

Mestrado em Engenharia Informática  
Dissertação/Estágio

# RANs – Modelo Computacional de Cognição, Personalidade e Emoção

Leandro André Cepeda Freitas Barroso  
lafb@student.dei.uc.pt

Orientador:  
Alexandre Miguel Pinto

Data: 1 de Julho de 2014



**FCTUC** DEPARTAMENTO  
**DE ENGENHARIA INFORMÁTICA**  
FACULDADE DE CIÊNCIAS E TECNOLOGIA  
UNIVERSIDADE DE COIMBRA



# Resumo

A prevalência de doenças mentais é uma preocupação crescente a nível mundial, e em particular, nos países industrializados. Uma das contribuições para a minoração desse problema tem sido a ciência cognitiva, responsável pelo estudo da mente e seus processos. Os modelos computacionais desenvolvidos têm-se revelado fundamentais na compreensão e estudo de vários fenómenos cognitivos e potenciais auxiliares na prevenção, diagnóstico e tratamento de patologias mentais.

Nesta tese propomos dar um primeiro passo na formalização e construção do modelo cognitivo *Regulated Activation Networks* (RANs) que ambiciona vir a representar computacionalmente fenómenos como personalidade, memória e emoção. Este passo consiste na formalização de uma versão reduzida do modelo, consistindo numa camada de nós de carácter conexionista. Testamos as suas propriedades e aplicação na modelação de alguns fenómenos cognitivos, incluindo o da criatividade. Apresentamos também uma ferramenta de software de suporte à experimentação e expansão do modelo que desenvolvemos.

**Palavras-chave** ciência cognitiva, modelo computacional, redes neuronais, fenómenos cognitivos, criatividade

# Agradecimentos

Gostaria de agradecer, em primeiro lugar, à minha família por todo o apoio e pela oportunidade que me deram de aqui chegar.

Em segundo lugar, a todos os meus amigos e colegas que, de diferentes formas, contribuíram para me ajudar neste caminho.

Por último, gostaria de agradecer ao meu orientador, o Professor Alexandre Pinto, pela sua constante dedicação e inspiração para este projecto.

# Índice

<b>1. Introdução.....</b>	<b>1</b>
1.1. Contextualização do Trabalho .....	1
1.2. Caracterização do Problema.....	1
1.3. Motivação.....	2
1.3.1. Desafios a ultrapassar .....	2
1.4. Características e Qualidade Globais do Modelo .....	3
1.4.1. Características Científicas.....	4
1.4.2. Características Tecnológicas .....	4
1.5. Estrutura do Documento .....	5
<b>2. Estado da Arte e Trabalho Relacionado.....</b>	<b>7</b>
2.1. Estado da Arte.....	7
2.1.1. Modelos cognitivos .....	7
2.1.2. Arquitecturas Cognitivas .....	11
2.1.3. Criatividade Computacional .....	17
2.1.4. Conceptual Spaces.....	18
2.2. Trabalho Relacionado.....	20
2.2.1. Hopfield Network .....	20
2.2.2. Spiking Neural Networks .....	21
<b>3. Objectivos.....</b>	<b>23</b>
3.1. Requisitos do Modelo.....	23
3.1.1. Fenómenos a Modelar.....	23
3.1.2. Características estruturais do modelo .....	26
3.1.3. Características inovadoras .....	29
3.2. Requisitos da Aplicação .....	30
3.2.1. Diagramas de Use-Case.....	30
3.2.2. Análise de Requisitos.....	31
<b>4. Arquitectura da versão uni-camada do modelo RANs .....</b>	<b>35</b>
4.1. Topologia da Rede.....	35
4.2. Propriedades de um nó.....	35
4.3. Injecção de Activação .....	35
4.4. Aprendizagem.....	39
4.5. Propagação da Activação.....	46
<b>5. Experimentação e Resultados .....</b>	<b>49</b>
5.1. Análise dos Dados de Entrada.....	49

5.2.	Comportamento Geral do Modelo .....	51
5.3.	Fenómenos Psicológicos .....	55
5.3.1.	Priming.....	56
5.3.2.	Paradigma Deese-Roediger-McDermott.....	67
5.4.	Use-Case de Criatividade .....	76
5.4.1.	Avaliação dos Resultados .....	78
<b>6.</b>	<b>Implementação do Modelo e Aplicação.....</b>	<b>83</b>
6.1.	Arquitectura do Sistema .....	83
6.2.	Implementação do Modelo.....	85
6.3.	User Interface.....	92
6.3.1.	Menu.....	92
6.3.2.	Configuração do Modelo.....	92
6.3.3.	Parametrização de <i>Inputs</i> .....	94
6.3.4.	Execução de Simulação.....	97
6.3.5.	Visualização de Resultados.....	98
<b>7.</b>	<b>Conclusões e Trabalho Futuro.....</b>	<b>100</b>
	<b>Referências .....</b>	<b>101</b>

# Lista de Figuras

Figura 1 - Diagrama de Use-cases. Encontram-se na figura todas as interacções que o utilizador poderá ter com o sistema.....	31
Figura 2 - Conexões positivas frequencistas. Distribuição dos pesos das ligações positivas.....	44
Figura 3 - Influências excitatórias e inibitórias frequencistas. Distribuição dos pesos das ligações positivas.....	45
Figura 4 - Influências excitatórias e inibitórias frequencistas. Distribuição dos pesos das ligações negativas .....	46
Figura 5 - Injecção de Activação Ponderada.....	52
Figura 6 - Injecção de Activação com Solipsismo Dinâmico.....	52
Figura 7 - Injecção de Activação com Solipsismo Dinâmico.....	53
Figura 8 - Convergência das activações para um ponto fixo .....	54
Figura 9 - Aplicação de <i>thresholds</i> .....	54
Figura 10- Procedimento para Priming perceptual no mesmo nó.....	57
Figura 11 - Priming. Solipsismo = 0.1, Intensidade do estímulo = 0.75, Intervalo entre estímulos = 1 .....	58
Figura 12 - Priming. Solipsismo = 0.9, Intensidade do estímulo = 0.75, Intervalo entre estímulos = 1 .....	58
Figura 13 - Priming. Solipsismo = 0.1, Intensidade do estímulo = 0.75, Intervalo entre estímulos = 2.....	59
Figura 14 - Priming. Solipsismo = 0.9, Intensidade do estímulo = 0.75, Intervalo entre estímulos = 2.....	59
Figura 15 - Procedimento para Priming conceptual .....	60
Figura 16 - Priming. Solipsismo = 0.5, Intensidade do estímulo = 0.75, Peso = 1, Intervalo entre estímulos = 2.....	62
Figura 17 - Máxima DUR obtida. Solipsismo = 0.9, Intensidade do estímulo = 1, Peso = 1, Intervalo entre estímulos = 1 .....	63
Figura 18 - Máxima INT obtida. Solipsismo = 0.1, Intensidade do estímulo = 0.25, Peso = 1, Intervalo entre estímulos = 1 .....	63
Figura 19 - Procedimento para Priming perceptual e conceptual .....	64
Figura 20 - Solipsismo = 0.9, Intensidade do estímulo = 0.75, Peso = 1, Intervalo entre estímulos = 1 .....	65
Figura 21 - Solipsismo = 0.9, Intensidade do estímulo = 0.75, Peso = 1, Intervalo entre estímulos = 8.....	66
Figura 22 - Solipsismo = 0.1, Intensidade do estímulo = 0.75, Peso = 1, Intervalo entre estímulos = 1.....	66
Figura 23 - Solipsismo = 0.1, Intensidade do estímulo = 0.75, Peso = 1, Intervalo entre estímulos = 8.....	67
Figura 24 - Procedimento para Paradigma Deese-Roediger-McDermott.....	68
Figura 25 - Medição média de INT em função do intervalo entre estímulos e número de nós origem.....	70
Figura 26 - DRM. Solipsismo = 0.1, Intensidade do estímulo = 0.75, Pesos = 1, Intervalo entre estímulos = 0, Número de nós origem = 5 .....	70
Figura 27 - Medição média de INT em função do intervalo entre estímulos e número de nós origem.....	71

Figura 28 - Medição média de INT em função do intervalo entre estímulos e número de nós origem.....	72
Figura 29 - Solipsismo = 0.9, Intensidade do estímulo = 0.75, Pesos = 1, Intervalo entre estímulos = 0, Número de nós origem = 10.....	73
Figura 30 - Solipsismo = 0.9, Intensidade do estímulo = 1, Pesos = 1, Intervalo entre estímulos = 0, Número de nós origem = 10.....	73
Figura 31 - Solipsismo = 0.9, Intensidade do estímulo = 0.75, Pesos = 1, Intervalo entre estímulos = 1, Número de nós origem = 10.....	74
Figura 32 - Solipsismo = 0.9, Intensidade do estímulo = 0.75, Pesos = 1, Intervalo entre estímulos = 2, Número de nós origem = 10.....	74
Figura 33 - Processo de Criatividade. Selecção do primeiro ingrediente.....	77
Figura 34 - Processo de Criatividade. Selecção dos ingredientes seguintes .....	78
Figura 35 - Soma das distâncias para centróide em função do número de clusters .....	80
Figura 36 - Arquitectura do Sistema .....	83
Figura 37 - Formato de um ficheiro de input .....	85
Figura 38 - UML: Diagrama de Classes.....	86
Figura 39 - UML: Diagrama de Actividade. Procedimento de uma simulação .....	89
Figura 40 - UML: Diagrama de Sequência. Interacção do utilizador com GUI .....	90
Figura 41 - UML: Diagrama de Sequência. Processo de uma Simulação .....	91
Figura 42 - GUI: Menu de escolha de painéis.....	92
Figura 43 - GUI: Painel de Parametrização do modelo.....	93
Figura 44 - GUI: Painel de Grid-Search.....	94
Figura 45 - GUI: Painel de Parametrização de Inputs.....	95
Figura 46 - GUI: Painel de Visualização de Padrões .....	96
Figura 47 - GUI: Adição de um padrão .....	96
Figura 48 - GUI: Adição de um padrão com repetições.....	97
Figura 49 - GUI: Painel de Execução de Simulação .....	97
Figura 50 - GUI: Painel de Execução de Simulação de Criatividade .....	98
Figura 51 - GUI: Painel de Visualização de Resultados.....	99



# Lista de Tabelas

Tabela 1 - Requisitos da Aplicação .....	33
Tabela 2 - Activation Correlation Simétrica: alterações aos pesos .....	40
Tabela 3 - Activation Correlation Assimétrica: alterações aos pesos .....	41
Tabela 7 - Dados de Entrada. Ingredientes mais frequentes.....	50
Tabela 8 - Dados de entrada. Pares de ingredientes mais frequentes.....	51
Tabela 9 - Medição média de INT em função do ritmo de reposição e factor de solipsismo.....	57
Tabela 10 - Medição média de DUR em função do ritmo de reposição e factor de solipsismo.....	57
Tabela 11 - Medição média de INT em função do intervalo entre estímulos e factor de solipsismo .....	60
Tabela 12 - Medição média de DUR em função do intervalo entre estímulos e factor de solipsismo .....	61
Tabela 13 - Medição média de INT em função dos pesos .....	62
Tabela 14 - Medição média de INT e DUR em função do factor de solipsismo .....	64
Tabela 15 - Medição média de INT em função do intervalo entre estímulos e factor de solipsismo .....	65
Tabela 16 - Medição média de INT em função do ritmo de reposição e factor de solipsismo.....	68
Tabela 17 - Medição média de DUR em função do ritmo de reposição e factor de solipsismo.....	68
Tabela 18 - Medição média de INT em função do intervalo entre estímulos e número de nós origem.....	69
Tabela 19 - Medição média de INT em função do intervalo entre estímulos e número de nós origem.....	71
Tabela 20 - Medição média de INT em função do intervalo entre estímulos e número de nós origem.....	72
Tabela 22 - Medição média de INT e DUR em função do intervalo em que se situa a média dos pesos .....	75
Tabela 23 - Medição da Novidade Média e Desvio Padrão em função do número de ingredientes seleccionados .....	81

# 1. Introdução

Este projecto realiza-se no âmbito da Dissertação de Mestrado em Engenharia Informática da Faculdade de Ciências e Tecnologia da Universidade de Coimbra. Decorre em consonância com o projecto europeu FP7-ICT 611733 ConCreTe, sob a orientação do Professor Doutor Alexandre Miguel Pinto.

## 1.1. Contextualização do Trabalho

Anualmente, mais de um terço da população europeia sofre de uma doença mental (H.U. Wittchen, 2011). A nível mundial, os números são também preocupantes e em crescimento, sendo que a Organização Mundial de Saúde prevê que em 2030 a depressão seja a doença mais comum do planeta (Organization, 2011).

Também em Portugal a situação é preocupante, sendo um dos países europeus com a maior taxa de incidência deste tipo de doenças (Almeida, et al., 2012).

Esta é uma das razões para que a ciência cognitiva tenha evoluído significativamente e ganho importância nas últimas décadas, resultando da convergência de várias disciplinas como a filosofia, psicologia, neurociência, linguística e inteligência artificial. O seu principal objectivo é o estudo da mente e dos seus processos, especialmente na representação, processamento e transformação de informação e em capacidades como percepção, memória, raciocínio e emoção.

Mais especificamente, a modelação cognitiva e os modelos computacionais têm-se revelado ferramentas indispensáveis no estudo do comportamento humano (Fum, et al., 2007), pois disponibilizam a especificidade dos algoritmos, ou seja, conjuntos de passos bem definidos e detalhados, precisão e clareza conceptual. Espera-se que este tipo de ferramentas possa auxiliar na prevenção, diagnóstico e tratamento das patologias mentais referidas.

