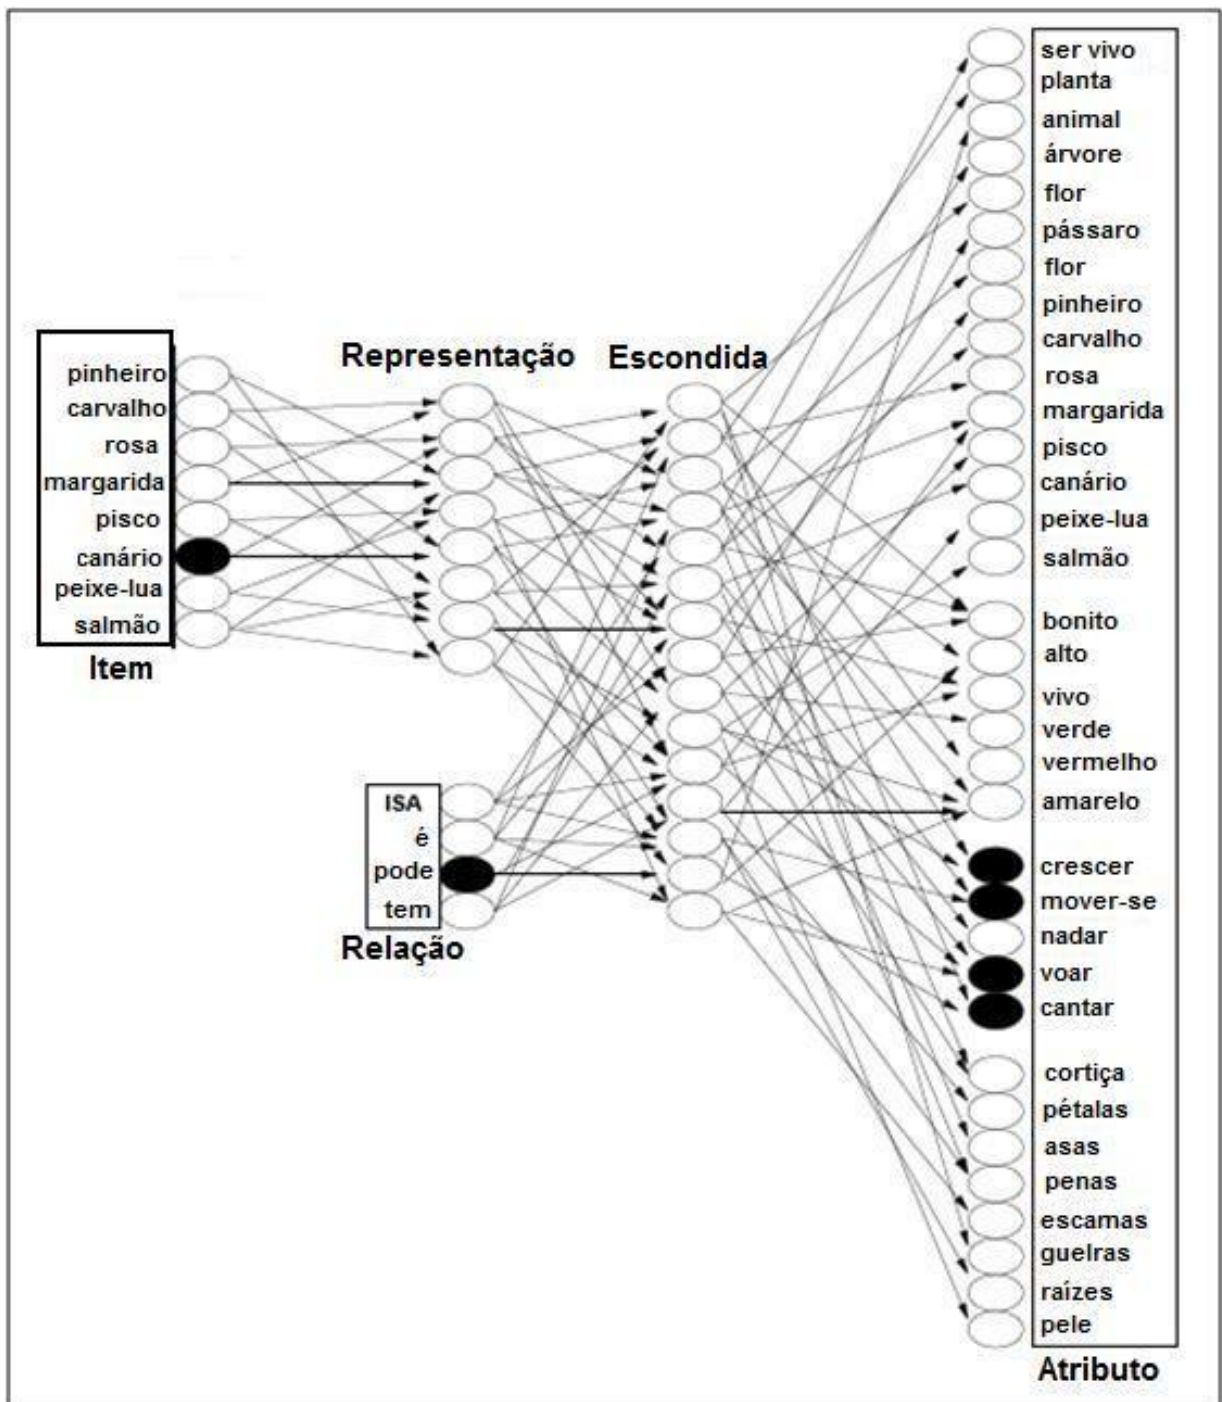


Figura 7: Modelo de Rumelhart (adaptado de Rumelhart, 1990; Rumelhart & Todd, 1993)

Rogers e McClelland acreditavam que o modelo criado por Rumelhart conseguia dar respostas às questões e limitações levantadas acerca da modelização da memória semântica já apresentadas anteriormente. Com o objectivo de explorar melhor as capacidades do modelo, Rogers e McClelland treinaram uma variante do modelo construído por Rumelhart e

investigaram o seu comportamento em vários aspectos durante o processo de aprendizagem (Rogers & McClelland, 2004; Rogers, 2008).

Foram considerados vários conceitos de diferentes domínios (animais e plantas) e ainda que inicialmente os seus padrões de activação fossem bastante semelhantes devido à inicialização aleatória dos pesos, a diferenciação entre os dois principais domínios verificou-se bastante cedo no processo de aprendizagem, enquanto que elementos da mesma classe (ex: rosa e margarida) foram os últimos a ser diferenciados pelo modelo, o que demonstra uma vantagem das classes mais gerais face às mais específicas. Este agrupamento (ou diferenciação) de itens acontece devido às semelhanças das suas características. Foram tidos em conta os seguintes itens: dois peixes, dois pássaros, duas flores e duas árvores. Logo numa fase inicial, depois de algumas iterações, começou a haver uma diferença entre os padrões produzidos pelos animais e plantas, só depois é que começou a haver uma distinção ao nível intermédio diferenciando os peixes dos pássaros e só mais tarde é que se verificou uma diferenciação ao nível subordinado diferenciando as plantas. A evolução dos padrões de activação para os diversos conceitos está esquematizada na Figura 8. Em cada iteração do modelo, vão sendo avaliadas as características de cada item e agrupados os itens mais semelhantes consoante os pesos que lhes são atribuídos. Para itens com representações semelhantes, a coerência das suas propriedades tende a mover as conexões na mesma direcção, enquanto que variações de características tendem a mover os pesos em direcções opostas que se anulam o que faz com que as propriedades partilhadas por itens com representações semelhantes sejam aprendidas mais rapidamente que as propriedades que os diferenciam (Rogers & McClelland, 2004; Rogers, 2008).

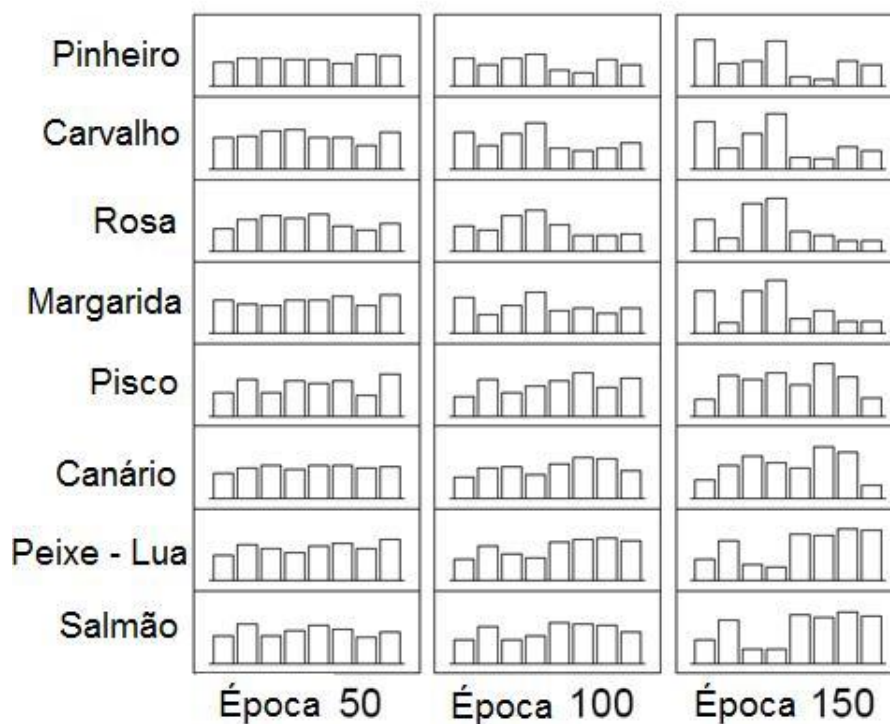


Figura 8: Padrões de activação ao longo do processo de aprendizagem de conceitos de diferentes categorias. (adaptado de Rogers & McClelland, 2004)

A partir da sua análise, Rogers e McClelland (Rogers & McClelland, 2004; Rogers, 2008) defendem que o modelo de Rumelhart consegue oferecer uma resposta a algumas das questões apresentadas.

Relativamente à questão 1 (Coerência das categorias), explicam que “boas” categorias consistem em itens que partilham conjuntos de propriedades que normalmente se encontram “juntos” em várias situações e contextos. Estes conjuntos de propriedades têm uma grande influência no processo de aprendizagem, fazendo com que as representações dos conceitos se aproximem ou afastem umas das outras contribuindo para a generalização da informação a novos itens. Quanto à segunda questão (Seleção das propriedades de um item), a teoria conexionista sugere que uma propriedade torna-se importante para a representação de uma categoria quando varia coerentemente com outras propriedades. Através das camadas Relação e Item que recebem inputs do exterior e através dos padrões de actividade criados através das camadas de representação e camada escondida, o modelo consegue ser sensível ao contexto e se adaptar a diferentes situações, dando assim resposta à terceira questão (Representação do contexto).

Contudo o modelo criado por Rumelhart não consegue representar a abstracção de conceitos, eventos e múltiplos objectos e relacionamentos. A resposta a estes problemas surgiu com a implementação de modelos linguísticos de interpretação semântica de frases. Estes modelos precisam além de ser sensíveis ao contexto, de estabelecer relações entre os elementos da frase de forma a conseguir lhe extrair o sentido correcto conseguindo desta forma combinar as três últimas questões: contexto, propriedades abstractas e combinação de múltiplos elementos (Rogers, 2008).

1.4.2.3. Modelo de Rogers e colegas (2004)

Com o objectivo de criar um modelo computacional da teoria conexionista da memória semântica, Rogers e colegas criaram um modelo (Rogers, et al., 2004) onde representações verbais e descrições visuais de objectos interagem através de um sistema semântico intermediário. Tal como dita a teoria conexionista e em seguimento dos modelos já apresentados, as representações do conhecimento semântico não são directamente introduzidas no modelo, mas emergem em resultado dos padrões de activação formados à medida que a rede vai sendo treinada e aprendendo.

A rede é organizada numa arquitectura com um módulo recursivo onde existem três camadas principais. As camadas *Verbal* e *Visual* (camadas visíveis) recebem informação do exterior e comunicam bidireccionalmente com a camada *Semântica* (camada escondida) que processa a informação recebida criando os padrões de activação que vão dar origem às representações semânticas do conhecimento. Cada camada representa uma região distinta do córtex, especializada no tipo de função associada ao tipo de informação que apresenta. A sua arquitectura está esquematizada na Figura 9. Unidades da camada *Verbal* recebem informação linguística acerca dos itens que se divide em várias áreas: informação perceptual, funcional,

enciclopédica e nominal. Por sua vez a camada *Visual* recebe descrições do aspecto visual de cada objecto (Rogers, et al., 2004).




Figura 9: Arquitectura do modelo computacional da memória semântica de Rogers e colegas (adaptado de Rogers et al., 2004).

O funcionamento do modelo de Rogers e colegas segue a mesma abordagem que os modelos conexionistas apresentados anteriormente, ou seja, a informação é processada através dos pesos das conexões entre as unidades semânticas, que vão sendo ajustados de forma iterativa até se alcançar uma estabilidade. Atingindo este ponto considera-se que a rede já aprendeu e podem ser feitas inferências acerca do conhecimento e das representações semânticas dos itens, que são conseguidas a partir de padrões de activação gerados pela rede. Estes padrões são conseguidos segundo as semelhanças entre as propriedades dos itens considerados.

Depois da aprendizagem da rede, os autores fizeram alterações na camada semântica do modelo de modo a lesionar a rede simulando uma situação de demência semântica. Foram executadas uma série de tarefas semânticas cujos resultados obtidos pelo modelo foram comparados com resultados reais (tarefas executadas por pacientes com demência semântica) com o objectivo de investigar e perceber a estrutura da memória semântica e os mecanismos relacionados com a perda de conhecimento semântico. Os resultados obtidos confirmam o que dita a teoria, sendo que à medida que a severidade da demência aumenta, o sistema começa a não conseguir recuperar as características idiossincráticas e informação distintiva dos itens. Deste modo o sistema não consegue fazer distinções, nem identificar itens atípicos, caindo nos protótipos dos seus vizinhos mais típicos.

1.5.Paradoxo vantagem Nível Básico vs Nível Sobreordenado

Tal como já foi dito, Warrigton (1975) foi pioneira no estudo da organização hierárquica da memória em pacientes com demência semântica, demonstrando que estes apresentam uma vantagem de acesso ao nível sobreordenado contrariamente ao observado para sujeitos saudáveis. Foram executadas várias tarefas de categorização com sujeitos com demência semântica, onde se verificou que os sujeitos descreviam com facilidade e diferenciavam conceitos do nível sobreordenado, mas mostravam muito mais dificuldade e maior número de erros a diferenciar e fornecer informação mais precisa e detalhada, relacionada com os níveis de maior especificidade. O que leva à conclusão que existe uma maior preservação da informação mais geral e uma vulnerabilidade para o conhecimento mais específico, que faz com que o conhecimento do nível sobreordenado esteja ainda acessível quando o conhecimento dos níveis básico e subordenado já não está. Nos sujeitos saudáveis, a vantagem de acesso verifica-se ao nível básico, sendo este o nível preferencial para identificação de um conceito e o nível hierárquico que é acedido mais rapidamente (Jolicoeur, Gluck, & Kosslyn, 1984; Murphy & Brownell, 1985; Tanaka & Taylor, 1991; Johnson & Mervis, 1997).

Esta diferença na vantagem de acesso ao nível básico ou sobreordenado do conhecimento semântico, constitui um fenómeno paradoxal da Psicologia cognitiva, no que diz respeito à estrutura e organização da memória semântica. Rogers e Patterson (2007) replicaram este fenómeno utilizando os mesmos dados em tarefas de categorização com sujeitos saudáveis e sujeitos com demência semântica. Observaram que os sujeitos saudáveis cometiam menos erros ao nível básico que ao nível sobreordenado ou subordenado e que sujeitos numa fase inicial da demência ainda mostravam uma ligeira vantagem do nível básico face ao nível sobreordenado, mas sujeitos numa fase mais avançada da doença cometiam mais erros ao nível básico que ao nível sobreordenado.

Vários estudos tentam explicar este fenómeno, visando compreender a estrutura e organização da memória semântica. Na teoria de Collins e Quillian (1969), uma vez que o conhecimento semântico está organizado numa hierarquia vertical de nós juntamente com as suas características, será sempre necessário percorrer a hierarquia para aceder aos vários níveis de conhecimento. É defendido que a hierarquia do conhecimento semântico pode ser percorrida de cima para baixo (do mais geral para o mais específico) ou de baixo para cima (do mais específico para o mais geral), mas os autores acreditam que faz mais sentido percorrer a hierarquia de conceitos de baixo para cima porque se acede mais rapidamente às propriedades de um conceito sem necessidade de percorrer toda a hierarquia. O que faria com que o conhecimento subordenado fosse mais robusto porque implicava menos processamento. Reformulando esta teoria, Warrigton a partir dos resultados do seu estudo (1975) defendeu que a hierarquia do conhecimento semântico era sempre percorrida numa perspectiva top-down, acedendo primeiro ao conhecimento mais geral e só depois de percorrer os nós superiores é que era acedido ao conhecimento mais específico. Numa fase avançada da demência semântica, quando as estruturas cerebrais se encontravam mais danificadas, já não era possível aceder ao conhecimento da base da árvore, perdendo-se assim o conhecimento mais específico. Esta teoria explica a vantagem do nível sobreordenado numa

situação de demência semântica, mas não oferece nenhuma explicação para a vantagem do conhecimento básico em sujeitos saudáveis. Já Jolicoeur e colegas (Jolicoeur, Gluck, & Kosslyn, 1984) afirmam que o ponto de entrada do conhecimento semântico está no nível básico, explicando assim a sua vantagem de acesso. Esta teoria oferece uma explicação para a vantagem do nível básico mas não explica a vantagem do nível sobreordenado, tendo sido já desconfirmada em estudos posteriores (Murphy & Brownell, 1985; Tanaka & Taylor, 1991). Analisando todas estas teorias e as suas contradições, chegamos a um paradoxo. Como é estruturada a informação semântica e o que diferencia o conhecimento de cada nível hierárquico para que o seu acesso não seja sempre feito da mesma forma?

Os modelos conexionistas explicam a vantagem do nível básico de acordo com a generalização de padrões. Conceitos de nível básico da mesma categoria activam as mesmas unidades semânticas criando padrões e conexões mais fortes para os conceitos de nível básico. Mas numa situação de demência semântica começa a haver uma distorção de padrões, que leva a que sejam dadas respostas erradas em que apenas algumas das unidades semânticas que representam o estímulo se mantêm. As unidades semânticas mais robustas são aquelas que são mais activadas porque são partilhadas por um maior número de conceitos, logo mais gerais e pertencentes ao nível sobreordenado. Tal encontra-se explicado mais detalhadamente na secção '1.3 Modelos Conexionistas'.