Este tipo de modelos cognitivos e respectivas ferramentas computacionais, pela natureza dos fenómenos que capturam, têm também potencial para simular e permitir estudar estados e processos mentais como, por exemplo, os associados à criatividade (Kyaga, et al., 2013). Neste contexto, este projecto integra-se no projecto europeu de investigação FP7 - ConCreTe, cujo principal objectivo é o estudo da criatividade em humanos e máquinas.

## 1.2. Caracterização do Problema

Tendo em conta o contexto referido, o problema de investigação mais alargado que se propõe resolver a longo prazo é o do desenvolvimento de um modelo cognitivo, capaz de representar computacionalmente fenómenos como a percepção, atenção, memória, personalidade humana que se traduzem em comportamentos, decisões ou acções. Enquadrado pelo contexto do projecto ConCreTe, o principal sub-problema que este trabalho de Mestrado endereça é o do desenvolvimento de uma primeira versão reduzida do referido modelo cognitivo, sendo esta aplicada na modelação de alguns fenómenos cognitivos e num *use-case* de simulação de fenómenos criativos.

Inspirado por vários factos conhecidos da neuroanatomia humana, bem como de vários modelos cognitivos computacionais, pretendemos desenvolver um modelo de carácter conexionista onde a semântica da rede, e de cada nó, é definida pelo utilizador, permitindo a modelação de diferentes processos cognitivos e a utilização de diferentes significados e níveis de abstracção.

O nosso modelo incluirá ainda um mecanismo de regulação que contribuirá para a modelação de emoções. Desta forma, por se tratar de um modelo conexionista com regulação de activação dos nós, o modelo é denominado “Regulated Activation Networks (RANs)”.

## 1.1. Motivação

A motivação para o desenvolvimento deste modelo pode dividir-se em duas aspirações fundamentais.

A primeira é que este venha a ter potenciais aplicações no auxílio ao diagnóstico e tratamento de patologias mentais, tais como autismo, esquizofrenia ou depressão. Tal poderá ser possível se, uma vez identificados os padrões de parâmetros que permitem simular processos mentais saudáveis e patológicos, se usar o modelo para aprender os valores dos seus parâmetros de forma a imitar as respostas de um utilizador/paciente. A segunda é que possa também dar um contributo na compreensão de fenómenos cognitivos como os sonhos, a criatividade e a expressão das emoções.

Existem já alguns resultados de outros investigadores (O'Reilly, 2006) (Rolls, et al., 2008) (Braver, et al., 1999) que mostram que este tipo de objectivo, embora ambicioso, não está fora do alcance da modelação cognitiva computacional.

Como tal, espera-se que o modelo possa vir a beneficiar tanto a população em geral, que padece destas patologias, como a comunidade científica no campo da modelação cognitiva.

É importante salientar que o trabalho a desenvolver no âmbito desta tese de Mestrado constitui apenas um primeiro passo na direcção do conjunto de objectivos enunciado, sendo este apenas atingível a muito longo-prazo.

### 1.2.1. Desafios a ultrapassar

A criação deste modelo com sucesso, bem como do seu protótipo, envolverá a superação de um conjunto de desafios.

No que diz respeito à construção do modelo formal da rede, às suas características e comportamento, pretende-se que o modelo da rede seja construído de forma a:

1. Permitir propagação de activação com diferentes valores. O cálculo do valor da activação dependerá do seu valor actual e da activação que recebe de outros nós modulada pelos pesos associados às ligações. A propagação de activação deve permitir a modelação de fenómenos como a inibição lateral (este fenómeno encontra-se descrito na secção 3.1.1.4).
2. Exibir comportamento não trivial na propagação de activação - pretende-se que os padrões de carga dos nós na rede possam estabilizar, seja num ponto fixo ou num ciclo limite, na ausência da injeção de activação na rede. Porém, quando

for injectada carga na rede pretende-se que essa injeção funcione como um desestabilizador da rede, conduzindo à passagem por vários novos estados, até eventualmente voltar a estabilizar.

3. Permitir a entrada de novas activações - isto significa receber novos *inputs* durante o processo de simulação, simulando, por exemplo, percepções sensoriais.
4. Permitir a regulação da propagação de activação - alguns nós poderão influenciar positiva ou negativamente uma ou mais ligações entre dois nós através de um coeficiente de regulação, exacerbando ou estrangulando essas ligações. Também será possível regular outros factores como, por exemplo, o ritmo de aprendizagem de uma ligação.

Tendo a regulação um papel essencial no funcionamento do cérebro, por exemplo, no controlo das emoções (Watt, 2004), este tipo de componentes regulatórios permitirá simular fenómenos complexos e de elevado nível cognitivo. Por exemplo, a existência da regulação pode provocar a instabilidade permanente numa rede que não recebe activação o que permite simular alguns tipos de patologias.

5. Permitir a exibição de padrões de activação novos - a exibição de novos padrões de activação, ou seja, o atingir de novos estados (suficientemente diferentes dos percebidos anteriormente) autonomamente por parte da rede será uma possível forma de simular criatividade.
6. Ter compatibilidade com resultados estabelecidos em outras áreas tais como neurologia, psiquiatria, e psicologia, sempre que seja possível.

Ao nível do comportamento criativo que se pretende atingir, encontram-se vários desafios, dos quais se destacam os seguintes:

1. A definição do próprio processo criativo - ou seja, o método através do qual a rede será capaz de demonstrar criatividade.
2. A avaliação dos resultados - quer essa avaliação seja feita pela rede, pelo utilizador, ou por ambos, os critérios a considerar para definir os outputs da rede como criativos é também um elemento desafiante.

Ao nível da implementação do protótipo encontram-se algumas questões práticas que podem influenciar o sucesso da experimentação tais como:

1. A escalabilidade do protótipo
2. A facilidade de configuração da rede por parte do utilizador
3. A disponibilização e visualização de informação útil sobre o processo e os resultados.

### 1.3. Características e Qualidade Globais do Modelo

### 1.3.1. Características Científicas

Do ponto de vista científico, sendo que pretendemos construir um modelo capaz de modelar determinados fenómenos cognitivos, tomamos como ponto de partida alguns fundamentos da psicologia e neurologia. Na subsecção 3.1.1 descrevemos em detalhe quais os fenómenos que se pretendeu modelar, e na subsecção 3.1.2 quais as características do modelo que possibilitam essa modelação.

Também como resultados de base, usamos algumas propriedades de diversos trabalhos da área da inteligência artificial e da ciência cognitiva. Na secção 2.1 revemos alguns modelos e arquiteturas cognitivas e na secção 2.2 outros trabalhos relacionados que são igualmente uma inspiração para o nosso modelo. Em ambas descrevemos de que forma estes trabalhos inspiram ou se assemelham ao nosso modelo das RANs, e de que forma contribuem para a modelação dos fenómenos.

É importante, nesta fase, salientar também um princípio fundamental na construção do modelo. No âmbito desta tese de Mestrado, a versão do modelo a desenvolver conterá apenas uma camada de nós. Posteriormente, o modelo das RANs evoluirá para uma versão multi-camada, em que uma camada de nível superior representará um maior nível de abstracção.

Assim, começaremos nesta fase com uma abordagem essencialmente conexionista, que posteriormente evoluirá, com a expansão do modelo, para uma abordagem híbrida, i.e., a criação de novas camadas levará a uma maior estruturação da informação, conduzindo a representações mais abstractas, e eventualmente simbólicas. Desta forma, as opções tomadas nesta fase terão em conta este facto.

A abordagem conexionista na primeira camada do modelo permitirá a captura de aspectos cognitivos como a variação contínua das activações, o que seria impossível de realizar com outras abordagens.

Como metodologia de trabalho, realizámos e documentamos vários testes que incluíram a experimentação de diferentes parâmetros e configurações da rede. Esta metodologia foi e continuará a ser incremental, na medida em que se pretende construir o modelo passo a passo através do teste e validação dos seus vários componentes, parâmetros e capacidades. Após a análise crítica ao desempenho e comportamento da rede nas várias experiências, foi seleccionada uma configuração para ser aplicada no *use-case* de fenómenos criativos.

### 1.3.2. Características Tecnológicas

A nível tecnológico o que se pretende desenvolver é uma aplicação com a implementação do modelo, que permita a realização de simulações parametrizáveis.

Dado este pressuposto, em conjunto com o âmbito maioritariamente científico desta tese de mestrado, não existem aparentes restrições ao nível das ferramentas ou linguagens a utilizar.

Assim, as escolhas tecnológicas tomadas prendem-se sobretudo com a construção de um interface parametrizável para realização das simulações e visualização de resultados e com o poder computacional e memória disponível para execução, sendo de notar que as operações sobre o modelo são essencialmente operações numéricas.

Esta aplicação conterà a implementação do modelo e servirá como ferramenta de teste para o use-case de simulação de fenómenos criativos.

## 1.4. Estrutura do Documento

Após esta introdução, em que abordamos o contexto em que decorre este trabalho, identificamos o problema e aquilo que nos motiva a resolvê-lo, assim como descrevemos as características globais de que pretendemos dotar a nossa solução, descrevemos agora a estrutura do restante documento.

No capítulo 2 revemos o Estado da Arte e Trabalho Relacionado.

A primeira secção (2.1), referente ao *state-of-the-art*, inclui a revisão de três influentes modelos cognitivos (2.1.1), cinco arquitecturas cognitivas (2.1.2), uma pequena introdução ao tema da criatividade computacional (2.1.3) e uma revisão da tese de “conceptual spaces” proposta por Peter Gärdenfors (2.1.4) que se pretende materializar, a longo prazo, com o modelo das RANs.

Na seguinte secção (2.2) revemos outros trabalhos que são uma influência para o nosso modelo, designadamente, as redes de Hopfield (2.2.1), e as Spiking Neural Networks (2.2.2)

O capítulo 3 contém uma descrição mais aprofundada dos objectivos do trabalho, identificando na primeira secção (3.1) os requisitos do modelo, que inclui a descrição dos fenómenos cognitivos que se pretende modelar (3.1.1), das características estruturais do modelo e de que modo estas contribuem para a modelação desses fenómenos (3.1.2) e dos aspectos inovadores que a nossa proposta contém (3.1.3). Na seguinte secção (3.2) apresentamos os requisitos da aplicação a desenvolver e o processo de levantamento dos mesmos, incluindo a elaboração de use-cases (3.2.1), bem como a descrição detalhada dos requisitos funcionais e não funcionais (3.2.2).

No capítulo 4 esses objectivos são concretizados na arquitectura do modelo, em que se descrevem os aspectos relacionados com a topologia do modelo (4.1), as propriedades que caracterizam cada nó (4.2), os vários métodos testados para a injeção da activação (4.3), para a aprendizagem (4.4) e para a propagação da activação (4.5).

O capítulo 5 descreve as experiências efectuadas e resultados obtidos, passando por uma análise introdutória aos dados de entrada usados (5.1), e analisando alguns aspectos gerais do modelo (5.2). O teste de modelação de fenómenos psicológicos é descrito na secção 5.3 em que se testa o fenómeno do *Priming* (5.3.1) e o paradigma Deese-Roediger-McDermott (5.3.2). Por último, testam-se as capacidades da rede na aplicação a processos criativos (5.4).

O capítulo 6 descreve a ferramenta de software desenvolvida, passando pela arquitectura do sistema (6.1), por aspectos concretos da implementação (6.2) e pela demonstração da interface gráfica e respectivas funcionalidades (6.3).

Por fim, no capítulo 7 resumizamos as conclusões obtidas e discutimos os seguintes passos para o desenvolvimento do modelo cognitivo RANs.

## 2. Estado da Arte e Trabalho Relacionado

Na ciência cognitiva, os modelos são frequentemente divididos em modelos computacionais, matemáticos e verbais/conceituais. Dada a importância, já referida, dos modelos computacionais no estudo da cognição humana (Fum, et al., 2007) e a natureza computacional do modelo proposto vamos focar-nos neste tipo de modelos.

Outra importante distinção, nem sempre fácil de fazer, é aquela entre modelos cognitivos e arquiteturas cognitivas. Enquanto os modelos tendem a focar-se num único processo cognitivo, ou na interação entre dois processos cognitivos, as arquiteturas cognitivas são usadas para análises mais alargadas e genéricas dos vários domínios da cognição. Estas fornecem um conjunto de estruturas essenciais, divisão de módulos e suas relações, entre outros aspectos que ajudam a restringir o desenvolvimento de modelos dentro da arquitetura. Deste modo, a própria arquitetura incorpora um conjunto de fundamentos teóricos.

Em conformidade com a multidisciplinariedade da ciência cognitiva, além dos modelos e arquiteturas cognitivas, convém ter em conta outro tipo de contribuições, designadamente da área da inteligência artificial, dada a forte conexão e inspiração nas redes neuronais artificiais para a construção de alguns destes modelos, incluindo o proposto neste projecto.

Na secção 2.1 iremos rever alguns dos mais influentes modelos cognitivos e arquiteturas cognitivas, e na secção 2.2 analisaremos essas outras contribuições.

### 2.1. Estado da Arte

Nesta secção revemos vários trabalhos influentes da ciência cognitiva, designadamente, na secção 2.1.1 alguns modelos cognitivos e na secção 2.1.2 algumas arquiteturas cognitivas. Além desses, incluímos também uma introdução ao tema da criatividade computacional em 2.1.3, dado o use-case de criatividade a que será aplicado o modelo das RANs nesta tese, e ainda uma revisão da tese de “Conceptual Spaces” de Peter Gärdenfors em 2.1.4.

#### 2.1.1. Modelos cognitivos

De seguida, apresentamos uma revisão de três modelos que são uma referência da abordagem conexionista à cognição. Com esta revisão, além de referirmos algumas ideias chave do conexionismo, pretendemos demonstrar o tipo de características do comportamento humano que estes modelos conseguem capturar.

Os primeiros dois modelos são trabalhos de McClelland e Rumelhart e lidam com o efeito do contexto na percepção de letras (2.1.1.1) e com a aprendizagem do pretérito perfeito dos verbos em inglês (2.1.1.2). Em 2.1.1.3 revemos as conhecidas redes recorrentes de Elman.



### 2.1.1.1. Interactive Activation Model of Context Effects in Letter Perception

O modelo Interactive Activation (IA) (McClelland, et al., 1981; McClelland, et al., 1982) pretendeu capturar fenómenos ligados à influência do contexto na percepção visual de letras.

Na altura do seu desenvolvimento, era já sabido que as pessoas eram melhores a reconhecer letras em palavras do que em sequências aleatórias de letras. Para além disso, a influência do contexto é também perceptível em pseudo-palavras pronunciáveis, quando comparadas com sequências aleatórias.

Rumelhart e McClelland construíram então um modelo computacional essencialmente baseado nas seguintes ideias:

- O processamento perceptual ocorre em sistemas com vários níveis de processamento, em que cada um corresponde a um diferente nível de abstracção.
- A percepção visual envolve processamento paralelo dos vários níveis de abstracção e dos vários componentes do objecto (neste caso das várias letras da palavra).

Os vários níveis de processamento referidos traduziram-se neste modelo em três camadas de detectores: características das letras, letras e palavras.

A percepção das letras resulta, então, de interacções excitatórias e inibitórias entre os diferentes detectores, sendo que as diferentes camadas podem influenciar-se mutuamente (*bottom-up* e *top-down*). Dentro da mesma camada, hipóteses mutuamente exclusivas inibem-se uma à outra.

Os estados de activação do sistema foram simulados numa sequência temporal discreta, sendo que a activação de cada unidade é uma combinação da sua activação no instante anterior, as suas influências excitatórias e inibitórias e um factor de decaimento (*decay rate*).

Os pesos das ligações foram fixados manualmente, assim como o estado de activação inicial das palavras foi estabelecido manualmente reflectindo a frequência das mesmas.

O modelo conseguiu capturar a maior precisão de detecção de letras em palavras e pseudo-palavras do que em sequências aleatórias ou letras isoladas. O resultado obtido nas pseudo-palavras (sequência de letras ortograficamente correctas, mas sem significado) pareceu demonstrar que o sistema se comportou como se contivesse regras ortográficas, apesar de estas não lhe terem sido fornecidas.

A conclusão mais importante a retirar deste modelo, é a demonstração de múltiplas influências a trabalhar simultaneamente e em paralelo para a obtenção do resultado do sistema.

O modelo RAN retira alguma inspiração do modelo IA, designadamente no cálculo da activação dos nós em cada instante, cálculo dependente da activação que recebe das suas ligações, da sua activação no instante anterior e de um factor de reposição (no modelo IA chamado *decay rate*). As grandes diferenças com este modelo são a aprendizagem dos pesos, e a regra de propagação da activação, que inclui também um factor de regulação.

### 2.1.1.2. On Learning the Past Tense of English Verbs

Enquanto que o modelo IA usou *localist coding* (cada nó da rede representa explicitamente um conceito) e conexões fixadas manualmente, o modelo de aprendizagem do pretérito perfeito dos verbos em inglês (McClelland, et al., 1986) de Rumelhart e McClelland marcou a real emergência do paradigma conexionista, usando *distributed coding* (os conceitos estão distribuídos na rede) e aprendizagem de pesos através da exposição repetida da rede ao domínio do problema.

A ideia principal por detrás deste modelo é a de que a conformidade com as regularidades da linguagem pode surgir numa rede conexionista sem uma representação explícita das regras linguísticas. Tal fenómeno já se tinha observado no modelo IA, mas será mais explícito neste modelo, que incorpora também padrões de excepção à regra geral.

O objectivo prático da rede era a aprendizagem do pretérito perfeito dos verbos em inglês, caracterizado por uma regularidade predominante de um grupo de verbos em que este tempo verbal é formado pela adição do sufixo "ed" à raiz, e um grupo de verbos que formam o pretérito perfeito de diferentes outras formas.

A rede foi construída usando duas camadas: A primeira contém uma representação distribuída baseada nos fonemas da raiz do verbo, a que chamaram "Wickelfeatures". A segunda contém uma distribuição semelhante do pretérito perfeito do verbo.

As conexões foram inicializadas aleatoriamente, e actualizadas usando a regra-delta no processo de treino.

Dos resultados obtidos pela simulação, destacam-se os seguintes:

- A rede aprendeu os pretéritos perfeitos quer os verbos regulares os dos irregulares, sem que tenha sido feita qualquer referência a essa distinção.
- A rede capturou o padrão evolutivo característico da aprendizagem do pretérito perfeito das crianças, em forma de U, em que se verifica uma rápida aquisição de um pequeno grupo de verbos regulares e irregulares mais

frequentes, seguida de uma fase de excessiva regularização das formas irregulares, e finalmente uma fase de recuperação nas formas irregulares que leva a um desempenho semelhante nos dois tipos.

- A rede foi capaz de generalizar a regra do pretérito perfeito, para uma quantidade substancial de verbos pouco frequentes, para os quais não tinha sido treinada.

A inclusão neste modelo de *distributed coding* e aprendizagem de pesos aproxima-o do modelo RAN. No entanto, quanto à representação da informação o modelo RAN permitirá usar tanto *distributed coding*, que será maioritariamente usado nesta fase do trabalho, como *localist coding* quando o modelo evoluir para uma rede com vários níveis de abstracção.

### 2.1.1.3. Finding Structure in Time

O modelo IA é um bom exemplo da ligação existente entre o conexionismo e o paralelismo, dado o processamento paralelo das várias letras da palavra. Contudo, esse processamento simultâneo de todo o *input* não é possível em muitas situações. Muitos comportamentos humanos estão directamente ligados a sequências temporais, em que o processamento é feito faseadamente e dependente dos instantes anteriores.

O modelo proposto por Elman em 1990 (Elman, 1990) (Elman, 1993), que se tornou extremamente influente e frequentemente usado, propõe lidar com a questão do processamento de sequências.

Conhecido como Elman Network, ou Simple Recurrent Network, este modelo consiste numa rede recorrente, em que uma camada de unidades escondidas, situada entre a camada de *input* e a de *output*, tem acesso ao seu estado anterior, através de uma camada de contexto.

Isto permite moldar o *output* de um instante de acordo não só com o estado da rede naquele momento, mas também com o estado anterior, constituindo assim uma espécie de memória.

Tendo em conta que cada momento é influenciado pelo instante anterior, essa dependência torna-se recursiva, o que significa que cada *input* é processado tendo em conta toda a história de *inputs* anteriores.

Todas as ligações entre as camadas são treinadas usando *backpropagation* (excepto a ligação entre a camada escondida e a camada de contexto, com pesos fixados a 1 para permitir a cópia dos valores).

Elman usou esta rede em várias aplicações, entre elas a previsão de qual a palavra seguinte numa dada frase. Durante o treino, a rede aproximou-se das probabilidades transicionais entre palavras em frases, ou seja, conseguiu prever qual a próxima palavra tanto quanto possível. Isto deveu-se em grande parte à complexidade das representações

internas, que se verificou conterem um misto de informação sintática e semântica, permitindo diferenciar entre nomes e verbos, assim como detectar por exemplo semelhanças entre "mulher" e "rapariga".

Mais tarde, Elman demonstrou outros aspectos como a capacidade da rede em acompanhar dependências de longo alcance, mesmo através da separação de várias frases e de incorporar aspectos como singularidade/pluralidade.

Elman usou também este modelo, para investigar a possível vantagem de usar conjuntos de treino inicialmente pequenos em fenómenos de aprendizagem, capturando com sucesso mudanças de maturação na memória a curto prazo das crianças (o uso de uma janela temporal inicialmente pequena e que cresce gradualmente permite a construção de representações internas mais simples que mais tarde são úteis para a decomposição de frases mais complexas) (Elman, 1993).

O modelo RANs não usará uma camada de contexto como forma para influenciar a resposta da rede de acordo com os instantes passados. Em vez disso, a activação de cada nó num dado instante será uma ponderação da sua activação no instante anterior e da activação recebida dos outros nós. A essa importância que cada nó dá a si mesmo chamamos "factor de solipsismo". Este mecanismo funciona como uma espécie de memória individual de cada nó, o que também acontece com o nível de activação contínuo e que ao longo do tempo se vai repondo para níveis neutros.

## 2.1.2. Arquitecturas Cognitivas

Nesta secção, apresentamos uma revisão de algumas arquitecturas cognitivas. Tendo em conta que existe uma grande variedade neste campo, escolhemos um grupo representativo de cinco arquitecturas, todas cumprindo o requisito de o seu desenvolvimento continuar activo. Devemos também salientar o facto de ser ainda prematuro estabelecer uma comparação directa entre o modelo RANs e estas arquitecturas, dado o elevado grau de desenvolvimento das mesmas. Assim, esta revisão serve como introdução ao tipo de estruturas, organização e capacidades que estas arquitecturas possuem e como referência para o desenvolvimento a longo prazo do modelo RANs.

Inicialmente, revemos três referências de indiscutível importância na modelação cognitiva: em 2.1.2.1 SOAR, em 2.1.2.2 ACT-R e em 2.1.2.3 CLARION. Adicionalmente revemos também, em 2.1.2.4, a arquitectura 4CAPS que tem a característica única de comparar os níveis de actividade dos seus vários módulos com medidas de neuro imagiologia da actividade cerebral e, em 2.1.2.5, a arquitectura DUAL que tem algumas semelhanças interessantes com o modelo das RANs.

### 2.1.2.1. SOAR

O desenvolvimento da arquitectura SOAR (States, Operators and Reasoning) por Newell, Laird e Rosenbloom (Laird, et al., 1987), esteve fortemente ligado às teorias de

Newell, em *Unified Theories of Cognition*, (Newell, 1990) sobre a cognição, servindo como um teste para as mesmas.

De acordo com a definição de inteligência de Newell como a habilidade para usar o conhecimento para atingir objectivos (Newell, 1990), SOAR foi desenhada para usar todo o seu conhecimento em cada problema. Assim sendo, propriedades da cognição humana não directamente relacionadas com o sistema de conhecimento não são centrais para a SOAR (Sun, 2008).

Na SOAR, todas as tarefas são representadas como "espaços de problema", sendo que realizar a tarefa, chamada objectivo principal, é equivalente a chegar a um determinado estado nesse espaço, partindo do estado inicial. Esse caminho é feito através de um conjunto de operadores que permitem a transição entre estados. O conhecimento é então um conjunto de *production rules* que representa o conjunto de esses operadores, as suas consequências e como escolher entre vários operadores quando disponíveis simultaneamente.

No caso de algum conhecimento faltar, evento definido com um impasse, resolver essa falta torna-se o objectivo principal do sistema (e um sub-objectivo do problema original). Quando o impasse é resolvido, o seu resultado é passado ao problema original e é adicionado à base de conhecimento, ou seja, é aprendido, para que o impasse não ocorra de novo, num processo denominado de *chunking*.

A arquitectura SOAR clássica, era assim um pouco limitada, contendo representações puramente simbólicas, em que todo o conhecimento era explícito e contendo apenas uma memória de longo prazo e uma forma de aprendizagem.

Essas limitações foram sendo reconhecidas após a sua aplicação a tarefas complexas (Laird, et al., 2012) e recentemente foram adicionadas novas memórias de longo-prazo (semântica e episódica), novas formas de aprendizagem (aprendizagem semântica para descrever conhecimento mais abstracto, aprendizagem episódica que retém a história da evolução do sistema e *reinforcement learning* para ajustar os valores de preferência dos operadores), assim como mecanismos de representação subsimbólicos e um módulo para modelar os efeitos da emoção no sistema cognitivo (Marinier, et al., 2004). A SOAR actualmente apresenta as suas decisões como sendo feitas através da combinação do conhecimento relevante em *runtime* (Laird, et al., 2012).

A SOAR demonstrou capacidades em linguagem natural, como NL-Soar (Rubinoff, et al., 1994), interpretando frases em inglês e aprendendo novas palavras, assim como na cooperação com outros agentes, como TacAir-Soar (John E. Laird, 1998).

No que refere à validade psicológica da arquitectura, a Soar tem sido comparada com a performance humana, modelando fenómenos como Einstellung Effect (Luchins, 1942), um efeito negativo de uma experiência prévia em que uma pessoa aprende uma maneira de resolver um problema e aplica esta solução para novos problemas, mesmo quando existem soluções mais simples e Power Law of Learning, a redução logarítmica do tempo de reacção na execução de uma tarefa com o aumento do número de tentativas. Este último está fortemente ligado à forma de aprendizagem (*chunking*) da SOAR.