Num estudo de Marques (2007), com vista a uma avaliação da natureza do conhecimento sobreordenado, foram pedidas descrições de conceitos através da construção de listas de atributos que os definissem. A criação de listas de atributos para a construção de uma base de dados de conceitos semânticos tem sido um método largamente utilizado para o estudo de conhecimento conceptual. Este método de extracção de conhecimento tem sido considerado válido devido à consistência dos seus dados. Em várias listas diferentes, tem sido observado que diferentes pessoas listam informação semelhante para os mesmos conceitos, evidenciando uma abstracção de conhecimento semelhante que se mantêm estável ao longo do tempo (Barsalou, 1993). No estudo de Marques foram criadas listas de atributos para conceitos básicos familiares, conceitos básicos não familiares e conceitos sobreordenados. Numa segunda fase foi analisada a natureza do conhecimento com base nos atributos dos conceitos considerando a sua classificação quanto ao tipo de conhecimento, frequência de produção, distinção e partilha de atributos. A distinção de atributos compara diferentes conceitos e avalia a exclusividade do atributo em relação ao conceito em questão (exemplo: focinho é um atributo exclusivo do conceito cão?) e a partilha de atributos faz uma comparação entre instâncias de um conceito avaliando em que medida o atributo é partilhado pelos vários membros do conceito (exemplo: focinho é um atributo comum a todos os cães?). Contrariamente ao que se tem observado em estudos anteriores, o conhecimento relativo ao nível sobreordenado não se verificou menos informativo que o conhecimento do nível básico, tendo valores equiparados no parâmetro de distinção de atributos. A diferença entre os diferentes níveis hierárquicos (nível básico vs nível sobreordenado) apenas se verificou na partilha de atributos, isto é, atributos dos conceitos do nível sobreordenado não são tão partilhados pelos seus membros como os atributos dos conceitos do nível básico.

2. Apresentação da proposta

De forma a estudar a identificação de conceitos por níveis hierárquicos e a perceber a sua diferenciação, é proposta a construção de um modelo que a partir das características de uma lista de atributos que definem um conceito, identifique se o conceito pertence ao nível básico ou sobreordenado. Para fazer esta diferenciação o modelo terá em conta não só a combinação de atributos que compõem um conceito mas principalmente o seu valor de partilha. Serão utilizados os dados do estudo de Marques (2007), onde foi constatado que atributos de conceitos do nível básico apresentavam valores de partilha mais altos comparativamente a atributos de conceitos de nível sobreordenado, revelando-se esta característica como factor distintivo do nível hierárquico.

Os modelos conexionistas e em particular as redes neuronais, são o tipo de modelos que melhor abstrai as teorias conexionistas da memória semântica, porque oferecem explicações mais robustas para o funcionamento da memória humana. Por esta razão e para tentar ter um modelo mais próximo da arquitectura humana, o modelo será desenvolvido com redes neuronais.

O modelo será alimentado com uma lista de atributos que formam conceitos e dará como resposta qual o nível hierárquico do conceito representado. Tomamos como primeira e principal hipótese que conceitos representados com atributos com maiores valores de partilha serão identificados como conceitos do nível básico e conceitos com menores valores de partilha identificados como conceitos do nível sobreordenado.

De acordo com as teorias conexionistas, os conceitos são formados por conjuntos de características e podem ser agrupados segundo a criação de padrões de activação que serão semelhantes para conceitos com as mesmas características (McClelland & Rogers, 2003; 2004; Rogers, et al., 2004). Esta organização de conceitos por categorias forma padrões distintos para diferentes domínios fazendo uma distinção entre conceitos vivos e não-vivos ou entre animais e plantas por exemplo. Partindo deste pressuposto, formulo uma segunda hipótese onde conceitos de diferentes domínios (animais, plantas e objectos) formam padrões de activação semelhantes para conceitos do mesmo domínio e distintos para conceitos de domínios diferentes.

Pretendo avaliar o impacto da partilha de atributos na generalização de conceitos observada nos modelos conexionistas. Criando um modelo computacional onde este parâmetro é introduzido e associado aos atributos dos conceitos do nível básico e nível sobreordenado. Pretendo avaliar se o modelo consegue fazer uma diferenciação do nível do conceito, tendo como base de distinção o valor de partilha. Espera-se que conceitos formados por um conjunto de atributos com valores de partilha mais baixos, sejam avaliados como conceitos do nível sobreordenado e conceitos formados por um conjunto de atributos com valores de partilha mais elevados sejam avaliados como conceitos do nível básico. Numa segunda análise espero que se formem padrões de activação semelhantes entre conceitos da mesma categoria e padrões de activação distintos para categorias diferentes.

2.1. Modelo

2.1.1. Seleção dos dados

Do conjunto total dos dados do estudo de Marques (2007) foi seleccionado um subconjunto de conceitos e respectivos atributos de modo a possibilitar a construção dos padrões de aprendizagem e teste que serão introduzidos no modelo. Optou-se por agrupar os conceitos em três categorias distintas: Animais, Plantas e Objectos. Em cada categoria foram incluídos conceitos do nível básico e o seu conceito relativo ao nível sobreordenado correspondente. Dos 43 conceitos foram seleccionados 27 (9 de cada categoria) como apresentado na Tabela 2.

Tabela 2: *Seleção dos conceitos utilizados para a construção do modelo computacional. Conceitos distribuídos por 3 categorias, cada uma com conceitos do nível básico e correspondente nível sobreordenado.*

Categoria	Conceito	Nível
<i>Animais</i>	Cão	Básico
	Toupeira	Básico
	Mamífero	Sobreordenado
	Tritão	Básico
	Cobra	Básico
	Réptil	Sobreordenado
	Mosca	Básico
	Insecto	Sobreordenado
	Animal	Sobreordenado
<i>Plantas</i>	Alface	Básico
	Legume	Sobreordenado
	Alfarroba	Básico
	Ginja	Básico
	Maça	Básico
	Fruto	Sobreordenado
	Rosa	Básico
	Rosmaninho	Básico
	Planta	Sobreordenado
<i>Objectos</i>	Computador	Básico
	Frigorífico	Básico
	Misturadora	Básico
	Electrodoméstico	Sobreordenado
	Maquina	Sobreordenado
	Escopro	Básico
	Martelo	Básico
	Rebarbadora	Básico
	Ferramenta	Sobreordenado

A listagem dos atributos foi normalizada criando um nome reduzido dos atributos, eliminando repetições e reduzindo ao mesmo atributo todas as descrições que se pudessem considerar sinónimos. Por exemplo as descrições: “É de cor castanha”; “É castanho”; “São castanhos”;

“Pode ser castanho”, podem ser todas reduzidas ao atributo *CASTANHO*. Tal como os sinónimos “Nojento” e “Repugnante” podem ser reduzidos ao atributo *NOJENTO*. De modo a que nenhum conceito fosse identificado univocamente devido à existência de um atributo único que o definisse, foram eliminados todos os atributos únicos (atributos listados apenas 1 vez, identificando univocamente um conceito). Foram então seleccionados segundos os critérios descritos, 92 atributos.

2.1.2. Análise dos dados

As hipóteses do modelo foram construídas com base no estudo de Marques (2007) que concluiu que a principal característica que diferenciava o nível básico do nível sobreordenado, era o valor de partilha dos atributos de um conceito. Atributos de conceitos do nível básico, apresentavam valores de partilha maiores que atributos de conceitos de nível sobreordenado. Para a construção do corrente modelo foi apenas usado um fragmento dos dados segundo a selecção anteriormente descrita. Para poder ter como hipóteses as conclusões do estudo teria de ser garantido que o fragmento dos dados manteria a mesma relação nível-partilha e a mesma coerência que a totalidade dos dados. Foi então calculada a média dos valores de partilha dos atributos dos conceitos do nível básico e sobreordenado e observado na Figura 10 que a selecção dos dados mantém a mesma relação apresentando um valor de partilha médio de 5,75 para atributos de conceitos básicos e 5,06 para atributos de conceitos sobreordenados, $t(25) = 4.85$, $p < .001$, pelo que as amostras são estatisticamente diferentes.




Figura 10: Relação Nível-Partilha por Nível Hierárquico para a média de valores de partilha dos dados seleccionados.

Mais especificamente ao nível do conceito, pode-se observar na Figura 11. que os conceitos pertencentes ao nível sobreordenado apresentam valores de partilha mais baixos que os conceitos do nível básico.




Figura 11: Relação Nível-Partilha por conceito para a média de valores de partilha dos dados seleccionados. Conceitos pertencentes ao nível sobreordenado estão representados pelas barras cor de laranja à direita e apresentam valores de partilha mais baixos que os conceitos do nível básico representados pelas barras azuis à esquerda.

A selecção dos dados verificou-se coerente com os dados originais, podendo assim servir para a construção do modelo e tentar verificar as hipóteses formuladas com base nas conclusões e dados originais do estudo de Marques (2007).

2.1.3. Arquitectura

Foi construído um modelo de redes neuronais em três camadas com progressão adiante (“feedforward”), o que significa que os neurónios da camada de entrada activam os neurónios da camada escondida que por sua vez são responsáveis pela activação dos neurónios da camada de saída. Um esquema da arquitectura do modelo está apresentado na Figura 12.

- Camada de entrada: Camada de alimentação do modelo onde cada neurónio corresponde a 1 atributo. A combinação de vários atributos representa 1 conceito. Todos os atributos são partilhados pelo menos por dois conceitos, de modo a que nenhum conceito seja identificado por atributos únicos. A listagem dos atributos da rede pode ser consultada na secção Anexos ‘I Rede Neuronal’. O nome de cada atributo é apresentado na coluna ‘unitName’ sendo as unidades identificadas por um ‘i’(input) na coluna ‘st’.
- Camada escondida: Camada intermédia apenas para processamento. Cada neurónio é alimentado pelos neurónios da camada de entrada e servirá de alimentação à camada de saída onde será produzida a resposta do modelo.
- Camada de saída: Camada de resposta do modelo. Camada constituída por 2 neurónios, um representará o nível básico e o outro o nível sobreordenado. A activação das camadas de entrada e escondida produzirá a activação dos neurónios de saída. O neurónio mais activado representa a resposta do modelo que irá identificar um conceito (através dos seus atributos) como um conceito do nível básico ou sobreordenado.

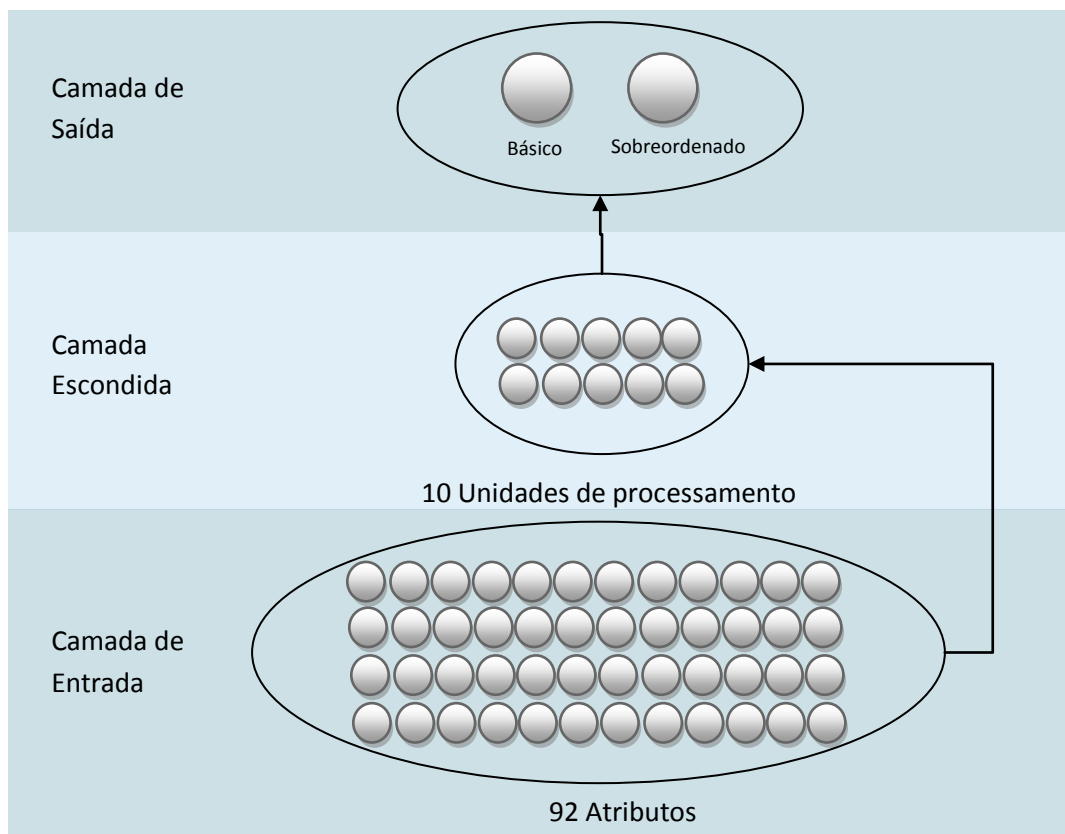


Figura 12: Arquitectura do modelo

A activação das unidades e o peso das suas conexões é feita segundo a função logística com valores que variam entre 1 e -1. Inicialmente os pesos das conexões são gerados aleatoriamente e vão sendo ajustados ao longo da aprendizagem da rede neuronal.

Para determinar o melhor número de neurónios da camada escondida foram feitas várias experiências onde fui variando o número de unidades da camada escondida, treinando a rede e comparando os seus resultados. O número inicial de neurónios da camada escondida foi 15 que foi sendo diminuído até chegar a 6 neurónios. Não foram registadas os valores de erros de todas as simulações feitas nestas experiências, mas apenas uma amostra das experiências feitas e dos resultados obtidos.

Os resultados estão representados na Figura 13. Para cada rede, foram registados os valores dos erros de validação de 10 simulações. A rede com 10 neurónios na camada escondida (N10) foi a que registou um erro mais baixo. Contudo os resultados obtidos nas experiências registadas para a N10 demonstraram alguma variância que pode ser vista em mais detalhe na Figura 15 da secção 'Aprendizagem da Rede Neuronal'.

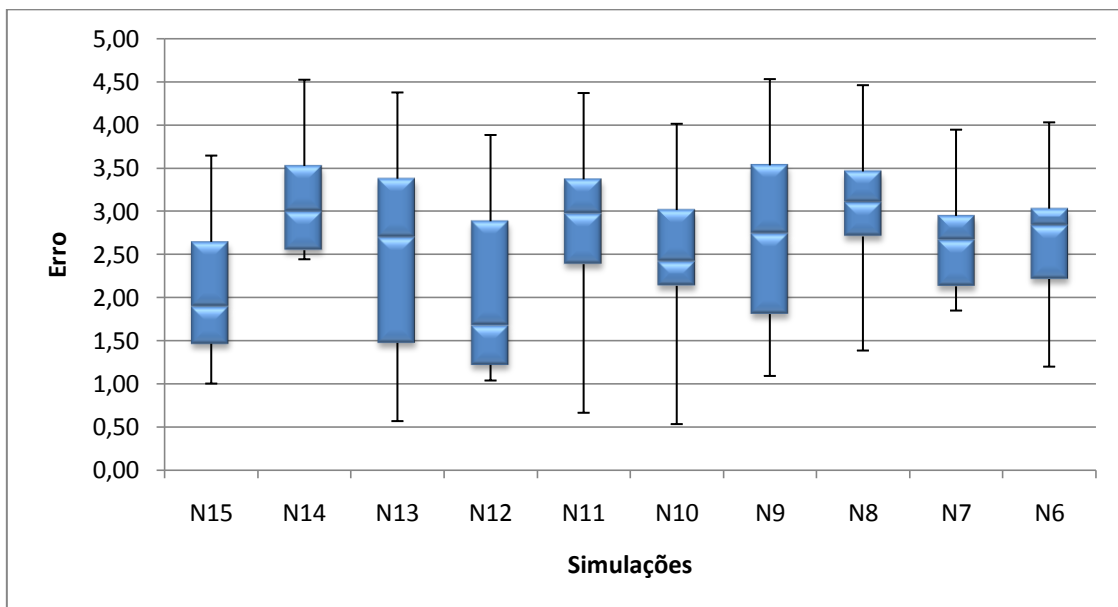


Figura 13: Simulações da rede neuronal com uma camada escondida de 6 a 15 neurónios. Para cada simulação é apresentado o erro mínimo obtido pelo extremo do traço vertical inferior, erro máximo representado pelo extremo do traço vertical superior, o 1º e 4º quartis pelos contornos inferior e superior da caixa azul e a mediana representada pelo traço horizontal existente na caixa azul.

2.1.4. Aprendizagem da Rede Neuronal

A aprendizagem da rede neuronal é feita através de padrões de treino e padrões de teste. O padrão de treino tem como objectivo treinar a rede até esta estabilizar dentro de uns limites de erro aceitáveis e o padrão de teste é utilizado para testar e validar a eficácia da rede depois de treinada. Ambos os padrões têm uma estrutura semelhante onde é apresentado um padrão de entrada e respectiva activação esperada da camada de saída (resposta da rede). Em cada ficheiro (teste ou treino) poderão ser definidos quantos padrões quanto desejável, mas de uma forma geral e para se conseguir uma aprendizagem satisfatória, o ficheiro de treino será sempre consideravelmente maior, deixando apenas uma pequena percentagem dos dados para teste da rede.

Para o modelo implementado foram criados os respectivos ficheiros de padrões de treino e teste. Dos 27 conceitos introduzidos no modelo, 21 foram incluídos no ficheiro de treino e os restantes 6 no ficheiro de teste organizados como descrito na Tabela 3.

Tabela 3: *Padrões de Teste e Treino da Rede Neuronal.*

<i>Treino</i>			<i>Teste</i>		
No	Padrão	Output	No	Padrão	Output
1	Alface	Básico	1	Maçã	Básico
2	Cão	Básico	2	Legume	Sobreordenado
3	Cobra	Básico	3	Martelo	Básico
4	Computador	Básico	4	Electrodoméstico	Sobreordenado
5	Rosmaninho	Básico	5	Toupeira	Básico
6	Tritão	Básico	6	Mamífero	Sobreordenado
7	Animal	Sobreordenado			
8	Fruto	Sobreordenado			
9	Planta	Sobreordenado			
10	Alfarroba	Básico			
11	Escopro	Básico			
12	Frigorífico	Básico			
13	Ginja	Básico			
14	Misturadora	Básico			
15	Mosca	Básico			
16	Rebarbadora	Básico			
17	Rosa	Básico			
18	Ferramenta	Sobreordenado			
19	Insecto	Sobreordenado			
20	Maquina	Sobreordenado			
21	Réptil	Sobreordenado			

Em ambos os ficheiros foram incluídos conceitos das 3 categorias (animais, plantas e objectos) e conceitos do nível básico e sobreordenado de modo a que se tentasse ter em ambos os ficheiros uma amostra representativa dos dados. Ambos os ficheiros têm a mesma estrutura,

onde constam os neurónios de entrada, ou seja, os atributos de um conceito e os neurónios de saída que correspondem ao nível hierárquico activado. O conceito é representado através da combinação de atributos activos, onde cada neurónio de entrada é activado com valor de partilha do atributo se aplicável ao conceito e mantém-se inactivo com valor 0 se não aplicável. Como resposta é activado com o valor 1 o neurónio representativo do nível hierárquico do conceito, sendo o primeiro neurónio representativo do nível básico e o segundo representa o nível sobreordenado. Um exemplo do padrão representativo de alface pode ser visto nos 'Anexos II Padrão Treino'.

A aprendizagem da rede é feita em vários ciclos de treino que constituem épocas, onde em cada época a rede é treinada com os padrões do ficheiro de treino e validada com os padrões do ficheiro de teste. Para a aprendizagem da rede foi utilizado o algoritmo de retro-propagação do erro ("backpropagation"). No ramo da neurociência o algoritmo backpropagation tem-se mostrado bastante eficiente para problemas representados por rede neuronais, mostrando-se uma ferramenta útil para a explicação das funções de alguns neurónios no córtex cerebral. Contudo apesar de este algoritmo ter feito valiosas contribuições de um nível abstracto do funcionamento dos neurónios reais e de ter ganho a confiança dos investigadores quanto aos processos de aprendizagem, o seu funcionamento parece ser biologicamente implausível. O movimento retrógrado da informação não acontece desta forma em neurónios reais, mas é verdade que o cérebro tem vários caminhos de propagação de informação e realmente pode transferir a informação por várias camadas posteriores e anteriores no processo de aprendizagem. Mas a objecção mais grave é que o algoritmo de retro-propagação do erro precisa de uma rede supervisionada onde existe uma resposta alvo que funciona como um professor. Na vida real muitas vezes não existe essa resposta alvo e aprendemos muitas coisas sem ter a ajuda de um professor (Hinton, 2002).