A abordagem simbólica desta arquitectura, o seu comportamento baseado num sistema de produções e a sua forma de aprendizagem distanciam-se bastante do modelo RANs, em que o comportamento surgirá dos padrões de activação emergentes de um conjunto de nós e, nesta fase, seguirá uma abordagem essencialmente conexionista.

Contudo, o modelo RANs completo, a especificar e implementar fora do âmbito deste trabalho de Mestrado, incorporará outro mecanismo de aprendizagem que possibilitará a criação de novos nós o que poderá ser mais facilmente comparável com o mecanismo de *chunking* da SOAR.

### 2.1.2.2. ACT-R

A arquitectura ACT-R (Adaptative Control of Thought - Rational) é uma das arquitecturas mais influentes na modelação cognitiva, originalmente desenvolvida por John Robert Anderson (Anderson, et al., 2004).

Baseia-se em três componentes essenciais: análise racional, distinção entre memória procedimental e declarativa, e na sua estrutura modular.

De acordo com a análise racional, cada componente da arquitectura é optimizado tendo em conta o ambiente em que se insere. Assim, quando há uma escolha entre estratégias a usar, ou entre que elementos da memória utilizar, ACT-R usará aquele que apresentar a maior utilidade, i.e, a escolha com a maior probabilidade esperada de sucesso e com o menor custo. Também nos processos de aprendizagem existe o conceito de optimização, sendo que estes podem tentar diferentes formas de representação até que a óptima seja seleccionada.

Um sistema de produções constitui a memória procedimental e guarda as produções que podem actuar na situação actual, mantendo cada uma um valor de utilidade, isto é, uma medida do seu sucesso passado. Esta representa conhecimento sobre como fazemos certas operações, como realizar uma adição ou conduzir.

A memória declarativa tem a forma de uma rede semântica e representa uma base de conhecimento de factos em que cada elemento (denominados de *chunk* por Anderson, mas diferentes dos *chunks* da SOAR) tem um valor de activação, que aumenta com a frequência da sua utilização e decai com o passar do tempo, o que permite modelar, por exemplo, fenómenos de esquecimento. Além disso, a rede contém pesos associativos entre os elementos que são adquiridos através da experiência. Este comportamento inclui a possibilidade dos elementos espalharem activação com aqueles a que estão ligados (mecanismo de Spreading Activation).

O facto de a arquitectura combinar esta duas formas de memória em que a memória declarativa usa valores de activação e de utilidade e a memória procedimental representações simbólicas, torna ACT-R numa arquitectura híbrida.

A aprendizagem na ACT-R envolve a criação de novos *chunks* através da codificação eventos externos ou da execução de uma produção, e o reforço do valor de activação dos *chunks* consoante o seu uso. A criação de produções está associada a

mecanismos de “procedimentação”, generalização, composição e analogia, em que usualmente a memória declarativa é usada como base para a criação das produções, numa aprendizagem *bottom-up*.

A estrutura modular corresponde a uma divisão entre o sistema de produções (o núcleo da arquitectura) e vários módulos (por exemplo, módulo visual), sendo a comunicação feita através de *buffers*.

O uso de uma rede semântica para a representação da memória declarativa, em conjunto com os mecanismos de Spreading Activation e o decaimento temporal da activação das unidades desta memória é uma característica que se assemelha ao modelo das RANs, sendo que no nosso modelo não existirá uma diferenciação entre tipos de memória.

### 2.1.2.3. CLARION

A arquitectura CLARION (Connectionist Learning with Adaptative Rule Induction Online) (Sun, 2003) (Sun, 2006), cujo desenvolvimento é liderado por Ron Sun, tem como base a distinção entre processos cognitivos explícitos e implícitos.

Essa distinção traduz-se numa divisão estrutural em dois níveis, *top-level* e *bottom-level* que correspondem, respectivamente, à cognição explícita e implícita. Além disso, cada nível está dividido em dois sistemas: *action-centered* e *non-action-centered*, sendo que o primeiro pode influenciar directamente as acções, e o segundo, que mantém conhecimento geral, apenas o pode fazer indirectamente.

Cada subsistema da arquitectura usa as suas próprias representações e mecanismos de aprendizagem. Muitas das representações implícitas são formadas por redes neuronais e a aprendizagem envolve uma combinação de *reinforcement learning* e *backpropagation* para melhorar a percepção de pares estado/acção aos quais associa medidas de qualidade.

O subsistema explícito utiliza este conhecimento adquirido implicitamente como base para construir estruturas simbólicas, numa forma de aprendizagem *bottom-up*. No entanto, também pode ocorrer uma aprendizagem *top-down*, em que a fixação ou pré-codificação de certas regras no *top-level* permite ao *bottom-level* acumular conhecimento guiado por essas mesmas regras.

Dada esta interacção entre diferentes representações pelo que é considerada uma arquitectura híbrida, com uma aproximação ao conexionismo mais forte que ACT-R.

A teoria central de CLARION é a de que o comportamento surge como um resultado da interacção entre os processos explícitos e implícitos, fornecendo assim uma boa forma de estudar estas interacções.

Além dos subsistemas já referidos, existe também o subsistema motivacional, responsável pela manutenção dos objectivos do sistema, e um subsistema meta-cognitivo, responsável pela monitorização e modificação das operações de todos os subsistemas.

A natureza híbrida da arquitectura CLARION, tal como a de ACT-R, permite uma comparação interessante com o que se pretende atingir no modelo RAN a longo prazo. O facto de a aprendizagem ser transformada de um nível aproximado ao conexionismo para o nível simbólico (podendo também ocorrer no sentido inverso) tem algumas semelhanças com a ponte que se pretende construir entre esses dois níveis no modelo RANs. No entanto, no nosso modelo essa transição será feita de uma forma gradual, utilizando várias camadas de nós que, gradualmente, irão adquirindo e estruturando informação, ao invés de usar mecanismos de transformação responsáveis por essa transição abrupta. Este ponto será discutido em detalhe na secção 2.1.4.

No modelo das RANs, os níveis de representação não pretenderão diferenciar entre conhecimento ou processos implícitos ou explícitos como na arquitectura CLARION.

#### 2.1.2.4. 4CAPS

4CAPS (Cortical Capacity-Constrained Concurrent Activation-based Production System) (Just, et al., 2007), desenvolvida por Marcel A. Just e Sashank Varma, é a mais recente versão de uma família de arquitecturas cognitivas, que inclui os seus predecessores CAPS e 3CAPS.

A arquitectura original CAPS (Thibadeau, et al., 1982) foi desenhada com o propósito de modelar o decurso do tempo e o conteúdo de um processo complexo.

O conhecimento procedimental é representado por um sistema de produções, em que cada produção é composta por uma ou mais condições necessárias e a acção consequente.

O conhecimento declarativo consiste em informação proposicional na forma de triplos conceito-relação-conceito, formando uma rede semântica, sendo que cada proposição tem associado um nível de activação numérico.

Em cada ciclo de processamento, todas as produções cujas condições sejam satisfeitas são executadas concorrentemente. A satisfação de uma condição requer a sua presença na *working memory*, com um nível de activação mínimo.

Uma proporção da activação pode ser direccionada por uma produção, de uma proposição para outra, um conceito chamado *directed activation* que contrasta com a distribuição de activação para todos os nós relacionados, e em vários níveis, da *spreading activation*. Também uma proposição pode direccionar activação para si própria, fenómeno usado para explicar a persistência de uma representação mental na ausência de estímulos externos, fenómeno intitulado de *self-activation*.

O seu sucessor, 3CAPS (Just, et al., 1992), adicionou restrições aos recursos existentes para manter e processar representações, o que permitiu a exploração de diferenças entre indivíduos. Nesta versão foram desenvolvidos vários modelos testando a compreensão de frases em adolescentes com diferentes capacidades de memória (Just, et al., 1992), resolução de problemas em adultos com diferenças ao nível da inteligência (Just, et al., 1996) e também comparando pacientes normais com pessoas com lesões no lobo frontal (Goela, et al., 2001), entre outros.



O sucesso desses modelos contribuiu para favorecer o argumento de que o processamento de informação dos humanos envolve mecanismos híbridos num ambiente em que os recursos são limitados.

A versão mais recente, 4CAPS (Just, et al., 2007), baseia-se em quatro assunções fundamentais: cada área cortical pode executar múltiplas funções cognitivas, cada área cortical tem um limite de capacidades computacionais, a rede cortical de regiões responsáveis por executar a tarefa varia dinamicamente de acordo com a saturação dos recursos da região, e a comunicação entre regiões corticais obedece a restrições semelhantes a uma largura de banda.

Desta forma, 4CAPS introduziu uma característica única: a habilidade de comparar a actividade de diferentes módulos da arquitectura com medidas de neuro imagiologia da actividade cerebral, proporcionando resultados mais precisos sobre as consequências comportamentais de lesões corticais.

No que diz respeito a semelhanças com o modelo das RANs, destaca-se a rede semântica usada para o conhecimento declarativo, tal como a existente na arquitectura ACT-R em que as produções podem direccionar activação para outras (diferente do mecanismo nas RANs, que será semelhante ao Spreading Activation) e inclusive para si mesmas, o que também será possível no nosso modelo.

#### 2.1.2.5. DUAL

Proposta por Boicho Konikov (Kokinov, 1994), a arquitectura DUAL é baseada em três ideias principais: *hybridity*, *emergent computation* e *context-sensitivity* (Kokinov, et al., 1996).

Um grande número de simples agentes híbridos não cognitivos, chamados agentes DUAL, forma o sistema, sendo que o comportamento emerge das interacções entre eles. Ou seja, todo o processamento e representação de conhecimento surgem dos padrões organizativos de estes agentes, sem um módulo central que controla o sistema. Este é o princípio da *emergent computation*.

Cada agente divide-se em duas partes: L-Brain e R-Brain, correspondentes ao paradigma simbólico e conexionista, respectivamente. Da perspectiva simbólica, cada agente representa parte ou a totalidade de um conceito, objecto, evento, plano, acção, etc.. Da perspectiva conexionista, cada agente contém um nível de activação, que corresponde à relevância do mesmo para a situação e contexto actual. As ligações entre agentes representam a força da relação associativa entre eles. Esta dualidade torna o sistema híbrido no *micro-level* (em cada agente), sendo que no *macro-level* não existe um módulo híbrido e outro conexionista. Essa influência do contexto no comportamento do sistema representa a terceira ideia fundamental da arquitectura, *context-sensitivity*.

A memória a longo prazo do sistema, é composta por todos os agentes, enquanto a *working memory* consiste no conjunto de agentes activos no momento. Cada agente activo

espalha activação aos seus vizinhos, quando esta é superior a um determinado *threshold*. O conceito de decaimento está também presente, reduzindo exponencialmente a activação de todos os nós de acordo com um *decay rate*. As excepções a este facto são os nós *focus* (nó mais activo), os nós de *input*, e os nós *goal*, que representam o objectivo do sistema.

Vários modelos foram desenvolvidos na arquitectura DUAL, designadamente o modelo AMBR de raciocínio humano, especialmente focado no aspecto de *analogy-making*, um modelo de memória episódica que demonstra a interacção entre a memória e o raciocínio, um modelo de julgamento humano (JUDGEMAP), e um modelo de percepção (PEAN) que expande o modelo AMBR, acrescentando-lhe capacidades perceptuais.

É interessante verificar como esta arquitectura híbrida divide as suas componentes conexionista e simbólica. De novo podemos estabelecer uma comparação com a forma como o modelo RANs abordará a questão dos níveis de representação. Ao invés de utilizar uma separação desses níveis como a efectuada em DUAL, o modelo das RANs pretenderá estabelecer uma transição entre esses dois níveis.

Contudo, esta arquitectura apresenta bastantes semelhanças com a primeira camada do modelo RANs a desenvolver nesta tese de Mestrado. A componente conexionista em que um grande conjunto de unidades interage para dar origem a padrões de comportamento emergentes, sem a actuação de um módulo central que controla as acções é uma característica partilhada entre os dois modelos, assim como a existência de relações associativas entre os elementos e o mecanismo de Spreading Activation accionado quando o nível de activação de um elemento supera um determinado *threshold*.

Apesar de poder haver pequenas distinções no funcionamento dos mecanismos já enunciados, uma grande diferença para com o modelo das RANs será a inclusão no nosso modelo de influências regulatórias entre os nós, para além do diferente modo de aprendizagem característico das RANs.

### 2.1.3. Criatividade Computacional

A criatividade computacional é um subcampo da inteligência artificial e da ciência cognitiva, que tem como objectivos perceber a criatividade humana e desenvolver sistemas computacionais que permitam modelar, simular ou estimular a criatividade humana.

É uma área de investigação que tem registado muito crescimento e actividade desde os anos 90, e que se tem debatido com um conjunto de questões teóricas e filosóficas, especialmente no que diz respeito à definição de criatividade e sistema criativo e à avaliação de um produto ou resultado como criativo.

Porém, enquanto essas questões são debatidas e várias formalizações são propostas, paralelamente a comunidade científica tem desenvolvido diversas implementações de sistemas criativos em variadíssimas áreas, que incluem, entre outras, composição e improvisação musical, arte visual, humor, poesia, geração de histórias, metáforas, analogia, matemática e resolução criativa de problemas.

No contexto do modelo RAN, a modelação de fenómenos criativos é apenas um dos aspectos que se pretende incorporar no modelo, razão pela qual não pretendemos sobrevalorizá-lo em relação aos outros fenómenos que pretendemos modelar, descritos na secção 3.1. Desta forma, sentimos que uma análise do estado da arte da área da criatividade computacional sairia fora do âmbito desta tese.

Para uma descrição da história e do estado actual desta área de investigação recomendamos a leitura de (Cardoso, et al., 2009) e (Colton, et al., 2012). Para uma análise mais detalhada dos fundamentos teóricos e implementações de sistemas criativos ver o capítulo 2 de (Pereira, 2007).

Dada a integração com o projecto ConCreTe, o trabalho desenvolvido nesta tese de mestrado terá como use-case uma situação de criatividade. Assim, será descrito em detalhe na secção 3.1 de que forma o modelo RAN abordará o fenómeno da criatividade.

## 2.1.4. Conceptual Spaces

O problema da representação da informação é um tópico fundamental tanto da inteligência artificial como da ciência cognitiva. O estudo das operações cognitivas humanas e de outros animais e a construção de modelos que permitam simular essas operações ou que apresentem comportamento considerado inteligente estão fortemente ligados ao modo como a informação é representada e processada.

Classicamente, existem duas abordagens para este problema. A abordagem simbólica, em que a informação está representada explicitamente através de símbolos, que quando combinados formam expressões ou proposições que se relacionam logicamente entre elas. Assim, o processamento da informação consiste essencialmente na manipulação de símbolos, não tendo em conta o conteúdo semântico dos mesmos.

A abordagem conexionista consiste na criação de redes neuronais artificiais, i.e, grandes conjuntos de unidades interconectadas, que processam a informação em paralelo, sendo que a informação se encontra distribuída nas várias unidades da rede. Os processos cognitivos são aqui representados, não através da manipulação de símbolos, mas pela observação da dinâmica dos padrões de actividade nas redes.

Peter Gärdenfors argumenta que existem aspectos dos fenómenos cognitivos que nenhuma destas abordagens é capaz de modelar, propondo uma terceira forma de representar informação baseada em estruturas geométricas ao invés de símbolos ou conexões entre neurónios (Gärdenfors, 1997). Contudo, este tipo de representação, a que chama de conceptual, não deve ser vista como concorrente do simbolismo ou conexionismo, mas sim como uma perspectiva ou nível intermédio necessário para explicar como podem representações simbólicas surgir de representações conexionistas. Assim, propõe que as três perspectivas sejam consideradas para explicar fenómenos cognitivos ou construir agentes artificiais.

A necessidade de este nível intermédio decorre de várias limitações do poder representacional das abordagens clássicas. A explosão combinatória que decorreria da formalização de conhecimento necessário para descrever o mundo e o conjunto de possíveis acções num formalismo simbólico é uma das limitações apresentadas. Outra limitação da abordagem simbólica reside no facto de ser necessário dar ao sistema um conjunto de predicados inicial, não sendo possível estudar a sua emergência evolucionária

e não existindo forma de descrever a situação ou o estado do agente antes de esses símbolos existirem. Além disso, sistemas simbólicos dificilmente aprendem novas propriedades através da interacção com o mundo, apenas formando novos predicados através da combinação dos anteriores, e não têm maneira de conhecer a similaridade entre conceitos. Em suma, a abordagem simbólica não permite induções criativas ou descobertas conceptuais, apenas possíveis no nível conexionista, e exige a existência de uma regra que especifique como interpretar uma representação para que se retire conteúdo semântico da mesma.

Contudo, algumas limitações são também apresentadas à abordagem conexionista. Nomeadamente, a dificuldade em mapear a informação demasiado rica e destruturada que as redes neuronais artificiais recebem para um nível conceptual. Apesar de alguns sistemas realizarem já este tipo de redução de dimensionalidade, como as *self-organising networks* de Kohonen (Kohonen, 1982), por vezes mantêm-se a dificuldade em interpretar o que representa o comportamento emergente da rede.

O nível conceptual proposto por Gärdenfors serve, essencialmente, como uma forma de representação intermédia, representando explicitamente conceitos básicos, que servirão de base para os símbolos. Assim, propõe o conceito de espaço conceptual, como forma de estruturar os conceitos em domínios, sendo que tal espaço consiste num número de *quality dimensions* que caracterizam as qualidades do objecto. Como exemplo dessas *quality dimensions* podemos considerar a altura, largura, temperatura, peso, etc...

A estruturação geométrica inicialmente referida advém da natureza geométrica das *quality dimensions*, sendo que estas podem ser unidimensionais ou multidimensionais, e podem tomar formas geométricas, como o tetraedro proposto por Henning (Erickson, 1984) representativo do paladar. Esta localização num espaço permite a definição de similaridade entre dois conceitos o objectos como a distância entre os seus pontos no espaço conceptual.

Assim, o nível conceptual apresenta vantagens ao nível da representação, permitindo o estabelecimento de similaridades entre objectos, sem o demorado processo de treino requerido nas redes neuronais. Além disso, permite a ordenação da informação em domínios e a atribuição de propriedades aos objectos, definidas como regiões do espaço conceptual.

Naquilo que é referido como a abordagem *state space*, se considerarmos a actividade de cada nó de uma rede neuronal artificial com uma dimensão, podemos olhar para essas redes como uma representação multidimensional semelhante à proposta por Gärdenfors, sendo que o problema que surge é do elevado número de dimensões.

No modelo das RANs, iremos seguir essa abordagem, onde cada nó representa uma dimensão de um espaço conceptual e, assim, cada estado de activação da rede representa um ponto no espaço conceptual multidimensional. A propagação de activação na rede faz com que esta, ao longo do tempo, descreva uma trajectória no espaço conceptual.

A evolução do modelo RANs para várias camadas (já fora do âmbito deste trabalho) levará a uma estruturação da informação, o que reduzirá o número de dimensões a considerar nas camadas superiores, e como tal, servirá de ponte entre o nível conexionista e o nível simbólico, tal como o nível conceptual proposto por Gärdenfors.

## 2.2. Trabalho Relacionado

Nesta secção revemos outros trabalhos da área da inteligência artificial que são uma inspiração para o modelo das RANs. Em concreto, revemos as redes de Hopfield (2.2.1), as *Spiking Neural Networks* (2.2.2) e as *Gene Regulatory Networks* (2.2.3).

### 2.2.1. Hopfield Network

A rede de Hopfield, inventada por John Hopfield em 1982, consiste num conjunto de nós interconectados, formando um tipo de rede neuronal recorrente.

As ligações entre um par de nós são caracterizadas por um peso  $w$ , sendo que cada nó não pode estar ligado a si próprio e as ligações são simétricas, ou seja,  $w_{ij} = w_{ji}$ ,  $\forall i, j$ .

Tipicamente, o estado dos nós assume apenas os valores -1 e 1, dependendo se o *input* do nó excede ou não o seu *threshold*. Esse *input* é definido pelo somatório do estado dos nós com que tem uma ligação, multiplicado pelo peso da ligação que os une.

A actualização do valor dos nós pode ser feita assincronamente em que é actualizada uma unidade de cada vez, de acordo com alguma ordem pré-estabelecida ou aleatoriamente, ou sincronamente em que todas as unidades são actualizadas de uma forma simultânea.

Se tivermos em conta a rede no seu global, podemos determinar um valor escalar correspondente ao estado da rede, que é referido com a energia da rede, e calculado através da fórmula:

$$E = -\frac{1}{2} \sum_{i,j} w_{ij} s_i s_j + \sum_i \theta_i s_i$$

onde

- $w_{ij}$  é o peso da ligação entre o nó  $i$  e o nó  $j$
- $s_i$  é o estado do nó  $i$
- $\theta_i$  é o *threshold* do nó  $i$

Considerando uma actualização assíncrona, existem duas possibilidades de actualização para uma unidade: não muda de estado, mantendo-se a energia do sistema, ou muda de estado, diminuindo a energia do sistema. Isto implica, dado o número finito de estados, que a rede atingirá um estado estável, um mínimo local na função de energia.

Esta é uma das propriedades mais interessantes da rede de Hopfield, pois desta forma, a rede pode treinar-se para lembrar padrões. Esse processo envolve o treino da rede através do método de Hebb, em que os pesos das ligações entre dois nós simultaneamente activos são reforçados, e os pesos das ligações entre dois nós activos separadamente são reduzidos.

Assim, os pesos são alterados até que o padrão que pretendemos armazenar seja um mínimo local, o que permite que dado parte desse padrão como *input* à rede, ela possa convergir para o padrão completo, funcionando como uma memória associativa. Porém,

não é garantido que isso venha a acontecer, pois a rede pode convergir para outro mínimo local.

Foi demonstrado que com este processo de treino, uma rede de Hopfield pode armazenar, aproximadamente,  $0.14 * n$  padrões, sendo  $n$  o número de nós da rede (Wei, et al., 2007).

## 2.2.2. Spiking Neural Networks

As *Spiking Neural Networks* (SNN) são redes neuronais de terceira geração, i.e., que tentam replicar o comportamento dos neurónios biológicos.

A primeira geração de redes neuronais, baseada nos neurónios de McCulloch e Pitts (McCulloch, et al., 1943), também referidos como perceptrões ou *threshold-gates*, tem apenas outputs digitais. Ainda assim, por exemplo, uma rede de perceptrões com uma camada escondida pode aproximar qualquer função com um output booleano. Estas redes são chamadas universais para outputs digitais.

A segunda geração é baseada em unidades que aplicam uma função de activação, tipicamente a função sigmoide ou a tangente hiperbólica, transformando os seus *inputs* num valor de output pertencente a um domínio contínuo. As redes *feedforward* são um exemplo típico desta geração, que com uma camada escondida, além de computarem qualquer função booleana usando um *threshold* no *output* da rede, podem também aproximar qualquer função contínua de domínio limitado com *input* e output analógico, tornando-se aproximadores universais.

Interpretando, biologicamente, o comportamento destas unidades, e tendo em conta que um neurónio biológico funciona binariamente, disparando ou não, vemos o output de cada nó, tipicamente entre 0 e 1, como a frequência normalizada de disparo do nó num certo período de tempo. Este tipo de codificação é chamado de *rate coding*. Dado que se sabe que os neurónios biológicos disparam em várias frequências intermédias, entre a sua frequência máxima e mínima, a segunda geração de redes neuronais é biologicamente mais realista do que a primeira.

A terceira geração vem adicionar mais realismo, ao usar picos individuais, incorporando dessa forma informação espaço-temporal na comunicação entre os nós.

Desta forma, as unidades das SNN não disparam em cada ciclo de propagação, mas apenas quando o seu potencial de membrana ultrapassa um determinado valor, dando origem a um sinal que é enviado para outros neurónios. No caso de os sinais recebidos não serem suficientes para esse potencial, que pode ser interpretado como o estado da unidade ou como o seu valor de activação, ultrapassar o valor de *threshold* necessário para disparar, a activação irá sofrer um decaimento ao longo do tempo.

Estas redes permitem, então, outro tipo de codificação, *pulse coding*, que transmite informação num pulso individual e no instante temporal em que ocorre.

Esta hipótese é suportada por estudos neurológicos que revelaram que os humanos analisam e classificam *input* visual em menos de 100ms (Thorpe, et al., 2001). Sendo que desde a retina até ao lobo temporal existem, no mínimo dez passos sinápticos, restam cerca de 10ms de tempo de processamento para cada neurónio. Esta janela temporal é demasiado pequena para uma codificação baseada na média, como nos esquemas de *rate coding*. (Gerstner, et al., 1999)

Isto não significa que *rate coding* não seja usado, mas sugere que quando é necessária rapidez os mecanismos de *pulse coding* são favorecidos. (Thorpe, et al., 2001)

Biologicamente, os sinais são transmitidos de neurónio para neurónio pelas sinapses, e que esta comunicação requer a libertação de neurotransmissores químicos. Dada a complexidade destes fenómenos, e os vários tipos de codificação, vários modelos destas redes têm sido sugeridos ao longo do tempo.

O modelo RAN assemelha-se a estas na medida em que o estado das suas unidades terá um comportamento semelhante, recebendo input das unidades a si associadas, e dessa forma tendo a sua activação aumentada. No caso de essa activação superar um determinado *threshold* essa unidade disparará também, ao que se seguirá um período de decaimento da activação.

Contudo, o modelo RAN é de um nível de abstracção superior, modelando apenas o comportamento de um ponto de vista funcional, sem se preocupar em modelar as interacções químicas e electrofisiológicas.

## 3. Objectivos

### 3.1. Requisitos do Modelo

Nesta secção são detalhados quais os requisitos do modelo, isto é, quais os fenómenos que se pretende que o modelo possa representar; quais as características que se pretende incorporar no modelo; e em que medida esse conjunto de características possibilita a modelação dos fenómenos. Identificam-se também quais dos modelos revistos no estado da arte serviram de inspiração ou têm mecanismos que pretendemos incluir no modelo RAN. Terminamos esta secção com uma sintetização dos aspectos inovadores deste modelo.

#### 3.1.1. Fenómenos a Modelar

Descrevemos de seguida, de forma sucinta, os principais fenómenos cognitivos e emocionais que pretendemos que o modelo RAN venha a ter capacidade de representar e simular.

##### 3.1.1.1. Priming

O *Priming* é um fenómeno em que a resposta a um estímulo é influenciada pela exposição prévia a um estímulo igual ou semelhante. Ocorre de forma inconsciente, não sendo um acesso explícito à memória, mas sim um fenómeno de memória implícita (Jacoby, 1983).

O *priming* pode ocorrer a um nível perceptual em que há uma correspondência dos estímulos ao nível da forma, ou a um nível conceptual, em que os estímulos estão semanticamente relacionados.