A aprendizagem da rede com o algoritmo de retro-propagação do erro funciona ajustando em cada época os pesos das conexões de acordo com o erro calculado. O erro é calculado pela diferença entre a resposta actual da rede e a resposta esperada. Em cada época os pesos da rede são ajustados de forma a diminuir esta diferença. Quando o erro calculado atinge um valor aceitável, considera-se que a rede já aprendeu e deve ser terminado o processo de aprendizagem constituindo numa boa generalização do conhecimento, ou seja, quando a relação input-output da rede produz um resultado correcto (ou quase correcto) para os exemplos do padrão de teste que nunca foram apresentados à rede (Haykin, 1994).

O momento óptimo de paragem de modo a evitar o sobre-ajuste da rede, é quando se atinge o valor de erro mínimo da amostra de validação (cálculo do erro para o conjunto de teste da rede). Mesmo que o erro do conjunto de treino ainda não tenha atingido o valor 0, a partir do ponto que é atingido o erro mínimo para o conjunto de validação a rede começa a estar sobre-ensinada resultando numa posterior má generalização. Uma má generalização ocorre quando uma rede é sobre-treinada aprendendo relações demasiado específicas de input-output, acabando por memorizar estes padrões e conseqüentemente perde a capacidade de fazer uma correcta generalização do conhecimento a novos padrões (Haykin, 1994).

A rede neuronal do presente projecto foi treinada com cerca de 290 ciclos de treino, com 10 ciclos por época, com um rácio de aprendizagem " $\eta=0.2$ " sendo os padrões apresentados de forma aleatória. Terminou-se o processo de aprendizagem quando se atingiu um erro de validação de 0,10 e erro de treino de 0.0 como apresentado na Figura 14.

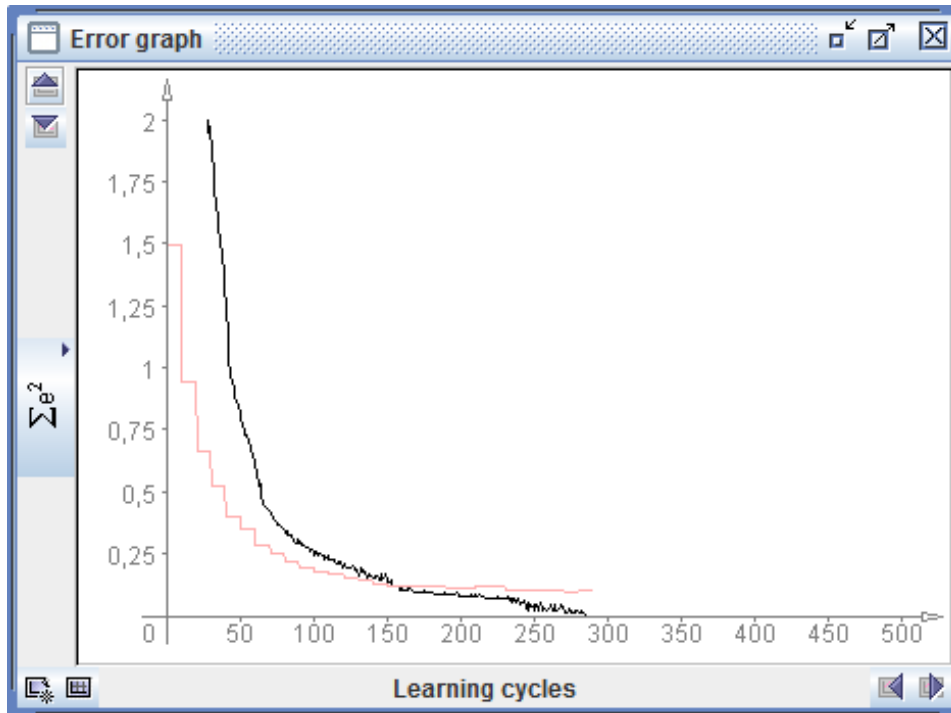


Figura 14: Aprendizagem da rede. A linha vermelha representa o erro do conjunto de validação e a linha preta o erro do conjunto de treino.

Tal como já referido, a rede N10 (rede com 10 neurónios na camada de escondida) foi a que produziu melhores resultados. Como apenas foram registados e apresentados na Figura 13 uma amostra das experiências feitas, não foram registadas todas as aprendizagens feitas para a rede N10 depois de escolhida esta arquitectura. Contudo, a partir da amostra registada é possível verificar que apesar desta rede registar os melhores resultados, também se verifica alguma dispersão de valores não se mostrando uma rede sempre coerente. De entre todos os registos de simulações para todas as redes, a rede 10 foi a que obteve um erro mínimo, mas mostra alguma disparidade de valores variando desde os 0,53 como erro mínimo e um erro máximo de 3,38 como se pode observar na Figura 15. Foi registada uma média de erros no valor de 2,43 com um desvio padrão de 0,83.

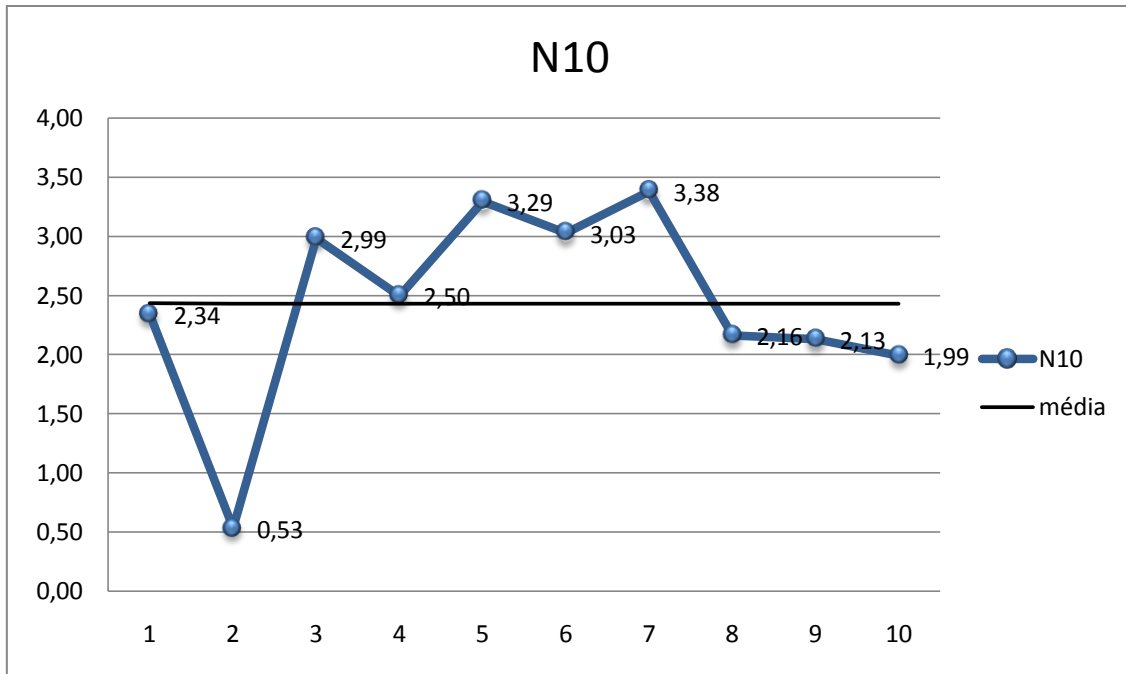


Figura 15: Resultados do registo de experiências da rede N10. A linha azul representa os erros obtidos em cada simulação e a linha preta a média dos erros de validação.

Numa fase inicial da aprendizagem, os pesos das conexões ainda não estão ajustados resultando numa má generalização e resultados imperfeitos. A rede ainda não será capaz de diferenciar conceitos do nível básico ou nível sobreordenado através da análise dos valores de partilha dos seus atributos. Depois de treinada é esperado que a rede consiga fazer essa diferenciação corretamente, activando mais na camada de output o neurónio que representa o nível hierárquico correcto do conceito.

Além da identificação do nível hierárquico do conceito, também esperaria à semelhança dos resultados das simulações de Rogers e McClelland (Rogers & McClelland, 2004) que se formassem padrões de activação da camada escondida para cada categoria. Padrões de activação das categorias Animais, Plantas e Objectos seriam semelhantes para os conceitos da mesma categoria e diferentes entre si. A activação dos neurónios da camada escondida é feita pelos neurónios da camada de entrada, ou seja, os atributos dos conceitos. Portanto os padrões de activação seriam determinados pelos atributos activados em cada conceito. Uma vez que Animais e Plantas são categorias de seres vivos, seria normal encontrar um padrão mais semelhante entre estas duas categorias por partilharem mais atributos, do que cada uma delas com a categoria Objectos, visto esta fazer parte do conjunto dos seres não vivos e assim haver menos atributos em comum.

2.1.5. Lesionar a rede

Um dos desafios da modelação cognitiva é também conseguir construir modelos que simulem situações em que existe lesão cerebral. Estas lesões podem ser causadas por doenças ou traumatismos cranianos. No caso específico de deficiências da memória semântica, estas podem ser provocadas por uma variedade de causas que tipicamente envolvem lesões em um ou ambos lobos temporais. Este tipo de lesões podem ser provocadas pela doença de Alzheimer, AVC, traumatismos cranianos, encefalite herpética e demência semântica (Lambon Ralph, McClelland, Patterson, Galton, & Hodges, 2001).

Vários estudos têm sido feitos com modelos que visam modelar lesões cognitivas, mas estes modelos têm como principal objectivo tentar compreender o funcionamento de um cérebro lesionado, mas não assumem o compromisso de reproduzir a lesão cerebral “real” numa rede neuronal artificial (Hinton & Shallice, 1991; Hinton, Plaut, & Shallice, 1993; Lambon Ralph, McClelland, Patterson, Galton, & Hodges, 2001; Farah & McClelland, 1991). Apesar dos modelos conexionistas e em particular as redes neuronais serem o tipo de modelo que mais se assemelha ao cérebro humano, essa semelhança é em termos funcionais e não propriamente “físicos” até porque o cérebro humano tem uma estrutura muito complexa e em cada modelo apenas se tenta modelar uma pequena parte. Ao lesionar um modelo que simula dado fenómeno, não se está a ter em conta todo o resto envolvente que compensa ou também sofre impactos sobre a zona e estrutura lesionada.

Hinton e colegas em estudos sobre a dislexia profunda (Hinton & Shallice, 1991; Hinton, Plaut, & Shallice, 1993), criaram um modelo computacional capaz de produzir os erros habituais deste tipo de pacientes que sugeriam que na leitura de uma palavra, os pacientes acediam a outra palavra semanticamente relacionada. Entre os erros produzidos, eram relatados erros puramente semânticos (em vez de ler a palavra pêssego um paciente lia a palavra alperce - palavras com grafias e sons diferentes, mas com significados semelhantes) e erros semântico-visuais (em vez de ler a palavra gato um paciente lia a palavra rato – palavras com grafias, sons e significados semelhantes).

O modelo de Hinton e Shallice(1991) foi baseado num dos primeiros modelos de lesões em redes neuronais (Hinton & Sejnowski, 1986) em que numa arquitectura em 3 camadas (camada de entrada, camada escondida e camada de saída) a lesão foi simulada introduzindo ruído em todos os pesos da camada intermédia (camada escondida), alterando os pesos das suas conexões para zero (eliminação de conexões) ou removendo as suas unidades. O modelo de Hinton e Shallice (1991) tinha mais que uma camada intermédia numa arquitectura recursiva, mas o método para lesionar a rede foi semelhante ao anteriormente executado. O desempenho da rede lesionada foi semelhante aos resultados dos pacientes reais, mas Hinton e colegas admitem que o seu modelo pode não ser muito realista quando comparado com o sistema cerebral humano, mas o seu objectivo era uma simulação do seu funcionamento e não uma representação das suas estruturas reais deixando margem para uma investigação neste sentido (Hinton, Plaut, & Shallice, 1993).

Farah e McClelland (1991) criaram um modelo de estudo da estrutura e organização da memória semântica onde visavam diferenciar a identificação de conceitos vivos e não-vivos através de descrições visuais ou funcionais criando simulações de sujeitos saudáveis e sujeitos com lesões que afectavam o sistema semântico. Num modelo com arquitectura em 2 camadas bidireccionais onde a camada de entrada funcionava também como camada de saída e comunicava bidireccionalmente com uma camada intermédia à qual chamaram de “camada semântica”. As lesões foram infligidas na camada intermédia removendo de forma aleatória algumas das suas conexões para a camada de input/output ou através da remoção de unidades da camada semântica. Em ambos os tipos de lesões criaram-se várias simulações aumentando a sua gravidade e percentagem de rede lesionada. Tal como esperado, o desempenho do modelo deteriorava-se cada vez mais à medida que a percentagem de rede lesionada aumentava. Não foi encontrada uma relação entre as lesões ao nível das unidades da rede e as lesões ao nível das conexões, contudo as lesões das conexões levaram a uma maior consistência de itens falhados. Isto porque algumas conexões são mais importantes que outras para a activação de certas representações, logo, quando uma parte destas conexões é destruída, o subconjunto das representações que lhe está relacionada sofre mais impactos. Os autores não defendem que as lesões cerebrais possam ser simuladas através da destruição de neurónios como as unidades da rede neuronal, ou através da destruição de conexões entre os neurónios. Os efeitos de encefalite herpética, trauma craniano ou AVC que são as principais causas de demência semântica, são melhor representados por uma combinação de lesões ao nível das unidades da rede e das conexões, tal como noutras mudanças na rede, como a introdução de ruído nos pesos das conexões ou na activação das unidades ou alteração da variação com que a activação decai. Este tipo de alterações certamente teria um impacto diferente no desempenho da rede lesionada.

Em projectos posteriores, em estudos computacionais da estrutura da memória semântica com especial ênfase na demência semântica (Lambon Ralph, McClelland, Patterson, Galton, & Hodges, 2001; Rogers, et al., 2004) foram criados modelos computacionais de organização e estrutura da memória semântica, lesionados através de alteração dos pesos das conexões da camada intermédia para zero (eliminação computacional da conexão) e comparados os resultados da simulação com dados de pacientes reais. Os resultados da rede lesionada mostram um comportamento e desempenho análogos aos resultados dos pacientes reais em que são cometidos os mesmos tipos de erros demonstrando que este tipo de simulações constitui uma boa abstracção do comportamento de doentes semânticos.

Em suma, em todas as redes as lesões são simuladas através da remoção de unidades (neurónios artificiais) da camada intermédia ou das suas conexões para a camada de saída. Mas não se pode fazer uma comparação directa com o cérebro humano e as suas estruturas reais, devido à enorme complexidade do cérebro e as arquitecturas relativamente simples das redes e porque os modelos criados e as redes neuronais artificiais desenvolvidas apenas visam simular o funcionamento de uma pequena estrutura cerebral para compreender algum tipo de fenómeno, não tendo desta forma toda a envolvência e a cooperação das restantes estruturas existentes no cérebro humano.

Dados de pacientes afásicos vítimas de AVC com lesões no lobo pré-frontal, apresentam comprometimento do controlo semântico. Estes dados, convergem com o observado num estudo de Raposo e colegas (In press) que argumentam que devido ao menor grau de partilha de atributos, o processamento de conceitos sobreordenados exige mais processamento executivo para conseguir coordenar informação que é menos partilhada. Partindo deste pressuposto, serão feitas lesões no modelo implementado neste projecto de modo a analisar o impacto que uma lesão na rede terá no seu processamento e desempenho.

3. Resultados

3.1. Identificação do nível hierárquico dos conceitos

De uma forma geral, a generalização da rede foi boa. Depois do treino da rede, foram verificados os resultados da generalização para o conjunto de treino e de teste como representado na Tabela 4.

Tabela 4: *Output geral da rede neuronal.*

	Padrão	Esperado Básico	Activação Básico	Esperado Sobreordenado	Activação Sobreordenado
Conjunto de treino	Alface	1,00000	0,90043	0,00000	0,08493
	Cão	1,00000	0,90025	0,00000	0,0997
	Cobra	1,00000	0,96528	0,00000	0,05539
	Computador	1,00000	0,92842	0,00000	0,08442
	Rosmaninho	1,00000	0,95349	0,00000	0,04634
	Tritão	1,00000	0,97209	0,00000	0,02509
	Alfarroba	1,00000	0,96036	0,00000	0,03316
	Escopro	1,00000	0,96974	0,00000	0,02502
	Frigorifico	1,00000	0,9834	0,00000	0,01416
	Ginja	1,00000	0,98978	0,00000	0,01034
	Misturadora	1,00000	0,99599	0,00000	0,0031
	Mosca	1,00000	0,95983	0,00000	0,03184
	Rebarbadora	1,00000	0,91864	0,00000	0,05666
	Rosa	1,00000	0,9583	0,00000	0,03973
	Animal	0,00000	0,07637	1,00000	0,90405
	Fruto	0,00000	0,088	1,00000	0,91117
	Planta	0,00000	0,07376	1,00000	0,93341
	Ferramenta	0,00000	0,01147	1,00000	0,9807
	Insecto	0,00000	0,05375	1,00000	0,92761
	Maquina	0,00000	0,0998	1,00000	0,90023
Réptil	0,00000	0,09972	1,00000	0,90053	
Conjunto de teste	Maçã	1,00000	0,84682	0,00000	0,07932
	Martelo	1,00000	0,89109	0,00000	0,10737
	Toupeira	1,00000	0,89971	0,00000	0,0984
	Legume	0,00000	0,07415	1,00000	0,88002
	Electrodoméstico	0,00000	0,05079	1,00000	0,97266
	Mamífero	0,00000	0,10151	1,00000	0,84998

O conjunto de treino, tal como já era esperado teve resultados muito bons, tendo sido sempre significativamente mais activado o neurónio correspondente ao nível hierárquico desejado do conceito, como se pode verificar na Figura 16.

Para os conceitos de nível básico, a média dos níveis de activação para a unidade de nível básico foi de 0,95 contra os 0,04 de activação de média para a unidade de nível sobreordenado. Para os conceitos de nível sobreordenado a média dos níveis de activação para a unidade de nível sobreordenado foi de 0,92 contra os 0,07 de activação média para a unidade de nível básico.




Figura 16: Activação dos conceitos do conjunto de treino. Todos os conceitos de nível básico tiveram uma activação do neurónio representativo do nível básico na ordem dos 0,9 ou superior representado pelas barras vermelhas, dado que o valor máximo seria 1. O mesmo se verificou para os conceitos de nível sobreordenado em que a activação do neurónio representativo do nível sobreordenado rondou também os 0,9 ou superior representado pelas barras roxas.

O conjunto de teste também apresentou uma boa generalização a todos os conceitos como se pode observar na Figura 17.

Para os conceitos de nível básico, a média dos níveis de activação para a unidade de nível básico foi de 0,88 contra os 0,10 de activação de média para a unidade de nível sobreordenado. Para os conceitos de nível sobreordenado a média dos níveis de activação para a unidade de nível sobreordenado foi de 0,90 contra os 0,08 de activação média para a unidade de nível básico.




Figura 17: Activação dos conceitos do conjunto de teste. Todos os conceitos de nível básico tiveram uma activação do neurónio representativo do nível básico na ordem dos 0,84 ou superior representado pelas barras vermelhas, dado que o valor máximo seria 1. O mesmo se verificou para os conceitos de nível sobreordenado em que a activação do neurónio representativo do nível sobreordenado rondou também os 0,84 ou superior representado pelas barras roxas.