Por exemplo, se for apresentada a uma pessoa uma lista de palavras contendo a palavra "*mystery*" e posteriormente lhe for pedido para completar uma palavra com espaços em branco, por exemplo, *\_YS\_E\_Y*, a probabilidade de essa pessoa escolher "*mystery*" é maior do que se a pessoa não tivesse sido estimulada. (Roediger, et al., 1987) Esse estímulo é perceptual, pois envolve a forma da palavra. Esse efeito pode ocorrer mesmo depois de a palavra ser conscientemente esquecida.

Como exemplo de *priming* conceptual, se considerarmos a palavra "*fruit*" esta iria ter efeitos positivos em conceitos relacionados, como "*apple*", i.e., tendo a pessoa presente na sua consciência o conceito "*fruit*" mais rapidamente se lembra ou responde ao conceito "*apple*". (Matsukawa, et al., 2005)

Outras formas de *priming* têm sido sugeridas, tais como *associative priming*, em que as palavras não se relacionam por características semânticas, mas estão frequentemente associadas ou existe uma alta probabilidade de estarem juntas. Outra forma semelhante é o *context priming*, em que o contexto é usado para lidar mais rapidamente com estímulos mais prováveis de ocorrer nesse contexto.

A simulação do fenómeno de *priming* contribuirá para a captura de fenómenos psicológicos de memória implícita, preconceito, viés (*bias*) cognitivo, projecção,



predisposição e contexto cognitivo. O decaimento temporal da intensidade do *priming* poderá ser usado para modelar o retorno a um estado cognitivo neutro.

### 3.1.1.2. Paradigma Deese-Roediger-McDermott

O paradigma Deese-Roediger-McDermott (DRM) é um procedimento iniciado por James Deese, nos anos 50, e estendido por Henry L. Roediger e Kathleen McDermott (*Creating false memories: Remembering words not presented in lists.*, 1995) nos anos 90 que pretende estudar fenómenos de falsa memória e falso reconhecimento.

O processo envolve a leitura de uma lista de palavras a uma pessoa, sendo que todas estão associadas a uma palavra não apresentada. Por exemplo, sendo a palavra associada "*sleep*", a lista contém palavras como *bed*, *rest*, *awake*.

Imediatamente a seguir, é pedido à pessoa que se lembre do número máximo de palavras que conseguiu ou que assinale as palavras que ouviu numa outra lista. Em ambos os casos, a palavra associada e não presente é lembrada tão frequentemente quanto as outras palavras apresentadas na lista. Frequentemente, também uma elevada proporção das pessoas afirma lembrar-se de ter ouvido a palavra, sugerindo a presença de uma falsa memória.

Através da captura do efeito Deese-Roediger-McDermott o modelo das RANs irá simular fenómenos de falsa memória.

### 3.1.1.3. Habituação / Sensibilização

A habituação é o fenómeno em que a resposta a um estímulo diminui após várias exposições a esse mesmo estímulo (Rankin, et al., 2009). A sensibilização é o fenómeno oposto, ou seja, um aumento na resposta ao estímulo repetido.

O processo da habituação é gradual e não definitivo. Isto é, quando passa um período de tempo suficiente entre a exposição aos estímulos a resposta habituada pode recuperar espontaneamente de uma forma parcial ou total.

A habituação pode também ser potenciada. Isto verifica-se quando são repetidas várias fases de recuperação espontânea. Após cada recuperação, a diminuição da resposta para níveis habitados ocorre mais rapidamente. Também um menor intervalo de tempo entre estímulos irá aumentar o ritmo da habituação. Além disso, a exposição continuada a um estímulo cuja habituação já estabilizou, ou seja, cuja resposta não sofre qualquer diminuição poderá ter efeitos conseqüentes como atrasar a recuperação espontânea.

Os conceitos de generalização e discriminação de estímulos estão também associados a este fenómeno. A habituação a um estímulo irá também revelar-se em estímulos semelhantes, e observar-se-á tanto mais quanto maior for o grau de semelhança entre eles. A discriminação de estímulos verifica-se quando é observada habituação em estímulos semelhantes ao habitado, mas não em estímulos diferentes.

A modelação da habituação será efectuada quando forem introduzidos os componentes regulatórios no modelo RANs.

### 3.1.1.4. Inibição Lateral

A inibição lateral é um fenómeno que ocorre ao nível das células, em que uma célula inibe, ou seja, reduz a actividade de uma ou mais células vizinhas (Millodot, 2009). É um fenómeno característico dos neurónios envolvidos em tarefas de processamento de informação sensorial, na visão, na audição e no tacto, sendo útil para aumentar a precisão sensorial por estreitar o perfil espacial do estímulo e provocar um aumento do contraste.

O fenómeno ocorre graças à existência de componentes de inibição nos receptores dos neurónios, componentes usadas para inibir a distribuição de activação na direcção lateral por parte dos neurónios activados de uma maneira mais rápida ou mais forte para os seus vizinhos.

Este fenómeno é modelado através do estabelecimento de ligações inibitórias entre os nós. Quando a activação é propagada através destas ligações, esta contribui para a redução ou a total inibição dos níveis de actividade do nó a que esta se destina.

### 3.1.1.5. Criatividade

Como referido anteriormente, o fenómeno da criatividade é apenas um dos aspectos que se pretende que o modelo das RANs seja capaz de modelar, em conjunto com os outros fenómenos acima referidos, ainda que seja aquele que será aplicado a um use-case, no âmbito desta tese de Mestrado.

Assim sendo, não se pretende que o modelo ou parte dele seja pensado ou construído com o intuito de sobrevalorizar a criatividade. Pelo contrário, a hipótese a testar é a de os fenómenos psicológicos a modelar serem os mecanismos que possibilitam a demonstração de um comportamento criativo.

Esta abordagem é sustentada pelo facto de os processos cognitivos envolvidos nas actividades criativas serem os mesmos que operam em outras áreas da cognição. Por exemplo, as falsas memórias são criadas pelos mesmos processos que afectam a criação de ideias (Smith, et al., 2012).

Também a cognição implícita é há muito considerada como tendo um papel crítico nos processos criativos, sendo que há evidência que processos inconscientes similares ao mecanismo *Spreading Activation* podem ser responsáveis por palpites intuitivos (Bowers, et al., 1995) e os efeitos de *priming* para níveis de activação abaixo de um *threshold*, seguidos de um estímulo relacionado, poderão ser a origem de descobertas ou “experiências aha!” (Seifert, et al., 1994).

Assim, ainda que não exista um conjunto fixo de operações cognitivas para todas as actividades criativas, existem algumas que são frequentemente consideradas na literatura e na investigação na área da criatividade. Uma delas é a combinação de ideias ou conceitos. Este fenómeno refere-se à mistura de dois conceitos que previamente estavam completamente não relacionados ou, no mínimo, pareciam diferentes.

No entanto, será fácil de constatar que nem todos os conceitos criados a partir de este processo se podem considerar criativos. Esta constatação traz-nos à questão de como avaliar a criatividade. Existindo neste campo diversas propostas e formalizações, e contando que no projecto ConCreTe existem esforços dedicados a esta questão, preliminarmente assumimos que esta avaliação será feita tendo em conta os resultados, i.e. não terá em conta o processo de criação, mas apenas os seus produtos, e que estes serão avaliados de acordo com os critérios de novidade e valor.

No que diz respeito à novidade, um resultado será considerado novo através de uma medida de distinção em relação aos conceitos aprendidos pela rede. Por outras palavras, após serem fornecidos à rede determinados conceitos que a rede aprenderá, será feita uma comparação entre aqueles que a rede conhece e aqueles que resultam do processo de criação, sendo avaliado o grau de distinção entre eles.

Outro aspecto importante neste capítulo são as propriedades do conceito criado. Uma simples sobreposição ou soma das propriedades dos conceitos usados para a criação não deve ser considerado criativo, pelo que se espera que a combinação resulte na emergência de um conceito com novas propriedades.

Quanto ao critério do valor, este pretende avaliar a utilidade do resultado criado, e como tal, está dependente do domínio ao qual se aplica o processo de criação. Nesta tese, o modelo das RANs será aplicado a um use-case de criação de combinações de ingredientes para receitas culinárias. Espera-se, então, que após a rede aprender combinações de ingredientes a partir de um determinado número de receitas, possa através de um estímulo que lhe seja apresentado, criar uma nova combinação. O valor dessa combinação será avaliado através de uma apreciação humana, processo que, por um lado está sujeito a alguma subjectividade, mas por outro, pode ser realizado pela maioria das pessoas.

Na secção 5.4, dedicada ao use-case de criatividade, serão descritos em detalhe o procedimento usado, os resultados obtidos e os critérios usados para a validação desses resultados.

### 3.1.2. Características estruturais do modelo

Descrevemos em detalhe as características estruturais do modelo, referindo de que forma estas contribuem para a modelação dos fenómenos pretendidos.

#### 3.1.2.1. Topologia

Ao nível da topologia da rede, a versão a desenvolver nesta tese de mestrado, terá apenas uma camada de nós. O modelo das RANs permite a conectividade total entre nós, assemelhando-se dessa forma às redes de Hopfield, formadas por uma camada de nós com ligações recorrentes. As RANs diferem, no entanto, no aspecto em que as ligações não são necessariamente simétricas e não exigem (mas possibilitam) a conectividade total entre nós.

Posteriormente, e já fora do contexto deste trabalho de Mestrado, prevê-se a expansão das RANs para um modelo com várias camadas, o que trará naturalmente algumas semelhanças com as redes neuronais *multi-layer*, mas especialmente com o modelo IA, em que as várias camadas representam diferentes níveis de abstracção e se podem influenciar mutuamente, ao contrário das típicas redes *feedforward*. Nessa versão completa do modelo RANs a sua topologia será dinâmica havendo lugar a uma construção *bottom-up* de várias camadas. Aí, cada novo nó criado numa camada representa um conceito novo e que corresponde a um padrão emergente da camada inferior.

A possibilidade da existência de pesos negativos nas RANs é o suficiente para modelar o fenómeno da inibição lateral, pois um nó activo mais rapidamente ou mais

fortemente que os seus vizinhos, se tiver ligações com pesos negativos com estes irá passar-lhes uma carga negativa, inibindo-os e destacando-se. Foram também exploradas outras formas de conseguir a modelação deste fenómeno sem pesos negativos, nomeadamente através da representação nestes de aproximações de probabilidades condicionadas.

### 3.1.2.2. Representação da Informação

Ao nível da semântica da rede, o modelo RANs de uma camada permite alguma flexibilidade, pois pode suportar uma abordagem mais distribuída ou localizada dos conceitos.

Contudo, a versão multi-camada das RANs terá como propósito criar uma hierarquia de conceitos, sendo, portanto, a camada mais baixa mais próxima do conexionismo e da representação distribuída, e à medida que se avança para o topo da hierarquia de camadas, a representação de informação será cada vez mais localizada e estruturada, ou seja, mais simbólica. A flexibilidade é oferecida na medida em que não existe um número fixo de camadas, nem uma restrição quanto ao nível de abstracção e distribuição dos conceitos nas camadas mais inferiores ou superiores. Esta característica é uma das inovações deste modelo, sendo que ainda assim se inspira no modelo *Spreading Activation* por formar uma rede semântica de conceitos associados.

### 3.1.2.3. Activação e Propagação

Pretende-se que a activação possa ser propagada na rede através das ligações entre nós relacionados assemelhando-se ao modelo *Spreading Activation*, em que um nó com uma activação superior a um *threshold* propaga parte da sua carga para os nós com que se relaciona.

Este fenómeno está também presente em diversas arquitecturas cognitivas, como ACT-R, 4CAPS e DUAL.

A reposição, ao longo do tempo, da activação é uma característica essencial para modelar a activação ou repressão dos conceitos em cada instante. Esta é uma característica usada, por exemplo, no modelo IA e nas arquitecturas ACT-R e DUAL. A grande inspiração, contudo, vem das *Spiking Neural Networks*, redes que introduziram informação temporal na comunicação entre nós. A reposição, no modelo RAN, corresponde à característica das SNN, do modelo IA e das arquitecturas referidas denominado de decaimento, e representa o decaimento de valores positivos para nulos.

Os fenómenos de *Priming* são possíveis de simular no modelo RANs dada a continuidade no tempo, e o decaimento, das activações de cada nó.

Não havendo neste modelo uma distinção entre a memória implícita e explícita, consideramos a activação de um nó como o grau de intensidade da relevância desse conceito para o resto do padrão de activação dos outros nós. Tendo em consideração o decaimento gradual ao longo do tempo, isto é suficiente para que se possa modelar o *priming* perceptual, pois se a carga dos nós do estímulo inicial ainda não tiver decaído totalmente, irá aumentar e facilitar a resposta a um novo estímulo igual, ou semelhante na sua forma, isto é, em que uma parte dos nós é activada de novo.

Dado que a aprendizagem no modelo RAN com uma camada é essencialmente associativo, o mecanismo de *Spreading Activation* será também envolvido na modelação do *associative priming*. O estímulo inicial irá propagar parte da sua carga para os nós relacionados (associativamente) o que irá facilitar a resposta a um estímulo associado ao primeiro.

Com a expansão do modelo RAN para várias camadas, construir-se-ão relações semânticas entre conceitos, o que permitirá com o mecanismo de *Spreading Activation* a modelação do *priming* conceptual.

O paradigma Deese-Roediger-McDermott é possível de modelar também graças a estes componentes, em que a injeção de vários padrões relacionados com um certo conceito, irão activar o mesmo pelo mecanismo de *Spreading Activation*, podendo levar a uma activação tão forte que pode ser interpretada como uma falsa memória.

#### 3.1.2.4. Regulação

Os fenómenos da regulação serão introduzidos numa versão futura do modelo RANs. Este componente traduzir-se-á em influências exacerbadoras ou inibitórias das ligações entre nós, e.g., imitando a configuração axoaxónica (Panzanelli, et al., 2011) (Wang, et al., 2012) ou o efeito abrangente das células neuragliaiformes (Oláh, et al., 2009) (Chittajallu, et al., 2013), podendo dar origem a redes de regulação complexas.

Outra forma possível de actuação dos mecanismos de regulação que iremos explorar em futuras versões do modelo é a de permitir que a activação dos nós com papel regulatório possam influenciar os parâmetros usados nos processos de aprendizagem e de propagação de activação dos nós regulados.

Nas RANs será possível também um nó realizar auto-regulação, i.e., reprimir a sua activação ou manter-se activo na ausência de activação de outros nós ou de *inputs* injectados na rede. Esta capacidade pode provocar a instabilidade permanente numa rede que não recebe activação o que permite simular alguns tipos de patologias ou explicar a permanência de uma representação mental na ausência de estímulos.

A inclusão destas forças regulatórias no modelo das RANs prende-se com o facto de se pretender permitir a modelação de fenómenos de maior complexidade e é suportada pela importância que os factores regulatórios têm em diversos processos neurológicos, especialmente na expressão das emoções, sendo este um campo de investigação em grande expansão nas últimas décadas (Gross, 1998) (Chambers, et al., 2009) (Ochsner, et al., 2012). Dada a metodologia iterativa com que se pretende desenvolver o modelo, o trabalho nesta tese focou-se na modelação dos fenómenos do *Priming* e DRM, sendo de menor complexidade, mas necessários para posteriormente se evoluir para a introdução de fenómenos mais complexos que exigem o uso de regulação.

O componente da regulação terá especial importância na modelação do fenómeno da habituação e do fenómeno oposto, a sensibilização. Concretamente, um estímulo repetido poderá ter a sua resposta aumentada ou diminuída através do componente da regulação na entrada dos seus nós. Pretende-se também modelar várias características essenciais deste fenómeno. A recuperação espontânea torna-se possível realizando um decaimento temporal da regulação inibitória, no caso da habituação. Isto é, após o fenómeno estar habituado através do componente da regulação, a ausência de esse estímulo levará a que esse componente gradualmente perca importância, o que permitirá

levar a resposta ao estímulo para níveis neutros. A potenciação da habituação através de vários processos de recuperação espontânea e do aumento da frequência dos estímulos pode também ser modelada, tendo em conta o número de recuperações já efectuadas e o intervalo de tempo entre estímulos.

### 3.1.2.5. Aprendizagem

Ao nível da aprendizagem, pretende-se que o modelo RANs, nesta primeira versão, seja capaz de aprender relações entre conceitos, de modo a que activação de um nó provoque a propagação de activação para conceitos relacionados. Ao mesmo pretende-se também a aprendizagem de relações inibitórias, que permitam a modelação da inibição lateral.

Em concreto pretendemos experimentar estilos de aprendizagem com inspirações na neurociência, mais especificamente, na teoria de Hebb que especifica um mecanismo para a plasticidade sináptica, em que uma activação simultânea de duas células aumenta a força sináptica entre as mesmas. Assim, quando é apresentado um padrão de activação à rede, será feita um ajuste nos pesos das ligações, reforçando aquelas que unirem dois nós com níveis semelhantes de activação ou repressão.

### 3.1.3. Características inovadoras

Das várias características do modelo RANs acima descritas, destaca-se nesta secção as que trazem a este modelo alguma diferenciação e grau de inovação.

Em primeiro lugar, o facto de o modelo completo, através da sua representação hierárquica de padrões, em que um nó de uma camada superior corresponderá a um determinado estado de um conjunto de nós de uma camada inferior, criar uma estrutura que fará a transição de uma camada puramente conexionista para camadas progressivamente mais próximas do simbolismo. Este tipo de estrutura é uma materialização do nível conceptual proposto por Peter Gärdenfors, descrito na secção 2.1.4. A implementação e exploração deste cenário de topologia dinâmica sai fora do âmbito deste trabalho, tendo lugar apenas dentro do âmbito do projecto ConCreTe.

Em segundo lugar, a incorporação de fenómenos regulatórios numa rede de carácter conexionista é um dos aspectos inovadores e pretende contribuir para a modelação de fenómenos cognitivos mais complexos e proporcionar um maior realismo ao nível neurológico.

No que se refere a aspectos relativos a esta fase do trabalho, a fórmula de cálculo da activação de cada nó em cada instante, com a inclusão de um factor de solipsismo, i.e., da importância relativa dada ao nível de activação anterior do nó versus a activação recebida dos outros nós, é diferenciadora. Em conjunto com o ritmo de reposição, funciona como uma espécie de memória individual do nó e contribuirá, tal como referido anteriormente, para a modelação de alguns fenómenos como o *Priming*.

O facto de os pesos da rede serem inicializados a zero e não com valores aleatórios, é também uma escolha incomum e deve-se ao facto de pretendermos imitar o

desenvolvimento cerebral, em que numa fase inicial existem neurónios, mas não existem ligações entre eles.

## 3.2. Requisitos da Aplicação

No âmbito deste trabalho, foi desenvolvida uma aplicação que permite a realização de simulações parametrizáveis de modo a tornar possível testar diferentes configurações do modelo e expô-lo a diferentes circunstâncias.

Como ponto de partida, elaboramos alguns princípios que guiaram a especificação dos requisitos. Tendo em conta que o público-alvo desta aplicação será os investigadores que prosseguirem o trabalho no modelo RANs, podemos assumir que o utilizador da aplicação terá alguns conhecimentos na área e que os conceitos envolvidos no modelo RANs já lhe serão familiares, o que terá alguma influência ao nível da usabilidade. Também dado o âmbito científico deste projecto e o facto de ser uma aplicação que não requer qualquer tipo de conexão à rede ou computação distribuída, não traz qualquer preocupação no que diz respeito à segurança.

Nesta secção incluímos os diagramas de use-case e os primeiros esboços da interface gráfica usados como parte do processo de levantamento de requisitos para a aplicação, assim como o conjunto de requisitos obtidos e a sua descrição.

### 3.2.1. Diagramas de Use-Case

Como parte do processo de levantamento de requisitos para a aplicação, recorreremos à elaboração de use-cases.

Existindo apenas um actor que interage com o sistema, elaboramos um diagrama compacto contendo os vários tipos de interacção permitidos, que são descritos abaixo.

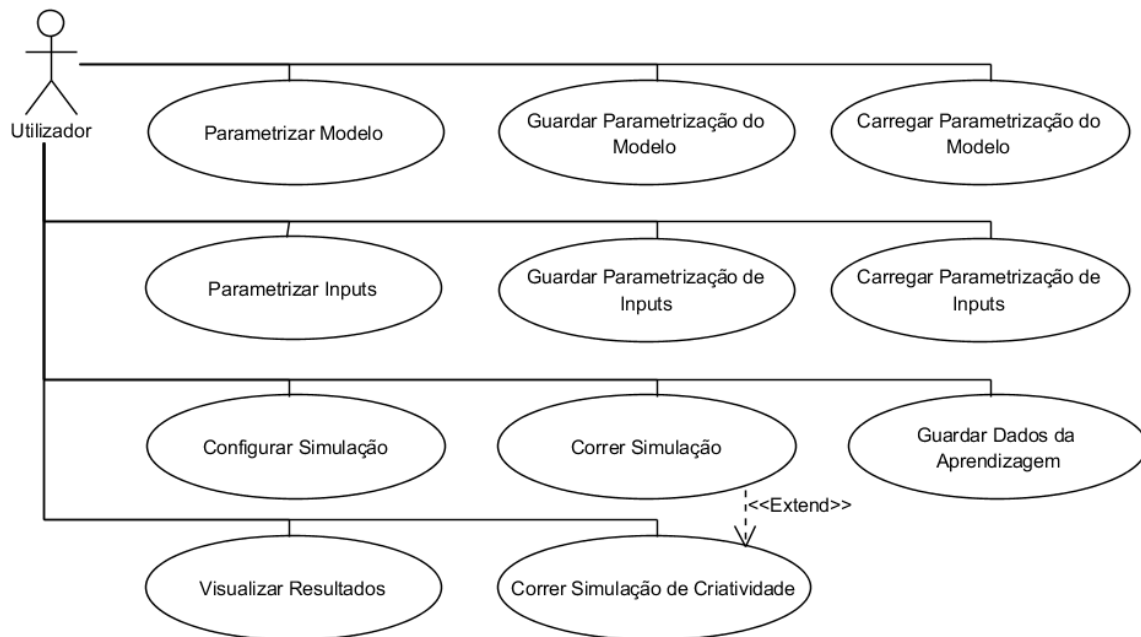


Figura 1 – Diagrama de Use-cases. Encontram-se na figura todas as interações que o utilizador poderá ter com o sistema.

A parametrização de modelo permitirá ao utilizador criar uma instância do modelo, i.e., definir as propriedades e os parâmetros do mesmo, como o número de nós e suas propriedades, tipo de conectividade, tipos de regulação a utilizar, etc. É permitido ao utilizador gravar e carregar essa parametrização para que possa ser usada posteriormente noutras simulações.

A parametrização de *inputs* permite definir quais os padrões que serão injectados na rede, bem como em que instantes temporais isso acontecerá. Também esta parametrização poderá ser guardada e carregada, permitindo, por exemplo, efectuar simulações com redes diferentes que recebem o mesmo conjunto de *inputs*.

A configuração da simulação diz respeito às propriedades da simulação em si, i.e., ao intervalo temporal em que esta decorrerá e a possibilidade de esta decorrer sem fenómenos de aprendizagem. Por fim, é permitido ao utilizador correr a simulação e após esta terminar, será permitido guardar os dados da aprendizagem efectuada pela rede para que possa ser usada numa nova simulação, e visualizar os resultados da evolução e estado final da rede. Alternativamente, o utilizador pode correr uma simulação de criatividade, que passa pela execução de uma simulação com algumas propriedades especiais.

### 3.2.2. Análise de Requisitos

A partir dos use-cases e esboços de GUI elaborados efectuamos uma análise de requisitos funcionais e não funcionais para a aplicação. A análise realizada segue a categorização FURPS<sup>1</sup> (Grady, 1992), e inclui uma classificação de importância dos

<sup>1</sup> Sistema de classificação de requisitos desenvolvido por Robert Grady na Hewlett-Packard. O acrónimo representa **F**unctionality, **U**sability, **R**eliability, **P**erformance e **S**upportability, sendo o '+' referente a outros requisitos: Design, Implementation, Interface, Physical.



requisitos de acordo com o método MoSCoW<sup>2</sup> (International Institute of Business Analysis, 2009). A seguinte tabela sumariza essas informações.

<b>Tipo de Requisito</b>	<b>ID</b>	<b>Descrição</b>	<b>Classificação MoSCoW</b>
<b>Functionality</b>	F1	Capacidade de criar, gravar e carregar uma instância do modelo, ou seja, um conjunto de parâmetros do modelo RANs	<b>MUST</b>
	F2	Capacidade de criar, gravar e carregar uma parametrização de <i>inputs</i> , ou seja, um conjunto de padrões a injectar no modelo RANs	<b>MUST</b>
	F3	Capacidade de criar uma configuração de simulação, ou seja, um conjunto de parâmetros para a simulação do modelo RANs	<b>SHOULD</b>
	F4	Capacidade de gravar os dados relativos à aprendizagem realizada numa simulação	<b>MUST</b>
	F5	Capacidade de aceder aos resultados das simulações	<b>MUST</b>
<b>Usability</b>	U1	Facilidade em efectuar alterações ao modelo, i.e, alterar os parâmetros globais do mesmo, por exemplo, o tipo de conectividade, funções de activação, intervalo de activações, etc. através da interface	<b>MUST</b>
	U2	Facilidade na modificação dos parâmetros dos nós através da interface	<b>SHOULD</b>
	U3	Possibilidade de configurar simulações automáticas parametrizáveis para extracção de estatísticas e características do modelo	<b>SHOULD</b>
	U4	Fácil visualização de resultados e estatísticas das simulações	<b>MUST</b>
<b>Performance</b>	P1	Optimização das estruturas de dados usadas em termos de memória, tendo em conta a expansão do modelo e o crescimento do número de nós e ligações (escalabilidade)	<b>SHOULD</b>
	P2	Optimização das operações realizadas em termos de eficiência de processamento, tendo em conta a expansão do modelo e o aumento do número de operações a realizar	<b>SHOULD</b>
<b>Supportability</b>	S1	Facilidade em alterar e expandir o código de modo a permitir a variação da topologia do	<b>MUST</b>

<sup>2</sup> Método de priorização de requisitos criado por Dai Clegg da Oracle UK Consulting com a seguinte escala: **MUST** - requisito crítico para o projecto ser considerado um sucesso, **SHOULD** - requisito importante para o projecto que deve ser incluído se possível, **COULD** - requisito desejável, mas não necessário, devendo ser incluído se houver tempo e recursos, **WON'T** - requisito a não incluir, mas que será considerado no futuro.

	modelo	
--	--------	--

Ao nível da *Reliability* não foram encontrados requisitos, pois a aplicação não tem de lidar com assuntos como *availability* ou recuperação de falhas. Também não existem

Tabela 1 - Análise de Requisitos

restrições ao nível de *design*, implementação (linguagem ou standards a usar na implementação), interface (sistemas externos com que a aplicação tenha de interagir) ou físicos (relativos ao hardware).