Dada a boa generalização da rede tanto para o conjunto de treino como para o conjunto de teste, podemos afirmar que em todos os conceitos a rede foi capaz de identificar corretamente o seu nível hierárquico através da análise do valor de partilha dos seus atributos. Com este pressuposto pode-se então confirmar a hipótese 1 do estudo que ditava que conceitos com atributos com valores de partilha mais elevados seriam identificados como conceitos do nível básico e conceitos com atributos com valores de partilha mais baixos seriam identificados como conceitos de nível sobreordenado, indo então de encontro com o concluído por Marques (2007) e testado neste modelo.

3.2. Categorização de conceitos

Quanto ao agrupamento de categorias e a diferenciação dos níveis de activação por relação Categoria-Conceito já não se verificaram os resultados desejados, não se conseguindo encontrar um padrão de activação comum para nenhuma das categorias. Desta forma também não é possível comparar categorias de ser vivo vs ser não vivo ou comparações entre categorias. Os resultados estão representados na Figura 18 e esperaria uma mancha semelhante para cada conceito em cada categoria, formando assim um padrão homogéneo para cada categoria que poderia ser comparado com as categorias restantes. Em vez disso, cada conceito registou um padrão de activação diferente.

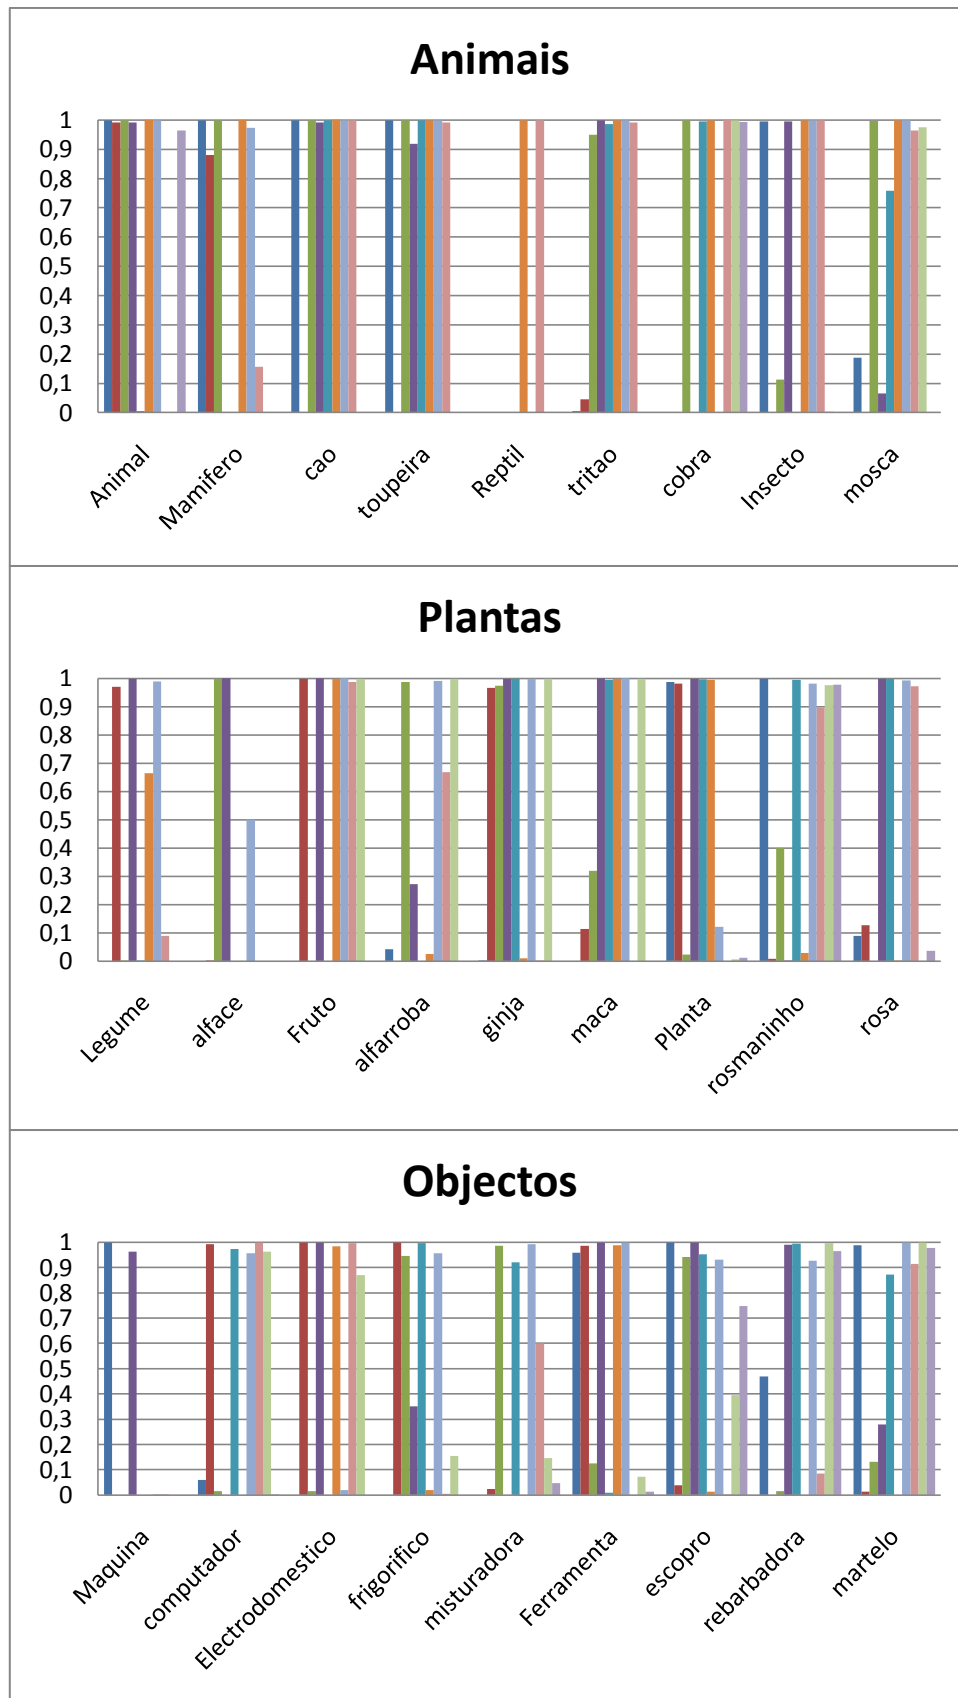


Figura 18: Padrões de activação por conceito – categoria. As várias cores representam o valor de activação dos 10 neurónios da camada escondida para cada conceito.

Dentro da categoria dos animais, conceitos como cão e toupeira criaram um padrão semelhante como se pode ver na Figura 19, mas não foi generalizado aos restantes conceitos para se poder determinar um padrão da categoria animal.

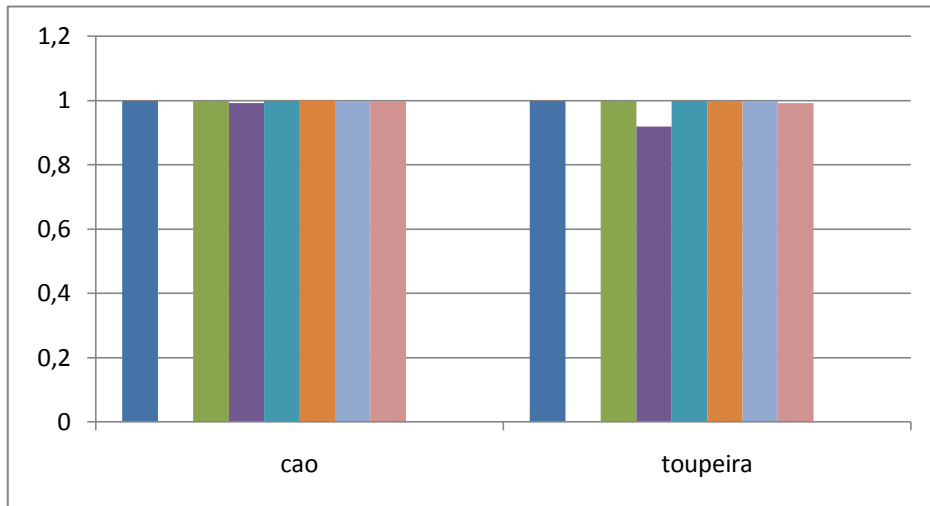


Figura 19: Padrão de activação de cão e toupeira. As várias cores representam o valor de activação dos 10 neurónios da camada escondida para cada conceito.

Para comparar de outra forma a activação dos vários conceitos-categorias, foram calculados coeficientes de correlação entre os vários conceitos e analisados quais é que mostravam uma maior correlação. Os resultados desta comparação estão representados na Figura 20. onde conceitos altamente correlacionados apresentam uma cor verde (conceitos com as mesmas características) ou cor vermelha (conceitos com características opostas). Esperaria encontrar forte correlação para conceitos da mesma categoria e fraca correlação para conceitos de categorias diferentes. Em vez disso não se criou um padrão de correlação com excepção de alguns conceitos da categoria ‘Animais’ onde se pode observar uma pequena mancha verde.




Figura 20: Correlação dos vários conceitos-categorias. Conceitos altamente correlacionados apresentam uma cor verde (conceitos com as mesmas características) ou cor vermelha (conceitos com características opostas).

Esta falta de coerência nos padrões dos conceitos de cada categoria pode ser explicada com base nos atributos que definem os conceitos. Uma vez que os atributos foram conseguidos através de listas de características indicadas por participantes reais, há a limitação das características que os participantes se lembraram no momento não havendo uma listagem exaustiva de todas as características que dado conceito verifica. Por exemplo é verdade que todos os animais são seres vivos, respiram, alimentam-se, etc., mas este tipo de características não foi listada para a maioria dos animais, e muito menos em conjunto para todos os conceitos da categoria animal o que dificulta criar um padrão de activação por agrupamento de características. Além disso, para que a construção do modelo e a inserção de dados fosse mais simples e computável, foram seleccionados apenas uma parte do conjunto de dados, limitando ainda mais o número de conceitos e atributos necessários para a emergência de padrões e categorias.

A formação de categorias faria mais sentido num modelo com uma arquitectura semelhante à do modelo de Rogers e colegas (2004) apresentada na Figura 9 da secção '1.4.2.3 Modelo de Rogers e colegas (2004)', onde o diferente tipo de conhecimento (nominal, perceptual, funcional, etc.) é agrupado em diferentes estruturas. Desta forma foi feita uma diferenciação de atributos criando uma maior intersecção entre conceitos. No corrente projecto o tipo de atributos não é diferenciado, existindo só uma camada (camada de entrada) onde são introduzidos todos os atributos fazendo só a distinção do seu valor de partilha.

3.3. Rede lesionada

Os resultados anteriormente apresentados representam uma simulação de identificação do nível hierárquico dos conceitos para sujeitos saudáveis. Para se simular e testar o comportamento da rede numa situação de demência semântica, simularam-se várias lesões na rede, desde a uma lesão mais superficial a lesões mais severas.

Foram simulados 5 graus de lesões, fazendo alterações na camada escondida (camada de processamento) simulando assim uma situação em que as estruturas cerebrais vão ficando cada vez mais danificadas, resultando em morte neuronal de algumas estruturas.

Foram simuladas dois tipos de lesões. Lesões ao nível das conexões, onde algumas conexões da camada escondida para a camada de saída foram eliminadas e lesões ao nível dos neurónios alguns neurónios da camada escondida foram sendo eliminados. Em ambas as situações as eliminações de conexões ou neurónios foram sendo feitas de forma gradual de forma a simular lesões de menor e maior gravidade.

3.3.1. Lesões ao nível das conexões

Partindo da rede original com a arquitectura descrita na secção 2.1.3 Arquitectura (pag.42) foram feitas lesões ao nível das conexões da camada escondida para a camada de saída. Estas conexões foram sendo eliminadas aleatoriamente de forma gradual simulando vários níveis de gravidade.

Foram criados 5 tipos de lesões sendo a lesão 1 menos grave e a lesão 5 a lesão mais severa de acordo com o plano descrito na Tabela 5. Dado que a camada escondida contém 10 neurónios e a camada de saída 2 neurónios, como existe uma conexão de cada neurónio da camada escondida para a camada de saída, na rede inicial existem 20 conexões da camada escondida para a camada de saída (10x2).

Tabela 5: Plano de lesões ao nível das conexões

Lesão	Conexões Removidas	Conexões intactas	Percentagem lesionada
Lesão 1	1 Conexão de cada neurónio	Restam 18	10%
Lesão 2	2 Conexões de cada neurónio	Restam 14	30%
Lesão 3	1 Conexão de cada neurónio	Restam 12	35%
Lesão 4	1 Conexão de cada neurónio	Restam 10	50%
Lesão 5	1 Conexão de cada neurónio	Restam 08	60%

Cada neurónio da camada escondida tem duas conexões para a camada de saída. Em cada lesão foi eliminada 1 conexão de cada neurónio (à excepção da lesão 2 onde se eliminaram 2

conexões) tentando assegurar que este continuava a estar ligado à camada escondida mantendo a outra conexão intacta. A lesão 1 é a lesão mais leve em que apenas foram eliminadas 2 conexões (1 para cada neurónio da camada de saída), lesionando 10% da rede, mantendo intactas 18 conexões. Cada nova lesão é feita sobre a lesão anterior, aumentando a percentagem de rede lesionada. Na lesão mais severa (lesão 5), 60% da rede está lesionada, restando apenas 8 conexões, o que provocou a inactivação e eliminação de 2 neurónios porque não restou nenhuma ligação para a camada de saída.

Depois de provocadas as lesões, para as 5 redes lesionadas foram introduzidos os padrões de treino e teste já apresentados para testar a identificação dos conceitos e avaliar desempenho da rede.

O comportamento da rede foi análogo tanto para o conjunto de treino como para o conjunto de teste. O desempenho geral da rede piorou tanto para os conceitos de nível básico como para os conceitos de nível sobreordenado, sendo muito mais acentuada a perda para os conceitos do nível sobreordenado. Na Figura 21 podem-se ver os resultados das lesões para o conjunto de treino.




Figura 21: Identificação dos conceitos do conjunto de treino das redes lesionadas ao nível das conexões. As linhas vermelhas correspondem aos resultados da rede saudável e as linhas azuis aos resultados das redes lesionadas, em que o azul mais escuro representa a lesão mais leve (lesão 1) e o azul mais claro a lesão mais severa (lesão 5).

Analisando os conceitos do nível básico pode-se ver que a maioria dos conceitos continuou a ser corretamente identificado. Os piores resultados registaram-se nas lesões 4 e 5 onde já havia uma percentagem de 50% e 60% lesionada respectivamente. Resultados mais detalhados podem ser consultados na Tabela 6.

Tabela 6: *Activação do conceito de nível básico do conjunto de treino das redes lesionadas ao nível das conexões*

<i>Nível básico</i>						
	Saudável	Les 1	Les 2	Les 3	Les 4	Les 5
alface	0,90043	0,90043	0,90156	0,87003	0,34978	0,34978
cao	0,90025	0,90025	0,83182	0,72558	0,17505	0,50669
cobra	0,96528	0,96904	0,94424	0,94424	0,5756	0,57576
computador	0,92842	0,92844	0,87532	0,79408	0,78748	0,80274
rosmaninho	0,95349	0,95839	0,92994	0,87762	0,72294	0,92661
tritao	0,97209	0,97209	0,95043	0,91109	0,48211	0,48439
alfarroba	0,96036	0,96036	0,9416	0,89646	0,41677	0,43314
escopro	0,96974	0,97225	0,97254	0,95179	0,64677	0,89855
frigorifico	0,9834	0,9834	0,98342	0,97021	0,74854	0,74855
ginja	0,98978	0,98978	0,9899	0,98127	0,8168	0,81765
misturadora	0,99599	0,99601	0,99424	0,98932	0,88481	0,88481
mosca	0,95983	0,95983	0,92972	0,8762	0,36322	0,43448
rebarbadora	0,91864	0,92682	0,92408	0,87183	0,86752	0,93209
rosa	0,9583	0,95847	0,92786	0,8734	0,87335	0,88829

Relativamente aos conceitos do nível sobreordenado, os seus resultados estão apresentados na Figura 21 e Tabela 7. Neste caso já se observa uma degradação acentuada do desempenho da rede onde a maior parte dos conceitos não foi capaz de ser identificado corretamente, mas não se verificou um padrão comportamental, havendo conceitos como *Animal* que registou resultados péssimos na ordem dos 0,2 e inferior logo a partir da lesão 2, contrastando com conceitos como *Máquina* que manteve resultados medianos na ordem dos 0,6 ao longo das lesões.

Tabela 7: Activação do conceito de nível sobreordenado do conjunto de treino das redes lesionadas ao nível das conexões

Nível sobreordenado						
	Saudável	Les 1	Les 2	Les 3	Les 4	Les 5
Animal	0,90405	0,90405	0,20201	0,05323	0,05417	0,04603
Fruto	0,91117	0,93396	0,67248	0,31091	0,31099	0,31099
Planta	0,93341	0,93354	0,27927	0,08049	0,57825	0,57767
Ferramenta	0,9807	0,98114	0,60394	0,25469	0,25939	0,25893
Insecto	0,92761	0,9277	0,25789	0,25789	0,25872	0,25872
Maquina	0,90023	0,90023	0,62601	0,62587	0,62623	0,62623
Reptil	0,90053	0,90057	0,56762	0,56755	0,56791	0,56791

Pode-se ver uma comparação geral dos resultados em média para o nível básico e sobreordenado na Figura 22.




Figura 22: Média da identificação dos conceitos do conjunto de treino das redes lesionadas ao nível das conexões.

Para a simulação saudável e lesões superficiais, o nível básico e sobreordenado apresentam um desempenho bom, começando a degradação do nível sobreordenado a ser mais acentuada

a partir da lesão 2, onde a média da activação no nível sobreordenado não ultrapassa o 0,5 não sendo suficiente para a sua identificação.

Os resultados para o conjunto de teste seguem o mesmo comportamento dos resultados do conjunto de treino e pode ser observado na Figura 23 o resultado geral e em média na Figura 24.

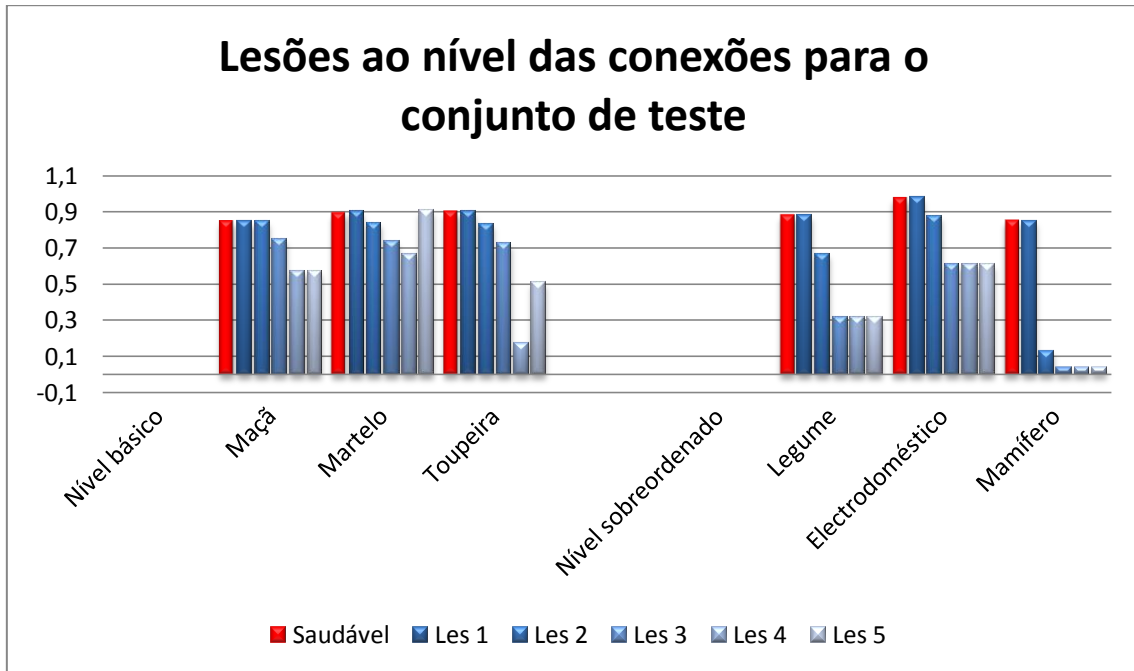


Figura 23: Identificação dos conceitos do conjunto de teste das redes lesionadas ao nível das conexões.




Figura 24: Média da identificação dos conceitos do conjunto de teste das redes lesionadas ao nível das conexões.

3.3.2. Lesões ao nível dos neurónios

Partindo da rede original com a arquitectura descrita na secção 2.1.3 Arquitectura (pag.42) foram feitas lesões ao nível do neurónio, eliminando neurónios da camada escondida (camada de processamento). Os neurónios foram sendo eliminados de forma gradual simulando vários níveis de gravidade.

Foram criados 5 tipos de lesões sendo a lesão 1 menos grave e a lesão 5 a lesão mais severa de acordo com o plano descrito na Tabela 8.

Tabela 8: Plano de lesões ao nível dos neurónios

Lesão	Neurónios Removidos	Neurónios Activos	Percentagem lesionada
Les 1	neurónio 7	9	10%
Les 2	neurónio 7 neurónio 4	8	20%
Les 3	neurónio 7 neurónio 4 neurónio 5 neurónio 6	6	40%
Les 4	neurónio 7 neurónio 4 neurónio 5 neurónio 6 neurónio 3	5	50%
Les 5	neurónio 7 neurónio 4 neurónio 5 neurónio 6 neurónio 3 neurónio 8	4	60%

A selecção de eliminação dos neurónios foi feita de acordo com a sua activação, em que os primeiros neurónios a ser lesionados foram aqueles mostravam uma maior activação para a generalidade dos conceitos. Para cada conceito foi verificada a activação das unidades da camada escondida e feita uma contagem das vezes que cada unidade mostrou uma activação superior a 90%. Os neurónios com mais activações superiores a 90% foram os considerados mais activados.

Foi eliminado o neurónio mais activado para criar a lesão 1 (lesão mais superficial) seguido do segundo neurónio mais activado e assim por adiante até se atingir uma percentagem de área lesionada superior a 50% restando apenas 4 neurónios dos 10 iniciais.

Depois de provocadas as lesões, para as 5 redes lesionadas foram introduzidos os padrões de treino e teste já apresentados para testar a identificação dos conceitos e avaliar desempenho da rede. O comportamento da rede foi análogo tanto para o conjunto de treino como para o conjunto de teste.

O desempenho da rede quanto à identificação dos conceitos do nível básico ficou bastante comprometido ao longo das lesões, em que quanto mais severa a lesão, pior o desempenho da rede. O mesmo já não acontece com os conceitos do nível sobreordenado, onde o desempenho da rede piorou ligeiramente para alguns conceitos mas não significativamente e nalguns casos até melhorou. Os resultados da activação da rede para as várias lesões e comparação com a simulação saudável estão representados na Figura 25.




Figura 25: Identificação dos conceitos do conjunto de treino das redes lesionadas ao nível dos neurónios. A barra vermelha representa a simulação saudável e as lesões são representadas pelas barras azuis, dado que o azul mais escuro representa a lesão mais superficial (lesão 1) e o azul mais claro a lesão mais severa (lesão 5).

Para os conceitos do nível básico registou-se uma degradação do desempenho consistente com a gravidade das lesões. Em geral para todos os conceitos não se observou grande diferença entre a Lesão 1 e Lesão 2 porque tendo sido apenas removido mais 1 neurónio, a lesão 2 não seria muito mais grave que a lesão 1. A partir da lesão 3 e seguintes, notam-se grandes diferenças na identificação dos conceitos, sendo que na lesão 5 nenhum conceito mostra uma activação do neurónio de nível básico com um valor superior a 0,5 não sendo possível identificá-lo como tal. Para uma análise mais pormenorizada dos resultados pode-se consultar a Tabela 9.

Tabela 9: *Activação do conceito de nível básico do conjunto de treino das redes lesionadas ao nível dos neurónios.*

<i>Nível Básico</i>						
	Saudável	Les 1	Les 2	Les 3	Les 4	Les 5
alface	0,90043	0,86858	0,87003	0,87024	0,35021	0,35021
cao	0,90025	0,82832	0,83011	0,71969	0,17084	0,10031
cobra	0,96528	0,96528	0,96528	0,94314	0,57056	0,41822
computador	0,92842	0,87691	0,87691	0,3088	0,30035	0,1885
rosmaninho	0,95349	0,91719	0,9172	0,41059	0,20222	0,12746
tritao	0,97209	0,94902	0,94963	0,91138	0,483	0,3368
alfarroba	0,96036	0,92862	0,92885	0,93255	0,53298	0,43081
escopro	0,96974	0,94699	0,94762	0,55339	0,10308	0,10291
frigorifico	0,9834	0,97018	0,97031	0,66677	0,1546	0,15418
ginja	0,98978	0,98105	0,98128	0,75703	0,20959	0,20947
misturadora	0,99599	0,99255	0,99255	0,90619	0,44472	0,3565
mosca	0,95983	0,92746	0,92752	0,93037	0,51847	0,37325
rebarbadora	0,91864	0,86321	0,86469	0,27358	0,26608	0,25599
rosa	0,9583	0,92496	0,92583	0,42272	0,42261	0,28708

Relativamente aos conceitos do nível sobreordenado, os seus resultados estão apresentados na Figura 25 e Tabela 10. Nas lesões ao nível do neurónio, ao nível sobreordenado todos os conceitos continuam a conseguir ser corretamente identificados e em alguns conceitos a activação ainda é superior. Todos os conceitos à excepção de réptil têm uma activação do nível sobreordenado bastante clara, registando valores superiores a 0,8.

Tabela 10: *Activação do conceito de nível sobreordenado do conjunto de treino das redes lesionadas ao nível dos neurónios.*

	Nível Sobreordenado					
	Saudável	Les 1	Les 2	Les 3	Les 4	Les 5
Animal	0,90405	0,97166	0,96497	0,80263	0,97511	0,97511
Fruto	0,91117	0,97392	0,96769	0,81308	0,81308	0,81772
Planta	0,93341	0,9426	0,92944	0,96786	0,96955	0,96955
Ferramenta	0,9807	0,99462	0,99331	0,95743	0,9677	0,9677
Insecto	0,92761	0,97902	0,97399	0,84514	0,87577	0,87913
Maquina	0,90023	0,90048	0,87977	0,87993	0,87995	0,87996
Reptil	0,90053	0,90053	0,90053	0,56815	0,56871	0,57634

Pode-se ver uma comparação geral dos resultados em média para o nível básico e sobreordenado na Figura 26.




Figura 26: Média da identificação dos conceitos do conjunto de treino das redes lesionadas ao nível dos neurónios.

O nível básico mostra uma degradação acentuada ao longo das lesões, principalmente a partir da lesão 2 uma vez que a severidade da lesão 1 para a lesão 2 não se mostrou significativa. O nível sobreordenado mostra uma robustez ao longo das lesões, tendo sempre uma activação

superior a 0,8 para os conceitos sobreordenados, mostrando até ativações ligeiramente superiores para as lesões menos significativas.

Os resultados para o conjunto de teste seguem o mesmo comportamento dos resultados do conjunto de treino e podem ser observados na Figura 27 os resultados gerais e em média na Figura 28.




Figura 27: Identificação dos conceitos do conjunto de teste das redes lesionadas ao nível dos neurónios.

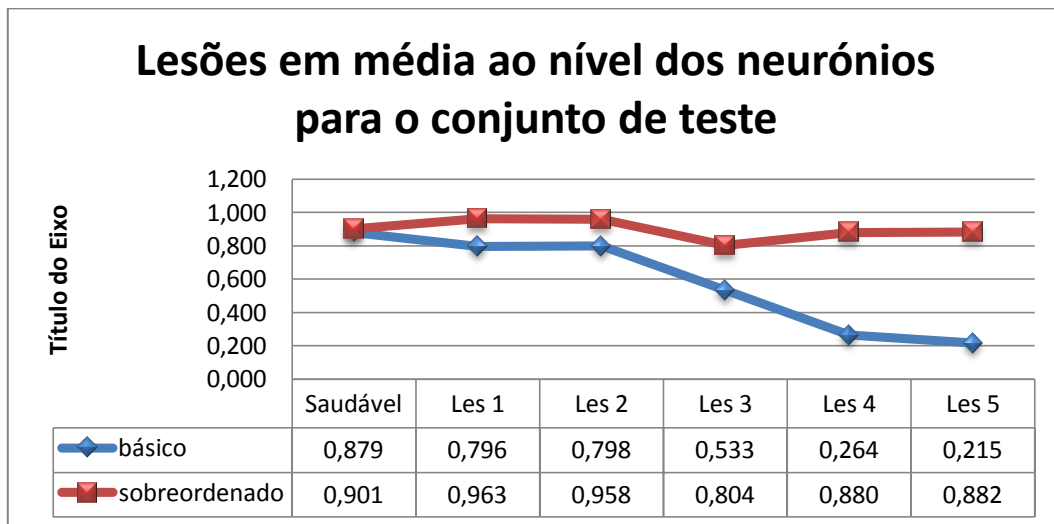


Figura 28: Média da identificação dos conceitos do conjunto de teste das redes lesionadas ao nível dos neurónios.

De modo a avaliar o critério de eliminação das unidades da camada escondida para criação das lesões, foi feita uma comparação entre os resultados obtidos com o critério escolhido (eliminação dos neurónios mais activos) e com o que resultaria se tivessem sido eliminados os neurónios menos activos. Criou-se uma simulação da lesão mais grave (Lesão 5) mas em que os 60% das unidades eliminadas correspondem aos neurónios menos activos. A média dos dados de treino e teste estão representados na Figura 29.




Figura 29: Comparação entre as simulações de lesão de nível 5. Dados do conjunto de treino e teste.

Verificou-se para a lesão dos neurónios menos activos um comportamento oposto ao verificado para a lesão dos neurónios mais activos. Ou seja, na lesão dos neurónios menos activos, os conceitos de nível básico ainda tiveram uma activação medianamente satisfatória enquanto que a activação dos conceitos do nível sobreordenado piorou. Este comportamento é mais evidente para o conjunto de dados de teste onde se verifica um declínio evidente de activação do nível sobreordenado, mas este também se observa para o conjunto de dados de treino.

4. Conclusão

4.1. Discussão

De acordo com a literatura estudada para a concretização do trabalho, considero que os modelos conexionistas oferecem teorias mais robustas para o funcionamento e organização da memória semântica. As teorias baseadas nos modelos hierárquicos da organização da memória semântica entram em contradição umas com as outras e não conseguem dar uma resposta consistente que explique o paradoxo da vantagem Nível Básico vs vantagem do Nível Sobreordenado. A organização do conhecimento faz mais sentido organizada num conjunto de características que forma padrões de activação de acordo com as semelhanças dos seus atributos, agrupando num mesmo tipo de padrão conceitos semelhantes dando assim origem a categorias de conceitos.

O modelo desenvolvido para a concretização deste projecto, é um modelo de redes neuronais que tem como base de funcionamento as teorias conexionistas. A partir de um conjunto de atributos para cada conceito, são criados padrões de activação para cada conceito. No presente modelo o principal objectivo não era tanto a criação de categorias, mas sim a diferenciação do nível hierárquico do conceito com base no valor de partilha dos seus atributos. Tal como visto no estudo de Marques (2007), atributos de conceitos de nível básico apresentam valores de partilha mais elevados que atributos de conceitos de nível sobreordenado. Alimentando a rede com estes dados, pudemos comprovar que o modelo foi capaz de diferenciar o nível hierárquico de cada conceito com sucesso, comprovando que este parâmetro tem um papel importante na caracterização e organização do conhecimento semântico. Os modelos anteriormente estudados que pretendiam estudar a estrutura da memória semântica (Rogers, et al., 2004) faziam a diferenciação do nível básico e sobreordenado pela avaliação do desempenho da rede em várias tarefas semânticas e analisando a quantidade de erros para cada nível hierárquico. Desta forma era estudado e comparado o desempenho do modelo em simulações saudáveis e lesionadas para as várias tarefas, mas não era analisada a contribuição e importância de nenhum parâmetro específico para a estrutura e organização da memória semântica sendo apenas feita a diferenciação entre informação verbal e visual dos conceitos.

O modelo aqui desenvolvido tinha como segundo objectivo a formação de categorias a partir dos padrões de activação dos conceitos. Os conceitos introduzidos na rede pertenciam a 3 domínios, animais, plantas e objectos e todos os atributos eram partilhados por pelo menos dois conceitos de forma a tentar criar mais intersecções de atributos fomentando a partilha de atributos por conceitos e a formação de categorias. Contudo, não se verificaram padrões de activação de conceitos que conseguissem formar categorias. Apenas se verificou um padrão semelhante entre os conceitos cão e toupeira e alguma correlação entre conceitos do domínio

animal. Entre os conceitos do domínio animal, cão e toupeira são os conceitos que partilhavam um maior número de atributos. Apesar de estes resultados não serem suficientes para confirmar a hipótese de que conceitos formam padrões de activação semelhantes para o mesmo domínio e distintos para domínios diferentes, levam a crer que existe alguma relação entre conceitos do mesmo domínio, mas que o conjunto de dados não é suficiente para fazer esta avaliação. Além da insuficiência de dados devido ao pouco número de conceitos e de atributos listados para cada conceito, a forma como os atributos foram gerados é limitativa. A listagem de atributos torna-se limitada e pouco eficiente porque por vezes não são incluídos atributos essenciais para a definição de um conceito. Por exemplo, todos os animais são seres vivos, respiram, alimentam-se etc. mas estas características não foram listadas para todos os animais, reduzindo assim a possibilidade de serem agrupados de acordo com as suas características, o que aconteceria com mais probabilidade se os atributos fossem exaustivamente listados. Esta e outras críticas também foram apontadas por outros autores considerando que a listagem de atributos por pessoas não será uma forma eficiente de definição de conceitos (Rogers, et al., 2004).

Como terceiro objectivo do projecto criei lesões para avaliar o comportamento da rede. Foram criadas lesões ao nível das conexões e ao nível dos neurónios.

Ao nível das conexões optei por lesionar as ligações da camada escondida para a camada de saída, porque é na camada escondida que é feita uma maior transformação de pesos e processamento da rede. O processamento entre camada escondida (intermédia) e a camada de saída tem um processamento não linear que resulta de dados já transformados, enquanto que o valor das conexões da camada de entrada para a camada escondida está dependente do input que para cada conceito é constante e já conhecido. Uma lesão numa conexão entre uma unidade da camada de entrada e a camada escondida, iria sempre afectar qualquer resposta que tivesse como input a unidade com a conexão danificada, podendo enviesar um pouco os resultados obtidos.

O modelo quando lesionado ao nível das conexões evidenciou um declínio de desempenho na identificação dos conceitos do nível sobreordenado mais acentuado do que para os conceitos de nível básico. Considerando que as lesões ao nível das conexões têm um maior impacto no processamento da rede, pode-se fazer um paralelismo com o facto de atributos menos partilhados (que estão associados aos conceitos sobreordenados) exigirem mais processamento (Raposo, Mendes, & Marques, In press). Quando as estruturas responsáveis pelo processamento da rede são danificadas, o seu desempenho para a identificação dos conceitos sobreordenados é mais afectada.

A lesão ao nível dos neurónios obteve resultados mais comparáveis com o comportamento observado em pacientes com demência semântica. Foram criados 5 níveis de lesões lesionando 10%, 20%, 40%, 50% e 60% das unidades da camada escondida da rede. Observou-se que à medida que a dimensão da rede lesionada aumentava, simulando uma lesão mais grave, pior era o seu desempenho ao nível básico, mas não ao nível sobreordenado, mostrando o mesmo comportamento que o observado em modelos computacionais anteriores com simulações de lesões (Hinton & Shallice, 1991; Farah & McClelland, 1991; Lambon Ralph,

McClelland, Patterson, Galton, & Hodges, 2001; Rogers, et al., 2004). Apesar de neste projecto, não terem sido comparados os resultados da rede com dados de paciente reais, sabemos que pacientes com demência semântica mostram dificuldade na identificação de conceitos de nível básico, mas continuam a conseguir identificar corretamente muitos conceitos de nível sobreordenado cometendo muitos mais erros ao nível básico que sobreordenado (Warrigton, 1975; Hodges, Graham, & Patterson, 1995; Rogers & Patterson, 2007), conseguindo o modelo reproduzir neste aspecto o comportamento dos pacientes.

Contrariamente ao que dizem as teorias conexionistas que justificam a robustez do nível sobreordenado com a afirmação que são as unidades semânticas mais activadas (Rogers & Patterson, 2007), nas simulações de lesões do presente modelo verificou-se o contrário. Foram lesionadas as unidades com maior activação e observadas alterações principalmente ao nível básico. Numa comparação em que se criou a lesão mais severa (lesão 5 com 60% das unidades da camada escondida lesionadas) mas afectando os neurónios menos activados. Verificou-se uma relativa preservação da identificação dos conceitos do nível básico e uma degradação da identificação dos conceitos de nível sobreordenado. Esta comparação sugere que as unidades de processamento mais activadas estavam relacionadas com a identificação do nível básico e as unidades menos activadas relacionadas com a identificação do nível sobreordenado. A maior activação dos neurónios para os conceitos do nível básico está de acordo com os resultados do estudo de Raposo e colegas (In press) que observaram uma extensa activação das áreas temporais, que pode reflectir uma maior representação dos atributos mais partilhados na rede semântica, visto que atributos que são comuns a mais conceitos tendem a ter associações mais fortes em memória. Além disso a rede foi alimentada com mais conceitos de nível básico do que conceitos de nível sobreordenado (17 nível básico, 10 nível sobreordenado) o que faz com que a sua aprendizagem crie padrões de activação mais fortes para estes conceitos. A superioridade numérica dos conceitos de nível básico e a maior partilha dos seus atributos contribui para uma maior activação das unidades de processamento da rede.

Como os modelos computacionais anteriormente feitos (Hinton & Shallice, 1991; Farah & McClelland, 1991; Lambon Ralph, McClelland, Patterson, Galton, & Hodges, 2001; Rogers, et al., 2004), este modelo também não pretendia uma representação fiel à estrutura do cérebro humano, mas sim uma reprodução do seu comportamento em determinada tarefa. Neste caso especificamente, era pretendido um modelo computacional que conseguisse trabalhar a questão da partilha dos atributos de um conceito e com este parâmetro conseguir fazer a diferenciação do seu nível hierárquico. A hierarquia do modelo é bastante simples nunca podendo ser comparada à complexidade da cognição humana. Também as lesões foram simuladas de uma forma simplista, provocando lesões apenas ao nível das conexões ou ao nível dos neurónios. Numa situação real existem lesões a ambos os níveis e o cérebro funciona numa globalidade de estruturas em que as regiões lesionadas são compensadas pelas regiões saudáveis tendo impactos no seu comportamento.

4.2. Trabalho futuro

Ao longo do trabalho e principalmente no fim, fui-me apercebendo de muita coisa que gostaria de ter feito ou ter feito de forma diferente. Por falta de conhecimento ou de tempo, já não foi possível incluir ou modificar muitas dessas coisas no presente projecto, mas fica o desejo de realização em trabalho futuro.

Um dos objectivos do modelo era também a categorização de conceitos, que não foi possível devido ao pouco número de dados, à listagem pouco exaustiva de atributos. Acredito que alimentando a rede de outra forma, onde para cada conceito seriam listados todos os atributos que se aplicassem, a emergência de padrões semelhantes para conceitos do mesmo domínio criando categorias teria surgido. Neste ponto, gostaria de alimentar a rede com um conjunto mais exaustivo de atributos para cada conceito, mas além de se tornar computacionalmente mais difícil, não tinha o valor de partilha para os atributos adicionais de cada conceito. No que diz respeito às simulações de lesões, tendo em conta o presente modelo, seria interessante poder comparar o desempenho da rede com o desempenho de pacientes reais e avaliar até que ponto os resultados das simulações de lesões da rede produziram resultados semelhantes aos reais.

Outra crítica que fiz ao meu próprio trabalho foi a simplicidade da arquitectura da rede. Alguns dos modelos computacionais anteriores tinham uma arquitectura com módulos recursivos que permitiam a criação de atractores (Hinton & Shallice, 1991; Lambon Ralph, McClelland, Patterson, Galton, & Hodges, 2001; Rogers, et al., 2004). Atractores são unidades da rede (normalmente da camada de saída) para os quais se criam padrões de convergência. Quando a activação dos pesos da rede se aproxima deste ponto, a unidade que funciona como atractor é mais activada. Criando uma rede com este tipo de arquitectura, alimentada com um conjunto exaustivo de atributos para cada conceito e tendo como output da rede os próprios conceitos e não o seu nível hierárquico, seria interessante lesionar a rede e verificar se nas simulações da rede lesionada a activação de conjuntos de atributos de conceitos de nível básico activariam como resposta o conceito de nível sobreordenado correspondente. Por exemplo, para o conjunto de atributos que define cão a resposta pretendida para a rede lesionada seria mamífero ou mesmo animal.

Existe ainda muito espaço e terreno inexplorado relativamente à modelação cognitiva e pretendemos com este tipo de modelos computacionais conseguir estudar a complexidade da cognição humana. Os modelos desenvolvidos ainda estão longe de ser uma boa abstracção do cérebro humano, mas já conseguem, aos poucos, ir simulando o seu funcionamento e recriando comportamentos. Espero com este modelo e trabalho ter contribuído um pouco para esta evolução e fusão entre áreas como a psicologia e a informática. É esta interdisciplinaridade que caracteriza a ciência cognitiva e acredito que seja o caminho do futuro.

5. Referências

- Barsalou, L. W. (1993). Flexibility, structure and linguistic vagary in concepts: Manifestations of a compositional system of perceptual symbols. In A. C. Collins, S. E. Gathercole, M. A. Conway, & P. E. Morris (Edits.), *Theories of memory* (pp. 29-101). Hove, UK: Lawrence Erlbaum Associates Ltd.
- Collins, A. M., & Loftus, E. F. (1975). A Spreading-Activation theory of semantic processing. *Psychological Review*, *82*(6), 407-428.
- Collins, A. M., & Quillian, M. R. (1969). Retrieval time from semantic memory. *Journal of Verbal Learning and Verbal Behavior*, *8*, 240-247.
- Farah, M. J., & McClelland, J. L. (1991). A Computational Model of Semantic Memory Impairment: Modality Specificity and Emergent Category Specificity. *Journal of Experimental Psychology: General*, *120*(4), 339-357.
- Haykin, S. (1994). *Neural Networks. A comprehensive foundation*. . USA: Prentice-Hall.
- Hinton, G. E. (2002). How Neural Networks Learn from Experience. In T. A. Polk, & M. C. Seifert (Edits.), *Cognitive Modeling*. Cambridge, MA: MIT Press.
- Hinton, G. E. (1981). Implementing semantic networks in parallel hardware. In G. E. Hinton, & J. A. Anderson (Edits.), *Parallel models of associative memory* (pp. 161-187). Hillsdale, NJ: Erlbaum.
- Hinton, G. E., & Sejnowski, T. J. (1986). Learning and relearning in Boltzmann machines. In D. E. Rumelhart, & J. L. McClelland (Edits.), *Parallel distributed processing: Explorations in the microstructure of cognition* (Vol. 1, pp. 282-317). Cambridge: MA: MIT Press.
- Hinton, G. E., & Shallice, T. (1991). Lesioning an Attractor Network: Investigations of Acquired Dyslexia. *Psychological Review*, *98*(1), 74-95.
- Hinton, G. E., Plaut, D. C., & Shallice, T. (1993). Simulating Brain Damage. *Scientific American*, *269*(4), 76-82.
- Hodges, J. R., & McCarthy, R. A. (1996). Loss of Remote Memory: A Cognitive Neuropsychological Perspective. In A. W. Ellis, & A. W. Young, *Human cognitive Neuropsychology*. (pp. 645-655). UK: Psychology Press.
- Hodges, J. R., Graham, N., & Patterson, K. (1995). Charting the progression in semantic dementia: Implications for the organisation of semantic memory. *Memory*, *3*, 463-495.
- Johnson, K. E., & Mervis, C. B. (1997). Effects of varying levels of expertise on basic level of categorization. *Journal of Experimental Psychology: General*, *126*, 248-277.
- Jolicoeur, P., Gluck, M., & Kosslyn, S. (1984). Pictures and names: Making the connection. *Cognitive Psychology*, *19*, 31-53.

- Kandel, E. R., Kupfermann, I., & Iversen, S. (2000). Learning and Memory. In E. R. Kandel, J. H. Schwartz, & T. M. Jessel (Eds.), *Principles of Neural Science*. USA: McGraw-Hill.
- Lambon Ralph, M. A., McClelland, J. L., Patterson, K., Galton, C. L., & Hodges, J. R. (2001). No Right to Speak? The relationship between Object Naming and Semantic Impairment: Neuropsychological Evidence and a Computational Model. *Journal of Cognitive Neuroscience*, *13*(3), 341-356.
- Marques, J. F. (2007). The general/specific breakdown of semantic memory and the nature of superordinate knowledge: Insights from superordinate and basic-level norms. *Cognitive Neuropsychology*, *24*(8), 879-903.
- McClelland, J. L., & Rogers, T. T. (2003). The parallel distributed processing approach to semantic cognition. *Nature Reviews Neuroscience*, *4*, 310-322.
- Murphy, G. L., & Brownell, H. H. (1985). Category differentiation in object recognition: Typicality constraints on the basic category advantage. *Journal of Experimental Psychology: Learning, Memory and Cognition*, *11*, 70-84.
- Polk, T. A., & Seifert, C. M. (Eds.). (2002). *Cognitive modeling*. Cambridge, MA: MIT Press.
- Raposo, A., Mendes, M., & Marques, J. F. (In press). The hierarchical organization of semantic memory: Executive function in the processing of superordinate. *Neuroimage*, (2011), doi:10.1016/j.neuroimage.2011.08.072.
- Rapp, B. C., & Caramazza, A. (1989). General to Specific Access to Word Meaning: A Claim Re-examined. *Cognitive Neuropsychology*, *6*, 251-272.
- Rogers, T. T. (2008). Computational models of semantic memory. In R. Sun (Ed.), *The cambridge handbook of computational psychology* (pp. 226-266). Cambridge, UK: Cambridge University Press.
- Rogers, T. T., & McClelland, J. L. (2004). *Semantic Cognition: A Parallel Distributed Processing approach*. Cambridge, MA: MIT Press.
- Rogers, T. T., & Patterson, K. (2007). Object Categorization: Reversals and Explanations of the Basic-Level Advantage. *Journal of Experimental Psychology: General*, *3*, 451-469.
- Rogers, T. T., Lambon Ralph, M. A., Garrard, P., Bozeat, S., McClelland, J. L., Hodges, J. R., et al. (2004). Structure and deterioration of semantic memory: A neuropsychology and computational investigation. *Psychological Review*, *111*(1), 205-235.
- Rosch, E. (1978). Principles of Categorization. In E. Rosch, & B. B. Lloyd (Eds.), *Cognition and categorization* (pp. 27-48). Hillsdale, N.J.: Lawrence Erlbaum.
- Rosch, E., Mervis, C. B., Gray, W. D., Johnson, D. M., & Boyes-Braem, P. (1976). Basic Objects in Natural Categories. *Cognitive Psychology*, *8*, 382-439.

Rumelhart. (1990). Brain style computation: {Learning} and generalization. In J. L. Davis, S. F. Zornetzer, & C. Lau (Edits.), *An introduction to neural and electronic networks* (pp. 405-420). San Diego, CA: Academic Press.

Rumelhart, D. E., & Todd, P. M. (1993). Learning and connectionist representations. In D. E. Meyer, & S. Kornblum (Edits.), *Attention and Performance XIV: Synergies in experimental psychology, Artificial Intelligence, and Cognitive neuroscience*. (pp. 3-30). Cambridge, MA: MIT Press.

Rumelhart, D. E., Smolensky, P., McClelland, J. L., & Hinton, G. E. (1986). Schemata and sequential thought processes in PDP models. In J. L. McClelland, D. E. Rumelhart, & t. P. Group (Edits.), *Parallel distributed processing: Explorations in the microstructure of cognition. Volume 2: Psychological and biological models* (pp. 7-57). Cambridge, MA: MIT Press.

Schacter, D. L., Wagner, A. D., & Buckner, R. L. (2000). Memory systems of 1999. In E. Tulving, & F. I. Craik (Edits.), *The Oxford handbook of memory*. New York: Oxford University Press.

Tanaka, J., & Taylor, M. (1991). Object categories and expertise: Is the basic level in the eye of the beholder? *Cognitive Psychology*, 23, 457-482.

Warrington, E. K. (1975). The selective impairment of semantic memory. *The Quarterly Journal of Experimental Psychology*, 27, 632-657.

Anexos

I. Rede Neuronal

SNNs network definition file V1.4-3D
generated at Fri Sep 23 19:29:46 2011

network name : T2_10

source

files :

no. of units : 104

no. of connections :

940

no. of unit types : 0

no. of site types : 0

learning function : Std_Backpropagation

update function : Topological_Order

unit default section :

act	bias	st	subnet	layer	act func	out func
0.00000	0.00000	h		0	1 Act_Logistic	Out_Identity

unit definition section :

no.	typeName	unitName	act	bias	st	position	act func	out func	sites
1		cultivado	0.00000	-0.93909	i	6,10, 1			
2		saudavel	0.00000	0.77679	i	4, 9, 1			
3		acompanhamento	0.00000	-0.65923	i	2, 8, 1			
4		alimento	0.00000	-0.08463	i	2, 9, 1			
5		vegetal	0.00000	0.18772	i	15, 7, 1			
6		verde	0.00000	-0.00528	i	0, 8, 1			
7		come-se	0.00000	-0.13517	i	0, 9, 1			
8		saboroso	0.00000	-0.10794	i	1,11, 1			
9		vitaminas	0.00000	-0.63482	i	3, 8, 1			
10		salada	0.00000	-0.12229	i	10,11, 1			
11		sopa	0.00000	-0.24558	i	10,10, 1			
12		terra	0.00000	0.25175	i	10, 8, 1			
13		comprido	0.00000	0.26695	i	16,10, 1			
14		fruto	0.00000	-0.96875	i	14, 9, 1			
15		castanho	0.00000	-0.68462	i	14, 8, 1			
16		metal	0.00000	0.71099	i	12,11, 1			
17		pernas_4	0.00000	0.84161	i	6,11, 1			
18		varias_formas	0.00000	-0.68676	i	5,11, 1			
19		varios_tamanhos	0.00000	0.86169	i	9, 9, 1			
20		botoes	0.00000	-0.33512	i	10, 7, 1			
21		varias_cores	0.00000	0.89349	i	10, 9, 1			
22		focinho	0.00000	-0.65691	i	11, 8, 1			
23		animal	650.000	-0.56163	i	17,10, 1			

24	mamifero	0.00000	0.26798	i	15, 9, 1
25	varios_tipos	0.00000	-0.91156	i	15, 8, 1
26	companhia	0.00000	-0.26658	i	4, 7, 1
27	olfacto	0.00000	0.37675	i	12, 7, 1
28	patas	564.000	0.01981	i	9, 7, 1
29	pelo	545.000	-0.55144	i	2, 7, 1
30	barulhento	0.00000	-0.14328	i	1,10, 1
31	reptil	0.00000	0.24351	i	5, 7, 1
32	ser_vivo	640.000	0.16648	i	5, 8, 1
33	move-se	0.00000	0.39695	i	5, 9, 1
34	nao_patas	0.00000	0.96026	i	4, 8, 1
35	rasteja	0.00000	0.74749	i	9,10, 1
36	venenoso	0.00000	0.23081	i	9, 8, 1
37	ovos	0.00000	0.41636	i	15,10, 1
38	escamas	0.00000	-0.55986	i	1, 9, 1
39	util	0.00000	0.16556	i	2,10, 1
40	ferramenta	0.00000	-0.01517	i	16,11, 1
41	conserva_alimentos	0.00000	-0.61650	i	0,10, 1
42	eletrico	0.00000	-0.91064	i	0,11, 1
43	grande	390.000	-0.14927	i	11, 7, 1
44	electrodomestico	0.00000	0.17508	i	9,11, 1
45	energia	0.00000	-0.35850	i	3, 9, 1
46	cozinha	0.00000	0.12967	i	3,10, 1
47	branco	0.00000	0.38475	i	7, 9, 1
48	doce	0.00000	0.31529	i	11,11, 1
49	pequeno	445.000	-0.12699	i	11,10, 1
50	redondo	0.00000	-0.15806	i	11, 9, 1
51	vermelho	0.00000	0.93768	i	5,10, 1
52	cheira_bem	0.00000	0.85723	i	17, 9, 1
53	amarela	0.00000	-0.16294	i	2,11, 1
54	arvore	0.00000	0.60643	i	8,11, 1
55	amargo	0.00000	0.39695	i	8,10, 1
56	caroco	0.00000	0.05319	i	8, 9, 1
57	casca	0.00000	-0.96875	i	8, 8, 1
58	sumo	0.00000	0.16568	i	14, 7, 1
59	perigoso	0.00000	-0.17112	i	8, 7, 1
60	pesado	0.00000	0.82287	i	7,10, 1
61	constr_civil	0.00000	-0.65758	i	12,10, 1
62	maquina	0.00000	-0.07730	i	12, 9, 1
63	batidos	0.00000	0.83404	i	15,11, 1
64	folhas	0.00000	-0.06430	i	16, 9, 1
65	laminas	0.00000	0.74804	i	16, 8, 1
66	irritante	0.00000	0.08670	i	1, 7, 1
67	nojento	0.00000	-0.64000	i	1, 8, 1
68	preto	0.00000	0.82311	i	13, 7, 1
69	asas	0.00000	0.13083	i	6, 7, 1
70	voa	0.00000	-0.52110	i	3,11, 1
71	cauda	0.00000	-0.46599	i	13, 9, 1
72	decorar	0.00000	0.33128	i	17, 8, 1
73	flor	0.00000	0.26957	i	4,10, 1
74	pica	0.00000	0.81121	i	4,11, 1
75	caule	0.00000	-0.92322	i	14,11, 1
76	oferta	0.00000	0.72851	i	13,11, 1
77	planta	0.00000	-0.93255	i	13, 8, 1
78	cozinhado	0.00000	-0.75024	i	14,10, 1
79	feio	0.00000	0.86181	i	16, 7, 1
80	viscoso	0.00000	-0.72155	i	6, 8, 1
81	bonito	0.00000	0.08194	i	6, 9, 1
82	pelos	555.000	-0.92334	i	13,10, 1
83	lojas	0.00000	0.18064	i	0, 7, 1

84	casas	0.00000	0.69286	i	0, 6, 1
85	realizar_tarefa	0.00000	0.41722	i	17, 6, 1
86	varias_funcoes	0.00000	0.26109	i	7, 8, 1
87	auxilia_tarefas	0.00000	0.27897	i	3, 7, 1
88	mercado	0.00000	0.77502	i	17,11, 1
89	cheiro	0.00000	-0.95679	i	12, 8, 1
90	estufas	0.00000	-0.24619	i	17, 7, 1
91	vive_agua	336.000	-0.27641	i	7, 7, 1
92	vive_terra	518.000	0.56761	i	7,11, 1
93	no_name	100.000	-0.44027	h	6, 3, 1
94	no_name	0.97479	0.29229	h	7, 3, 1
95	no_name	0.15720	-0.20417	h	8, 3, 1
96	no_name	0.00042	0.34223	h	9, 3, 1
97	no_name	100.000	0.67768	h	6, 2, 1
98	no_name	0.88157	-0.07548	h	7, 2, 1
99	no_name	0.99849	-0.40910	h	8, 2, 1
100	no_name	0.00002	0.65170	h	9, 2, 1
101	no_name	0.00002	-0.54747	h	10, 2, 1
102	no_name	0.00002	0.06531	h	10, 3, 1
103	Basico	0.10151	-0.61635	o	8, 0, 1
104	Sobreordenado	0.84998	0.30685	o	9, 0, 1

connection definition section :

target site source:weight

```

-----
93      1: 0.78112, 2:-0.34127, 3: 0.62580, 4: 0.60501, 5:-0.38411, 6: 0.37293, 7:-0.22138, 8:-1.01036,
9:-0.66387, 10:-0.01942, 11: 0.39245, 12:-0.31728, 13: 0.18361, 14:-0.48302, 15:-0.74457, 16:-0.65432,
17:-0.96345, 18: 0.31643, 19:-0.69147, 20:-0.91585, 21: 0.64923, 22:-0.19102, 23: 0.32365, 24: 0.85235,
25: 1.14579, 26:-0.80914, 27: 0.95379, 28: 0.83935, 29: 0.98810, 30:-0.35686, 31: 0.59158, 32:-0.05415,
33: 0.13596, 34: 0.77980, 35: 0.95461, 36:-0.59038, 37: 0.99450, 38:-0.48856, 39:-0.85041, 40:-0.15131,
41: 0.52148, 42: 0.37159, 43: 0.35228, 44: 0.06637, 45:-0.84129, 46:-0.70676, 47:-1.00251, 48:-0.88193,
49: 0.98131, 50: 0.36837, 51:-0.06390, 52:-0.09180, 53:-0.15656, 54: 0.94685, 55:-0.45485, 56:-0.55066,
57: 0.47185, 58: 0.53762, 59:-0.95430, 60:-0.02317, 61:-0.87293, 62:-0.20042, 63: 0.04580, 64:-0.77345,
65:-0.98847, 66:-0.01518, 67:-0.55133, 68:-0.28630, 69:-0.31436, 70: 0.34454, 71: 0.41171, 72: 0.61504,
73:-0.18912, 74: 1.00716, 75:-0.79308, 76:-0.15443, 77: 0.23474, 78: 0.13072, 79:-0.47380, 80:-0.11197,
81:-0.64447, 82: 0.68786, 83: 0.96080, 84: 0.03798, 85: 0.21055, 86:-0.43419, 87: 0.09763, 88: 0.73378,
89: 0.90781, 90:-0.59992, 91: 0.20657, 92:-0.64392

94      1: 0.88432, 2: 0.22187, 3:-0.67378, 4: 0.96171, 5:-0.08234, 6:-0.70750, 7:-0.87606, 8: 0.81853,
9: 0.02225, 10: 0.27236, 11:-0.50107, 12:-0.47541, 13:-0.51715, 14: 0.66740, 15:-0.35840, 16: 0.40043,
17: 0.81332, 18: 0.74114, 19: 0.48393, 20: 0.45698, 21:-0.27128, 22: 0.61251, 23:-0.66187, 24:-0.55147,
25:-0.02108, 26:-0.43225, 27: 0.20255, 28: 0.75140, 29: 0.56938, 30: 0.08724, 31: 0.93628, 32:-1.04737,
33: 0.34797, 34:-0.95044, 35:-0.37454, 36:-0.29998, 37:-0.92397, 38:-0.45857, 39: 0.24732, 40: 0.09919,
41: 0.60300, 42:-0.34051, 43:-0.35447, 44: 0.41665, 45:-0.69532, 46: 0.80007, 47: 0.16847, 48: 0.83978,
49: 0.81743, 50: 0.70690, 51:-0.70663, 52: 0.75567, 53:-0.90649, 54: 0.51592, 55:-0.03598, 56: 0.55272,
57: 0.27726, 58: 0.26579, 59: 0.30998, 60: 0.61308, 61:-0.51042, 62:-0.73518, 63:-0.74033, 64:-0.11009,
65: 0.74203, 66: 0.50458, 67: 0.00322, 68:-0.35254, 69:-0.52947, 70: 0.56124, 71: 0.09596, 72: 0.50919,
73:-0.44825, 74: 0.26931, 75: 0.94089, 76: 0.01234, 77: 0.07835, 78: 0.94788, 79: 0.81882, 80: 0.16391,
81: 0.54612, 82: 0.12067, 83:-0.13098, 84: 0.29971, 85:-0.43111, 86:-1.15711, 87: 0.50875, 88: 0.39793,
89:-0.31476, 90: 0.62050, 91:-0.28107, 92: 0.97423

95      1:-0.00204, 2: 0.07127, 3:-0.93085, 4:-0.75330, 5:-0.68333, 6: 0.19300, 7:-0.93836, 8:-0.74543,
9: 0.03329, 10:-0.93664, 11:-0.47557, 12: 0.28959, 13: 0.94537, 14: 0.36884, 15: 0.65287, 16:-0.77529,
17:-0.18597, 18: 0.62140, 19: 0.40929, 20:-0.22741, 21: 0.92829, 22: 0.42698, 23: 0.28241, 24: 0.00674,
25:-0.37429, 26:-0.19777, 27:-0.27949, 28: 1.04474, 29:-0.29561, 30:-0.26632, 31:-0.02091, 32:-0.76357,
33: 0.57310, 34: 0.22684, 35: 0.85485, 36:-0.33689, 37: 0.13480, 38:-0.51644, 39: 0.71070, 40:-0.36075,
41:-0.38376, 42: 0.75671, 43:-0.17276, 44:-0.88347, 45:-0.86424, 46:-0.31584, 47: 0.48977, 48: 0.46205,
49:-0.52375, 50:-0.84467, 51: 0.06577, 52:-0.05955, 53:-0.41475, 54: 0.42987, 55:-0.40570, 56:-0.17729,
57: 0.46476, 58:-0.48329, 59: 0.96350, 60: 0.08532, 61: 0.60691, 62:-0.31061, 63: 0.66321, 64:-0.58164,

```

65:-0.42744, 66:-0.49213, 67:-0.12133, 68: 0.31969, 69: 0.91570, 70:-0.68854, 71:-0.61508, 72:-0.70033, 73: 0.26562, 74: 0.82368, 75:-0.45261, 76: 0.27210, 77: 0.17579, 78: 0.61647, 79: 0.97919, 80: 1.07508, 81:-0.67126, 82:-0.25987, 83:-0.17252, 84: 0.71763, 85:-0.24469, 86: 0.68246, 87:-1.04921, 88: 0.71943, 89: 0.39716, 90: 0.87970, 91: 0.12570, 92: 0.25468

96 1:-0.61443, 2:-0.46520, 3:-0.66991, 4: 0.40717, 5:-0.27274, 6: 0.76723, 7:-0.41398, 8: 0.46426, 9:-0.34866, 10:-0.54904, 11:-0.51504, 12:-0.48864, 13: 0.55583, 14:-0.23921, 15: 0.84360, 16:-0.29684, 17:-0.97646, 18:-0.08026, 19:-0.16461, 20:-0.76197, 21: 0.22068, 22:-0.61451, 23:-0.26658, 24:-0.08482, 25:-0.67893, 26: 0.61622, 27: 0.39974, 28: 0.23675, 29:-0.20204, 30: 0.26323, 31:-0.24451, 32: 0.87374, 33: 0.27434, 34:-0.93605, 35: 0.57737, 36:-0.10591, 37: 0.07341, 38:-0.49117, 39: 0.99080, 40: 0.07811, 41: 0.43024, 42:-0.38759, 43:-0.76910, 44: 0.04323, 45:-0.33369, 46: 0.05154, 47: 0.30794, 48: 0.75008, 49: 0.35253, 50: 0.62145, 51: 0.11643, 52:-0.96678, 53: 0.24089, 54: 0.86897, 55: 0.58716, 56:-0.16267, 57:-0.78723, 58: 0.65311, 59: 0.69978, 60: 0.68763, 61: 0.85707, 62:-0.02476, 63:-0.79681, 64: 0.58491, 65: 0.43014, 66: 0.02012, 67: 0.47469, 68: 0.38382, 69:-0.66778, 70:-0.18995, 71: 0.54253, 72:-0.66385, 73:-0.43576, 74:-0.80617, 75:-0.00083, 76:-0.87910, 77: 0.59848, 78:-0.38713, 79:-0.83914, 80:-0.64850, 81:-0.71867, 82:-0.74019, 83:-0.92606, 84: 0.03847, 85: 0.26737, 86: 0.31914, 87:-1.07604, 88: 0.77552, 89: 0.71179, 90:-0.19851, 91:-0.80672, 92:-0.76529

97 1:-0.51415, 2:-0.99045, 3: 0.25651, 4:-0.51026, 5: 0.44222, 6:-0.86736, 7:-0.08572, 8: 0.03575, 9:-0.11399, 10:-0.31541, 11: 0.33726, 12:-0.87231, 13:-0.55271, 14:-0.57715, 15: 0.59893, 16: 0.81836, 17: 0.02776, 18:-0.93882, 19: 0.98324, 20: 0.31126, 21:-0.34827, 22: 0.02669, 23:-0.04423, 24: 0.41079, 25:-0.71047, 26: 0.38662, 27: 0.64903, 28: 0.92590, 29: 0.49109, 30:-0.32015, 31:-0.16952, 32: 0.45063, 33:-0.59903, 34: 0.30219, 35:-0.35287, 36: 0.21733, 37:-0.31740, 38:-0.97399, 39:-0.49618, 40: 0.56225, 41:-0.64379, 42:-0.96571, 43:-0.31273, 44:-0.12565, 45: 0.63286, 46:-0.13059, 47:-0.11371, 48:-0.99941, 49:-0.32320, 50: 0.91749, 51:-0.29444, 52: 0.29026, 53:-0.35304, 54:-0.19205, 55:-0.19051, 56:-0.45317, 57: 0.65827, 58: 0.33809, 59:-0.69472, 60: 0.34784, 61: 0.07618, 62:-0.11222, 63:-0.47771, 64: 0.76027, 65:-0.34537, 66:-0.72538, 67:-0.31309, 68: 0.19146, 69: 0.42135, 70:-0.04006, 71:-0.45124, 72:-0.66097, 73: 0.24547, 74: 0.09319, 75:-0.60854, 76: 0.19444, 77: 0.28398, 78: 0.56379, 79: 1.10012, 80:-0.22913, 81: 0.60907, 82: 0.57514, 83:-0.14530, 84: 0.78923, 85:-0.61432, 86: 0.28434, 87: 1.10718, 88:-0.71517, 89: 0.89109, 90: 0.37591, 91: 1.00335, 92: 0.01730

98 1:-0.20266, 2: 0.78511, 3: 0.37353, 4:-0.28769, 5:-0.28114, 6:-0.41934, 7:-0.04709, 8: 0.07938, 9:-0.40631, 10:-0.20992, 11: 0.28125, 12:-0.98067, 13:-0.12958, 14: 0.26138, 15:-1.03222, 16: 0.01502, 17: 0.02148, 18:-0.21923, 19: 0.50703, 20:-0.40232, 21: 0.25350, 22:-0.68967, 23:-0.76197, 24:-0.43030, 25: 0.52727, 26: 0.48185, 27:-0.65739, 28:-0.32110, 29: 0.53289, 30:-1.03857, 31: 0.51612, 32: 0.53683, 33: 0.56374, 34: 0.15442, 35:-0.78774, 36:-0.37170, 37:-0.71199, 38:-0.09007, 39: 0.91435, 40:-0.50002, 41: 0.49730, 42:-0.19326, 43:-0.52801, 44:-0.19058, 45: 0.90837, 46: 0.58194, 47: 0.76496, 48: 0.12658, 49:-0.28646, 50: 0.84335, 51:-0.46096, 52:-0.08753, 53:-0.12133, 54:-0.40414, 55:-0.89039, 56: 0.94117, 57:-0.52912, 58: 0.01545, 59: 0.70247, 60: 0.24108, 61:-0.61964, 62: 0.38606, 63: 0.00965, 64: 0.49164, 65:-0.45934, 66:-0.83227, 67: 0.83948, 68:-0.83032, 69:-0.72045, 70:-0.46352, 71:-0.13539, 72:-0.26430, 73:-0.58019, 74:-0.75672, 75:-0.55062, 76: 0.97732, 77: 0.05466, 78: 0.44426, 79:-0.61858, 80: 0.54524, 81:-0.61159, 82: 0.64501, 83: 0.33669, 84:-0.65467, 85: 0.08986, 86:-0.51127, 87:-0.53474, 88: 0.20800, 89: 0.71460, 90: 0.58328, 91:-0.48549, 92: 0.75139

99 1:-0.57061, 2:-0.79906, 3: 0.06563, 4: 0.18602, 5: 1.12096, 6:-0.03816, 7: 1.07144, 8:-0.28264, 9:-0.39961, 10:-0.33443, 11:-0.09477, 12:-0.00223, 13:-0.30973, 14: 0.53060, 15:-0.92465, 16:-0.34083, 17:-0.44286, 18:-0.94324, 19: 0.50706, 20:-0.42984, 21: 0.62207, 22:-0.52061, 23: 0.38470, 24: 1.13404, 25:-0.16237, 26:-0.18496, 27: 0.09143, 28:-0.37984, 29: 0.57845, 30: 0.36150, 31: 1.06206, 32:-1.04244, 33: 0.97982, 34: 0.01886, 35: 0.39939, 36: 0.57482, 37:-0.75182, 38:-0.26210, 39:-0.76937, 40: 0.72501, 41: 0.22956, 42:-0.30456, 43:-0.77580, 44: 0.66185, 45:-0.45936, 46: 0.68746, 47:-0.25856, 48:-0.99760, 49: 1.13690, 50:-0.10261, 51: 0.07966, 52: 0.24608, 53:-0.93367, 54: 0.50682, 55: 0.15165, 56:-0.70818, 57:-0.78338, 58:-0.29734, 59:-0.96609, 60: 0.83078, 61:-0.59839, 62:-0.01419, 63: 0.45461, 64: 0.79421, 65:-0.42594, 66: 0.07710, 67: 0.62223, 68:-1.09480, 69: 0.16269, 70: 0.75392, 71:-0.15913, 72:-0.67426, 73:-0.50048, 74:-1.03546, 75:-0.39558, 76: 0.06802, 77:-0.12856, 78: 0.59672, 79:-0.59249, 80:-0.88795, 81: 0.30924, 82: 0.88084, 83:-0.61936, 84:-0.51620, 85: 0.86620, 86:-0.21799, 87: 0.58107, 88:-0.16391, 89:-0.14904, 90:-0.82236, 91:-0.07594, 92: 0.65630

100 1: 0.66253, 2: 0.97308, 3: 0.33476, 4: 0.81044, 5:-0.55207, 6:-0.83480, 7: 0.38868, 8: 0.41337, 9: 0.69628, 10: 0.76653, 11: 0.19358, 12: 0.10300, 13:-0.10419, 14: 0.34026, 15:-1.04502, 16: 0.64688, 17: 0.13663, 18:-0.99475, 19: 0.29781, 20:-0.00176, 21:-0.92636, 22: 0.12425, 23:-0.33548, 24: 0.51063, 25: 0.59788, 26: 0.08627, 27: 0.20113, 28: 0.47968, 29:-0.40383, 30:-0.58075, 31: 0.92289, 32:-0.52103, 33:-0.29823, 34: 0.02264, 35: 0.37300, 36:-0.38100, 37:-0.65719, 38: 0.75814, 39:-0.69247, 40: 0.81713, 41: 0.19957, 42: 0.43136, 43: 0.24925, 44:-0.92765, 45: 0.93084, 46: 0.20065, 47:-0.66468, 48:-0.02536, 49: 0.26644, 50: 0.65984, 51: 0.24401, 52: 0.77151, 53: 0.84867, 54:-0.68548, 55:-0.56688, 56: 0.08243, 57: 0.08011, 58: 0.63939, 59:-0.49872, 60:-0.61208, 61: 0.11310, 62: 0.46189, 63: 0.87700, 64: 0.28430,

65:-0.95519, 66:-0.50098, 67:-0.43533, 68:-0.79861, 69: 0.21927, 70: 0.37383, 71:-0.02562, 72: 0.54892,
 73:-0.38203, 74: 0.63888, 75: 0.31572, 76:-0.30080, 77:-0.69340, 78:-0.04906, 79: 0.98729, 80:-0.06322,
 81:-0.02076, 82:-0.91098, 83: 0.89409, 84: 0.11864, 85:-0.48458, 86: 0.04136, 87:-0.18745, 88: 0.08615,
 89: 0.64897, 90: 0.73234, 91:-0.33391, 92:-0.46661

101 1: 0.55687, 2:-0.91347, 3:-0.18027, 4:-1.00475, 5:-0.99945, 6: 0.51648, 7:-0.32254, 8: 0.96641,
 9:-0.45019, 10:-0.35813, 11: 0.23490, 12:-0.96558, 13:-0.77947, 14: 0.48674, 15: 0.16953, 16:-0.70246,
 17: 0.66080, 18:-0.06201, 19:-0.03337, 20:-0.56149, 21: 1.08439, 22: 0.82550, 23: 0.09604, 24: 0.27410,
 25:-0.49760, 26: 0.22253, 27:-0.09280, 28: 0.52667, 29:-0.61896, 30: 0.02976, 31:-0.17572, 32:-0.05566,
 33: 0.18230, 34: 1.06233, 35:-0.83445, 36:-0.49939, 37: 0.33811, 38:-0.49458, 39: 0.11877, 40: 1.02362,
 41: 0.28678, 42: 0.61302, 43:-1.02401, 44: 0.49518, 45: 0.27157, 46:-0.65519, 47:-0.40482, 48: 0.58276,
 49: 0.44631, 50: 0.99652, 51:-0.81656, 52: 0.26998, 53: 0.33576, 54:-0.14208, 55: 0.24620, 56:-0.63391,
 57:-0.64572, 58: 0.64500, 59:-0.80976, 60:-0.17948, 61: 0.44615, 62:-0.36123, 63: 0.81953, 64:-0.35966,
 65:-0.51840, 66: 0.82827, 67:-0.82954, 68:-0.00240, 69:-0.65717, 70: 0.20614, 71:-0.46001, 72: 0.87038,
 73: 0.77728, 74: 0.01209, 75:-0.45811, 76:-0.19061, 77:-0.15055, 78:-0.42534, 79:-0.72412, 80: 0.11008,
 81:-0.38580, 82:-0.63564, 83:-0.70783, 84: 0.25045, 85:-0.01384, 86:-0.92905, 87: 0.38974, 88: 0.07517,
 89: 0.20895, 90: 0.63882, 91:-0.60382, 92:-0.52238

102 1: 0.34306, 2:-0.15898, 3:-0.47984, 4:-0.53171, 5:-0.31738, 6: 0.27451, 7: 0.69236, 8:-0.11538,
 9:-0.10161, 10:-0.86309, 11:-0.40983, 12:-0.86908, 13: 0.09368, 14:-0.54772, 15:-0.25177, 16:-0.99066,
 17: 0.36691, 18: 0.88371, 19:-0.71150, 20:-0.24747, 21:-0.84168, 22: 0.38957, 23:-0.40887, 24:-0.01506,
 25:-0.80259, 26:-0.06828, 27:-0.96344, 28:-0.60148, 29:-0.31340, 30: 0.73909, 31: 0.35776, 32: 0.65653,
 33: 0.50064, 34: 0.47081, 35:-0.54361, 36: 0.57014, 37: 0.12579, 38: 0.61711, 39: 0.16467, 40: 0.81847,
 41:-0.84064, 42:-0.20096, 43:-0.95476, 44: 0.20099, 45: 0.48948, 46:-0.13419, 47:-0.08705, 48:-0.91442,
 49:-0.34254, 50: 0.44659, 51:-0.22279, 52: 0.80829, 53:-0.14954, 54: 0.12325, 55: 0.12958, 56:-0.99574,
 57: 0.22958, 58:-0.21343, 59:-0.32234, 60: 0.15219, 61:-0.15923, 62: 0.21129, 63: 0.07536, 64:-0.63242,
 65: 0.50919, 66:-0.60047, 67: 0.53452, 68:-0.44349, 69:-0.57898, 70: 0.60049, 71:-0.38647, 72: 0.01961,
 73: 0.53882, 74:-0.95317, 75: 0.89950, 76: 0.01588, 77: 0.56707, 78:-0.64557, 79: 0.39639, 80:-0.95937,
 81: 0.35260, 82: 0.51787, 83: 0.99684, 84:-0.79395, 85:-0.19395, 86:-0.70270, 87: 0.23253, 88:-0.44435,
 89:-0.68858, 90:-0.43551, 91:-0.69698, 92:-0.55263

 93:-2.20319, 94: 0.62656, 95: 0.61421, 96: 0.40586, 97:-1.57704, 98:-1.14876, 99: 2.52496, 100:-
 0.01271,

103 101: 2.84665, 102:-0.11891

 93: 1.93167, 94:-1.29221, 95:-0.03119, 96:-0.32125, 97: 1.68633, 98: 1.51583, 99:-2.26546, 100:-
 0.22069,

104 101:-2.75866, 102: 0.17767

 layer definition section

:

layer	unitNo.
2	93, 94, 95, 96, 97, 98, 99, 100, 101, 102
3	103, 104

IV. Selecção dos Dados

Conceito	Atributo	Atributo_reduzido	Taxonomic Class	PF%	Shared
alface	é verde	verde	Basic Level	76,00	6,17
alface	tem folhas	folhas	Basic Level	56,00	6,82
alface	é um vegetal	vegetal	Basic Level	48,00	6,91
alface	usada em salada	salada	Basic Level	44,00	5,33
alface	é um alimento	alimento	Basic Level	32,00	6,92
alface	é saudável	saudavel	Basic Level	28,00	6,27
alface	é um acompanhamento	acompanhamento	Basic Level	24,00	4,82
alface	serve para comer	come-se	Basic Level	24,00	6,58
alface	tem sabor agradável	saboroso	Basic Level	24,00	4,83
alface	vem da terra	terra	Basic Level	24,00	6,27
alface	é cultivada	cultivado	Basic Level	20,00	6,42
alface	usada em sopa	sopa	Basic Level	12,00	3,75
alface	tem vitaminas	vitaminas	Basic Level	12,00	6,18
alfarroba	é um vegetal	vegetal	Basic Level	37,50	6,00
alfarroba	é um alimento	alimento	Basic Level	29,17	6,36
alfarroba	é um fruto	fruto	Basic Level	20,83	5,00
alfarroba	pode ser castanha	castanho	Basic Level	16,67	4,42
alfarroba	é comprida	comprido	Basic Level	16,67	5,36
cão	tem patas	patas	Basic Level	79,17	6,75
cão	tem pêlo	pelo	Basic Level	70,83	6,92
cão	tem 4 patas	pernas_4	Basic Level	70,83	6,58
cão	tem olfacto apurado	olfacto	Basic Level	33,33	6,45
cão	faz companhia	companhia	Basic Level	29,17	5,64
cão	é um animal	animal	Basic Level	25,00	6,91
cão	é um mamífero	mamifero	Basic Level	25,00	7,00
cão	tem focinho	focinho	Basic Level	16,67	7,00
cão	tem várias cores	varias_cores	Basic Level	12,50	5,58
cão	existem várias raças	varios_tipos	Basic Level	12,50	6,82
cobra	pode ser venenosa	venenoso	Basic Level	83,33	4,83
cobra	pode rastejar	rasteja	Basic Level	62,50	6,55
cobra	é comprida	comprido	Basic Level	45,83	5,00
cobra	é um réptil	reptil	Basic Level	45,83	6,92
cobra	é um animal	animal	Basic Level	37,50	6,83
cobra	tem escamas	escamas	Basic Level	33,33	6,17
cobra	não tem patas	nao_patas	Basic Level	33,33	6,83
cobra	tem várias cores	varias_cores	Basic Level	33,33	5,82
cobra	move-se	move-se	Basic Level	16,67	6,50
cobra	põe ovos	ovos	Basic Level	16,67	6,75
cobra	pode ser castanha	castanho	Basic Level	12,50	4,55

cobra	é um ser vivo	ser_vivo	Basic Level	12,50	6,73
cobra	existem vários tamanhos	varios_tamanhos	Basic Level	12,50	6,42
cobra	é verde	verde	Basic Level	12,50	3,45
computador	é útil	util	Basic Level	28,00	6,45
computador	tem várias cores	varias_cores	Basic Level	24,00	6,45
computador	tem botões	botoes	Basic Level	12,00	6,45
escopro	é uma ferramenta	ferramenta	Basic Level	25,00	6,40
escopro	é feito de metal	metal	Basic Level	12,50	4,25
frigorífico	conserva alimentos	conserva_alimentos	Basic Level	75,00	6,67
frigorífico	é um electrodoméstico	electrodomestico	Basic Level	41,67	6,83
frigorífico	pode ser branco	branco	Basic Level	37,50	4,82
frigorífico	é eléctrica	electrico	Basic Level	33,33	6,75
frigorífico	há na cozinha	cozinha	Basic Level	29,17	5,75
frigorífico	é grande	grande	Basic Level	29,17	4,17
frigorífico	tem várias cores	varias_cores	Basic Level	20,83	4,50
frigorífico	gasta energia	energia	Basic Level	12,50	6,45
ginja	é um fruto	fruto	Basic Level	62,50	6,64
ginja	é vermelha	vermelho	Basic Level	37,50	5,92
ginja	é doce	doce	Basic Level	29,17	4,67
ginja	é pequeno	pequeno	Basic Level	16,67	5,83
ginja	é redondo	redondo	Basic Level	16,67	6,18
ginja	tem sabor agradável	saboroso	Basic Level	16,67	4,33
maçã	é um fruto	fruto	Basic Level	76,00	7,00
maçã	é vermelha	vermelho	Basic Level	56,00	4,55
maçã	é saborosa	saboroso	Basic Level	52,00	5,00
maçã	é verde	verde	Basic Level	48,00	4,17
maçã	é amarela	amarela	Basic Level	44,00	3,91
maçã	é doce	doce	Basic Level	36,00	5,18
maçã	pode ser amarga	amargo	Basic Level	32,00	3,42
maçã	tem caroços	caroco	Basic Level	32,00	6,25
maçã	cheira bem	cheira_bem	Basic Level	32,00	5,17
maçã	come-se	come-se	Basic Level	32,00	6,50
maçã	é redonda	redondo	Basic Level	32,00	5,27
maçã	tem sumo	sumo	Basic Level	28,00	6,25
maçã	é um alimento	alimento	Basic Level	24,00	6,83
maçã	nasce em árvore	arvore	Basic Level	24,00	6,82
maçã	tem casca	casca	Basic Level	24,00	6,75
maçã	tem várias cores	varias_cores	Basic Level	20,00	5,75
maçã	tem vitaminas	vitaminas	Basic Level	16,00	6,58
maçã	é pequena	pequeno	Basic Level	12,00	4,17
maçã	existem várias qualidades	varios_tipos	Basic Level	12,00	6,73

martelo	é feito de metal	metal	Basic Level	56,00	5,64
martelo	é uma ferramenta	ferramenta	Basic Level	52,00	7,00
martelo	é pesado	pesado	Basic Level	48,00	5,00
martelo	usado na construção civil	constr_civil	Basic Level	32,00	5,50
martelo	é útil	util	Basic Level	20,00	5,00
martelo	é perigoso	perigoso	Basic Level	16,00	3,75
martelo	é barulhento	barulhento	Basic Level	12,00	5,50
misturadora	é eléctrica	electrico	Basic Level	52,00	6,09
misturadora	é um electrodoméstico	electrodomestico	Basic Level	36,00	5,50
misturadora	tem lâminas	laminas	Basic Level	36,00	5,75
misturadora	é barulhenta	barulhento	Basic Level	24,00	4,75
misturadora	pode fazer batidos	batidos	Basic Level	24,00	5,55
misturadora	é pequeno	pequeno	Basic Level	24,00	4,50
misturadora	é útil	util	Basic Level	20,00	5,92
misturadora	tem botões	botoes	Basic Level	16,00	6,08
misturadora	é uma máquina	maquina	Basic Level	16,00	6,67
misturadora	tem várias cores	varias_cores	Basic Level	16,00	5,18
misturadora	há na cozinha	cozinha	Basic Level	12,00	4,92
misturadora	é grande	grande	Basic Level	12,00	4,33
mosca	tem asas	asas	Basic Level	87,50	7,00
mosca	é pequeno	pequeno	Basic Level	54,17	5,92
mosca	voa	voa	Basic Level	50,00	6,45
mosca	é preta	preto	Basic Level	45,83	5,75
mosca	é irritante	irritante	Basic Level	37,50	6,08
mosca	tem patas	patas	Basic Level	33,33	7,00
mosca	é um animal	animal	Basic Level	25,00	6,09
mosca	é nojenta	nojento	Basic Level	25,00	5,33
mosca	serve de alimento	alimento	Basic Level	16,67	4,50
mosca	põe ovos	ovos	Basic Level	12,50	5,83
rebarbadora	é barulhenta	barulhento	Basic Level	25,00	5,33
rebarbadora	é uma ferramenta	ferramenta	Basic Level	20,83	6,00
rebarbadora	é eléctrica	electrico	Basic Level	16,67	6,33
rebarbadora	usado na construção civil	constr_civil	Basic Level	12,50	6,17
rebarbadora	tem lâminas afiadas	laminas	Basic Level	12,50	5,45
rebarbadora	é feita de metal	metal	Basic Level	12,50	6,18
rosa	é uma flor	flor	Basic Level	83,33	5,73
rosa	cheira bem	cheira_bem	Basic Level	79,17	5,64
rosa	tem várias cores	varias_cores	Basic Level	58,33	6,50
rosa	é decorativa	decorar	Basic Level	41,67	5,33
rosa	usada como oferta	oferta	Basic Level	41,67	5,25
rosa	é vermelha	vermelho	Basic Level	41,67	3,83

rosa	pode ser branca	branco	Basic Level	33,33	4,75
rosa	é amarela	amarela	Basic Level	25,00	3,55
rosa	tem folhas	folhas	Basic Level	25,00	6,92
rosa	tem caule	caule	Basic Level	20,83	6,83
rosa	pica	pica	Basic Level	12,50	5,92
rosmaninho	cheira bem	cheira_bem	Basic Level	80,00	5,75
rosmaninho	usada em cozinhados	cozinhado	Basic Level	64,00	4,91
rosmaninho	é uma planta	planta	Basic Level	40,00	6,50
rosmaninho	tem flores	flor	Basic Level	32,00	4,08
rosmaninho	é verde	verde	Basic Level	32,00	5,08
rosmaninho	é castanho	castanho	Basic Level	16,00	4,18
rosmaninho	serve para decoração	decorar	Basic Level	16,00	3,64
rosmaninho	tem folhas	folhas	Basic Level	16,00	6,36
toupeira	é um animal	animal	Basic Level	44,00	7,00
toupeira	tem pêlo	pelo	Basic Level	32,00	5,67
toupeira	pode ser castanha	castanho	Basic Level	28,00	5,42
toupeira	é um mamífero	mamifero	Basic Level	28,00	6,75
toupeira	tem 4 patas	pernas_4	Basic Level	28,00	6,25
toupeira	tem focinho	focinho	Basic Level	24,00	6,83
toupeira	é pequena	pequeno	Basic Level	24,00	5,64
toupeira	tem olfacto apurado	olfacto	Basic Level	20,00	6,42
toupeira	é feia	feio	Basic Level	12,00	4,18
tritão	é um animal	animal	Basic Level	32,00	6,67
tritão	tem cauda	cauda	Basic Level	24,00	5,55
tritão	tem patas	patas	Basic Level	16,00	6,18
tritão	tem 4 patas	pernas_4	Basic Level	16,00	5,70
tritão	tem pele viscosa	viscoso	Basic Level	16,00	6,25
tritão	é escamoso	escamas	Basic Level	12,00	4,67
tritão	é pequeno	pequeno	Basic Level	12,00	5,64
tritão	é um réptil	reptil	Basic Level	12,00	6,50
Animal	tem patas	patas	Superordinate	36,96	5,91
Animal	é ser vivo	ser_vivo	Superordinate	34,78	6,60
Animal	pode ter pelo	pelo	Superordinate	30,43	4,82
Animal	pdt quatro patas	pernas_4	Superordinate	26,09	4,40
Animal	serve para fazer companhia	companhia	Superordinate	21,74	4,09
Animal	pode mover-se	move-se	Superordinate	21,74	6,30
Animal	tem escamas	escamas	Superordinate	19,57	3,55
Animal	é grande	grande	Superordinate	17,39	3,90
Animal	muita variedade/diversidade	varios_tipos	Superordinate	17,39	5,20
Animal	pode ter pelos	pelos	Superordinate	15,22	4,73
Animal	pds pequeno	pequeno	Superordinate	15,22	4,10
Animal	voa	voa	Superordinate	15,22	4,18

Animal	é bonito	bonito	Superordinate	13,04	4,90
Animal	pode ser mamífero	mamifero	Superordinate	13,04	5,00
Electrodoméstico	encontra-se na cozinha	cozinha	Superordinate	32,56	4,50
Electrodoméstico	encontra-se em casas	casas	Superordinate	30,23	5,40
Electrodoméstico	é útil	util	Superordinate	30,23	6,20
Electrodoméstico	é grande	grande	Superordinate	25,58	4,00
Electrodoméstico	pds branco	branco	Superordinate	23,26	4,36
Electrodoméstico	compra-se em lojas	lojas	Superordinate	23,26	5,70
Electrodoméstico	é uma máquina	maquina	Superordinate	23,26	6,33
Electrodoméstico	pd conservar os nossos alimentos	conserva_alimentos	Superordinate	16,28	4,09
Electrodoméstico	tem várias funções	varias_funcoes	Superordinate	16,28	5,73
Electrodoméstico	pds pequeno	pequeno	Superordinate	13,95	3,55
Electrodoméstico	realizam tarefas domésticas	realizar_tarefa	Superordinate	13,95	5,45
Electrodoméstico	faz barulho	barulhento	Superordinate	11,63	4,64
Electrodoméstico	é eléctrico	electrico	Superordinate	11,63	6,40
Electrodoméstico	existem vários tipos	varios_tipos	Superordinate	11,63	6,30
Ferramenta	é de metal	metal	Superordinate	20,93	4,90
Ferramenta	usada para obras de construção	constr_civil	Superordinate	18,60	4,64
Ferramenta	pds pesada	pesado	Superordinate	18,60	4,09
Ferramenta	é útil	util	Superordinate	18,60	5,80
Ferramenta	compra-se em lojas	lojas	Superordinate	13,95	5,10
Ferramenta	auxilia execução de diferentes tarefas	auxilia_tarefas	Superordinate	11,63	5,80
Ferramenta	pds pequeno	pequeno	Superordinate	11,63	4,27
Ferramenta	existem vários tipos	varios_tipos	Superordinate	11,63	6,64
Fruto	pd vir das árvores	arvore	Superordinate	51,16	5,91
Fruto	serve para comer	come-se	Superordinate	46,51	5,80
Fruto	é saboroso	saboroso	Superordinate	41,86	5,36
Fruto	pds doce	doce	Superordinate	37,21	5,20
Fruto	tem cheiro	cheiro	Superordinate	32,56	5,50
Fruto	várias cores	varias_cores	Superordinate	30,23	5,50
Fruto	é saudável	saudavel	Superordinate	27,91	6,20
Fruto	cheira bem	cheira_bem	Superordinate	16,28	4,82
Fruto	pds amargo	amargo	Superordinate	13,95	3,18
Fruto	pdt caroço	caroco	Superordinate	13,95	5,90
Fruto	compra-se em lojas	lojas	Superordinate	13,95	4,27
Fruto	pd vir de plantas	planta	Superordinate	13,95	4,82
Fruto	é um alimento	alimento	Superordinate	11,63	6,82
Fruto	pdt casca	casca	Superordinate	11,63	6,00
Fruto	compra-se no mercado	mercado	Superordinate	11,63	4,09

Fruto	tem sumo	sumo	Superordinate	11,63	5,60
Fruto	várias formas	varias_formas	Superordinate	11,63	5,40
Fruto	pdt diferentes tamanhos	varios_tamanhos	Superordinate	11,63	6,20
Fruto	tem vitaminas	vitaminas	Superordinate	11,63	5,90
Insecto	tem asas	asas	Superordinate	62,79	4,91
Insecto	pds pequeno	pequeno	Superordinate	60,47	5,27
Insecto	voa	voa	Superordinate	37,21	5,45
Insecto	animal	animal	Superordinate	32,56	6,40
Insecto	tem patas	patas	Superordinate	32,56	5,55
Insecto	incomodativo/irritante	irritante	Superordinate	30,23	4,20
Insecto	pd picar	pica	Superordinate	20,93	4,91
Insecto	serve de alimento para outros animais	alimento	Superordinate	11,63	4,64
Insecto	faz barulho	barulhento	Superordinate	11,63	5,00
Insecto	é feio	feio	Superordinate	11,63	4,50
Insecto	preto	preto	Superordinate	11,63	4,09
Legume	serve para comer	come-se	Superordinate	76,60	5,70
Legume	é verde	verde	Superordinate	70,21	3,82
Legume	é saudável	saudavel	Superordinate	36,17	6,09
Legume	pd fazer-se sopa com eles	sopa	Superordinate	29,79	5,40
Legume	é uma planta	planta	Superordinate	23,40	5,82
Legume	tem vitaminas	vitaminas	Superordinate	23,40	5,80
Legume	várias cores	varias_cores	Superordinate	21,28	4,60
Legume	acompanhamento na refeição	acompanhamento	Superordinate	19,15	5,36
Legume	é cultivado	cultivado	Superordinate	19,15	6,45
Legume	pd servir para fazer saladas	salada	Superordinate	14,89	4,60
Legume	vem da terra	terra	Superordinate	14,89	6,30
Legume	várias formas	varias_formas	Superordinate	14,89	5,40
Legume	tem folhas	folhas	Superordinate	12,77	5,50
Legume	pds cozinhado	cozinhado	Superordinate	10,64	5,00
Legume	pd vir das estufas	estufas	Superordinate	10,64	3,90
Legume	compra-se no mercado	mercado	Superordinate	10,64	4,64
Legume	é saboroso	saboroso	Superordinate	10,64	5,09
Legume	há vermelhos	vermelho	Superordinate	10,64	2,82
Mamífero	animal	animal	Superordinate	39,53	6,50
Mamífero	pode ter pelos	pelos	Superordinate	32,56	5,55
Mamífero	pode ter pelo	pelo	Superordinate	25,58	5,45
Mamífero	vive em terra	vive_terra	Superordinate	25,58	5,18
Mamífero	é grande	grande	Superordinate	20,93	3,90
Mamífero	tem patas	patas	Superordinate	16,28	5,64

Mamífero	pds pequeno	pequeno	Superordinate	13,95	4,45
Mamífero	pd viver na água	vive_agua	Superordinate	13,95	3,36
Mamífero	é ser vivo	ser_vivo	Superordinate	11,63	6,40
Máquina	tem várias funções	varias_funcoes	Superordinate	26,09	5,60
Máquina	auxilia o homem em várias tarefas	auxilia_tarefas	Superordinate	23,91	6,00
Máquina	faz barulho	barulhento	Superordinate	23,91	5,00
Máquina	é de metal	metal	Superordinate	21,74	5,09
Máquina	necessita de energia	energia	Superordinate	19,57	6,40
Máquina	pdt botões	botoes	Superordinate	15,22	5,50
Máquina	é eléctrico	electrico	Superordinate	15,22	5,73
Máquina	é grande	grande	Superordinate	13,04	4,27
Máquina	encontra-se em casas	casas	Superordinate	10,87	3,91
Máquina	funciona para realizar uma tarefa	realizar_tarefa	Superordinate	10,87	6,10
Máquina	é útil	util	Superordinate	10,87	5,64
Planta	é verde	verde	Superordinate	71,74	5,36
Planta	tem folhas	folhas	Superordinate	50,00	6,00
Planta	pdt flores	flor	Superordinate	36,96	4,10
Planta	é bonito	bonito	Superordinate	26,09	5,36
Planta	serve para decorar	decorar	Superordinate	26,09	3,40
Planta	pdt caule	caule	Superordinate	23,91	5,30
Planta	pdt cheiro	cheiro	Superordinate	23,91	4,90
Planta	serve para comer	come-se	Superordinate	23,91	4,60
Planta	é ser vivo	ser_vivo	Superordinate	19,57	7,00
Planta	cheira bem	cheira_bem	Superordinate	17,39	4,18
Planta	pd oferecer-se	oferta	Superordinate	17,39	4,36
Planta	muita variedade/diversidade	varios_tipos	Superordinate	13,04	6,00
Planta	encontra-se em casas	casas	Superordinate	10,87	3,45
Planta	pd vir das estufas	estufas	Superordinate	10,87	4,40
Planta	é grande	grande	Superordinate	10,87	3,55
Planta	pds pequeno	pequeno	Superordinate	10,87	3,90
Planta	várias cores	varias_cores	Superordinate	10,87	5,50
Réptil	tem escamas	escamas	Superordinate	63,04	4,18
Réptil	é verde	verde	Superordinate	52,17	4,60
Réptil	rasteja	rasteja	Superordinate	32,61	5,18
Réptil	tem patas	patas	Superordinate	26,09	4,45
Réptil	animal	animal	Superordinate	23,91	6,10
Réptil	perigoso	perigoso	Superordinate	19,57	4,20
Réptil	põe ovos	ovos	Superordinate	17,39	6,00
Réptil	repugnante	nojento	Superordinate	17,39	3,55
Réptil	viscoso	viscoso	Superordinate	17,39	4,45
Réptil	pd viver na água	vive_agua	Superordinate	17,39	4,80

Réptil	vive em terra	vive_terra	Superordinate	17,39	4,55
Réptil	pdt cauda	cauda	Superordinate	15,22	4,60
Réptil	pd não ter patas	nao_patas	Superordinate	15,22	4,40
Réptil	venenoso	venenoso	Superordinate	13,04	3,45
Réptil	pdt quatro patas	pernas_4	Superordinate	10,87	3,60