Segue-se uma descrição detalhada dos requisitos encontrados.

F1 - Corresponde aos use-cases de parametrização do modelo e respectivas operações de guardar e carregar. Esta funcionalidade permitirá ao utilizador modificar todos os parâmetros e configurações do modelo que sejam variáveis e guardar esse conjunto de parâmetros num ficheiro.

F2 - Corresponde aos use-cases de parametrização dos *inputs* do modelo e respectivas operações de guardar e carregar. Esta funcionalidade permitirá ao utilizador criar uma lista de *inputs* aleatórios ou presentes em ficheiros para injectar na rede, especificando os instantes temporais em que isso acontecerá, e permitindo ainda criar variações dos padrões em causa. Estas configurações poderão ser guardadas e carregadas a partir de um ficheiro.

F3 - Corresponde aos use-cases de parametrização da simulação. Esta funcionalidade permitirá ao utilizador definir por quanto tempo decorrerá a simulação, bem como definir a possibilidade de uma simulação sem fenómenos de aprendizagem.

F4 - Corresponde aos use-cases de guardar os dados da aprendizagem. Permite ao utilizador guardar os dados recolhidos pela rede nos processos de aprendizagem, para serem usados em outras simulações.

F5 - Corresponde ao use-case de visualização de resultados. Permitirá ao utilizador aceder aos dados relativos à evolução e estado final da rede, como evolução da activação dos nós, evolução dos pesos, etc.

U1 - Este requisito diz respeito à facilidade de alteração dos parâmetros globais do modelo. A interface terá de permitir um rápido acesso e fácil alteração a todos estes parâmetros.

U2 - Este requisito diz respeito à facilidade de alteração dos parâmetros dos nós do modelo. A interface terá de permitir alterar as propriedades de cada nó, ou de conjuntos de nós, tendo em conta que o número de nós do modelo poderá ser bastante grande.

Tabela 2 - Requisitos da Aplicação

U3 – A realização de simulações automáticas refere-se à possibilidade de definir a realização de várias simulações, especificando quais as diferenças entre elas. Por exemplo, para uma instância do modelo, realizar 10 simulações com 5 ficheiros de *inputs* diferentes e 5 parametrizações de *inputs* aleatórias.

U4 – É de grande importância este requisito, pois além de poder aceder aos dados em bruto, será importante existirem formas de o utilizador visualizar de uma maneira intuitiva os dados das simulações. Exigirá o desenho de gráficos, criação de imagens ou extracção de estatísticas, sendo que o tipo de informações a visualizar ainda não está completamente definido.

P1 – A optimização das estruturas de dados utilizadas é um factor importante, na medida em que o modelo irá evoluir para versões com mais camadas, aumentando significativamente o número de nós e ligações. Para isso é importante nesta fase, respeitando a correcção do modelo, fazer uso da menor quantidade de memória possível.

P2 – A optimização do número de operações é outro factor a ter em conta dada a expansão referida do modelo.

S1 – Este requisito refere-se à qualidade do código desenvolvido. Este terá de ser desenvolvido em módulos, permitindo uma fácil inclusão ou exclusão de componentes, e configuração de parâmetros e deverá ter em conta a expansão do modelo em que o modelo desenvolvido nesta fase será apenas uma camada do modelo RANs que se pretende atingir.

## 4. Arquitectura da versão uni-camada do modelo RANs

Neste capítulo, é descrita a arquitectura da versão uni-camada do modelo conexionista das RANs.

### 4.1. Topologia da Rede

O modelo das RANs é formado, nesta altura, por uma única camada de nós. Neste aspecto o modelo difere bastante das tradicionais redes feed-forward. Não existe uma camada de *input*: a activação é injectada nos nós desta camada; nem uma camada de *output*: consideramos o *output* como os padrões emergentes, resultado da propagação da activação na rede ao longo do tempo. Os nós podem estabelecer ligações excitatórias ou inibitórias através da aprendizagem, realizada ao longo do tempo, quando é recebida informação sensorial, representada por padrões de *input*. Estas ligações permitem a propagação de activação entre os nós da camada.

### 4.2. Propriedades de um nó

Cada nó tem um estado interno, representado pelo seu nível de activação, que varia continuamente entre um valor mínimo e um valor máximo. A activação do nó  $n_i$  no instante  $t$  é denotada por  $A_{ni}(t)$ . A experimentação realizada focou-se em activações variáveis no domínio  $[0,1]$ .

Na ausência de activação injectada no nó, esta activação decai gradualmente ao longo do tempo para o *rest state*, de valor igual a zero.

A rapidez deste decaimento é controlada por dois factores: o factor de solipsismo  $0 \leq \lambda_{ni} \leq 1$ , que representa a importância relativa da activação do nó  $n_i$  no instante anterior em comparação com a activação recebida dos outros nós; e o factor de reposição  $0 \leq R_{ni} \leq 1$ , que controla a proporção de activação perdida pelo nó em cada instante.

Ao nível semântico, considera-se a activação de um nó, num dado instante, como o grau de activação do conceito por ele representado. No caso de esta ser igual ao *rest state*, considera-se o conceito como indiferente.

Cada nó  $n_i$  pode ter um *threshold*, denotado por  $T_{ni}(t)$ , cujo valor está contido no domínio da activação. Este define se o nó propagará ou não activação, de acordo com o seu estado nesse instante. Nesta altura consideramos apenas *thresholds* estáticos, sendo que futuramente serão experimentados *thresholds* dinâmicos, sujeitos a processos regulatórios.

### 4.3. Injecção de Activação

A activação de um nó  $n_i$ , num determinado instante de tempo, depende de três componentes: a proporção de activação do instante anterior com que o nó permanece, a

activação propagada pelos outros nós através das ligações com o nó  $n_i$ , e a activação injectada na rede na forma de *input* externo (e.g., para simular percepção sensorial).

O primeiro componente é calculado através da subtracção de uma percentagem, ditada pelo factor de reposição  $R_{ni}$ , do nível de activação que o nó tinha no instante anterior. Este funciona como uma memória individual do nó, permitindo que as transições de estado sejam feitas de forma progressiva. Para simplificar o entendimento das fórmulas que se seguirão este componente será denominado *Activação do Nó*:

$$\text{Activação do Nó } (i) = (A_{ni}(t) - R_{ni} * A_{ni}(t))$$

O segundo componente, relativo à activação propagada pelos diferentes nós da camada através das ligações com o nó  $n_i$  é dependente do método de propagação usado (secção 4.5). A activação a injectar em cada nó, calculada através do método de propagação, poderá (dependendo do método usado) ser ajustada por uma função de activação  $f$ . Esta função é uma função sigmóide:

$$f(x) = 2 * \left( \frac{1}{1 + e^{-\beta x}} \right) - 1$$

Onde

- $\beta$  é um parâmetro para a função sigmóide. Nas experiências realizadas é sempre igual a um, mas poderá ser futuramente alvo de variações.

Este componente é o principal responsável pela modelação da evolução de estados cognitivos através da propagação de activação pelas ligações existentes na camada. Será designado por *Activação da Camada*:

$$\text{Activação da Camada } (i) = f (\text{ Propagação para Nó}(i) )$$

Uma vez que os estes dois componentes dizem respeito à activação propagada entre os nós da rede, são alternativamente designados em conjunto por *Activação Interna*.

O terceiro componente corresponde à estimulação externa que irá desestabilizar a rede, usada para simular a recepção de informação sensorial. Por referir-se a activação externa à rede será designada por *Activação Externa*, sendo que  $I(i)$  se refere ao valor do padrão de *input* para o nó  $n_i$ .

$$\text{Activação Externa } (i) = I(i)$$

Ao longo do desenvolvimento desta fase inicial do modelo, foram testadas várias formas de combinar estes três componentes. Em seguida, expomos em que consistiam essas abordagens e quais as vantagens e desvantagens de cada uma delas, tendo em conta os objectivos do modelo.

### **Activação Externa VS Activação da Camada**

Numa primeira abordagem para calcular a activação de um dado nó num determinado instante, foi feita uma diferenciação entre a activação externa e a activação propagada pelos outros nós. Ou seja, se nesse instante existisse activação externa para injectar, essa activação seria ponderada com a activação do nó no instante anterior:

$$A_{ni}(t + 1) = \lambda_{ni} * Activação\ do\ Nó\ (i) + (1 - \lambda_{ni}) * I(i)$$

No caso de não existir, a activação do nó no instante anterior seria ponderada com a activação vinda dos outros nós:

$$A_{ni}(t + 1) = \lambda_{ni} * Activação\ do\ Nó\ (i) + (1 - \lambda_{ni}) * Activação\ da\ Camada\ (i)$$

Esta abordagem permitiu obter alguns resultados ao nível da aprendizagem de um padrão, que após ser injectado algumas vezes na rede, passava a ser representado por um ponto fixo, isto é, a activação dos vários nós estabilizava num determinado valor, não apresentando decaimento.

Contudo, esta forma de lidar com a injeção de activação tinha um problema que impossibilitava a correcta modelação dos fenómenos de *Priming* e DRM. A aplicação de duas formas diferentes de injeção, sendo que a primeira apenas inclui a activação externa e a activação do próprio nó, e a segunda que inclui apenas as duas componentes da activação interna, inviabiliza a recepção simultânea de activação externa e activação propagada por outros nós. Por exemplo, se consideramos que o nó  $n_i$  é activado no instante  $t=1$  e que tem uma ligação com o nó  $n_j$ , para o qual irá propagar activação no instante seguinte, segundo a abordagem descrita, no caso de no instante  $t=2$  existir activação externa para ser injectada, a activação propagada pelo nó  $n_i$  para o nó  $n_j$  não é considerada.

Esta abordagem impediria a acumulação e propagação de activação na rede, sendo claramente incompatível com a modelação dos fenómenos de *Priming* e DRM, caracterizados pela propagação da activação entre nós relacionados, e que requerem a consideração simultânea dos vários componentes da activação.

### Injeção de Activação Ponderada

Como forma de solucionar o problema enunciado na abordagem anterior, foi estabelecido um método de englobar, em todos os instates, os três componentes de activação. Esta consiste, em primeiro lugar, numa ponderação entre activação externa e activação interna. Esta ponderação é efectuada tendo em conta a intensidade de activação externa. A ponderação entre os dois componentes da activação interna continua s ser feita através do factor de solipsismo.

$$A_{ni}(t + 1) = I(i) * I(i)$$

$$(1 - I(i)) * (\lambda_{ni} * \text{Activação do Nó } (i)) + (1 - \lambda_{ni}) * \text{Activação da Camada } (i)$$

Com esta abordagem obtivemos dois benefícios: a combinação simultânea de todos os componentes da activação em todos os momentos da simulação, e a individualização de cada nó na ponderação activação externa e activação interna. A importância da activação externa é determinada pela própria dimensão desse *input*, ou seja, quando este é máximo, a activação interna não é considerada, e quando este é mínimo a activação interna é considerada na sua plenitude. Isto permite que a activação de um nó que receba activação externa, de intensidade não máxima, seja uma ponderação entre essa componente e a activação interna, enquanto que para um nó que não é estimulado externamente, activação interna não é afectada.

Apesar da melhoria efectuada, encontramos ainda algumas particularidades deste método, que podem ser entendidas como limitações. Uma delas é o facto de o decaimento das activaões ser efectivamente controlado por dois parâmetros: solipsismo  $\lambda_{ni}$  e reposição  $R_{ni}$ .

Se consideramos um nó que não recebe activação externa, nem propagada por outros nós a sua activação num instante é dada por  $\lambda_{ni} * \text{Activação do Nó } (i)$ , ou seja, existe uma perda de  $(1 - \lambda_{ni}) * \text{Activação do Nó } (i)$ , sendo que a Activação do Nó (i) compreende já a perda de alguma activação de acordo com a reposição  $R_{ni}$ .

Isto implica que a modelação de um possível fenómeno em que a activação de um nó persiste inalterada, na ausência de qualquer recepção de activação, seja feita através de um factor de solipsismo igual a  $\lambda_{ni} = 1$  e uma reposição  $R_{ni} = 0$ . Ao mesmo tempo, isto implica que nessa situação, se surgir activação vinda de outros nós, esta será ignorada. Não existe portanto um forma de simular um estado estático de activação (diferente do nível de activação rest state) em que o nó permaneça receptivo a activação da camada.

### Injecção de Activação com Solipsismo Dinâmico

Como forma de tentar suprir este problema, foi testada uma nova versão de injecção de propagação, em que o decaimento é totalmente controlado pelo factor de decaimento, e o factor de solipsismo passa a ser dinâmico, e ditado pela força da activação recebida de outros nós. Este mecanismo é semelhante ao usado anteriormente para balancear a activação externa com a activação interna.

$$A_{ni}(t + 1) = I(i) * I(i) + (1 - I(i)) * (\text{Activação da Camada } (i)) * \text{Activação da Camada } (i) + (1 - \text{Activação da Camada } (i)) * \text{Activação do Nó } (i)$$

Este método traz algumas vantagens, designadamente a possibilidade de aplicar um decaimento mais suave e lento para a activação dos nós sem, com isso, afectar a recepção de activação propagada por outros nós. Na versão anterior, um decaimento mais lento é necessariamente modelado utilizando factores de solipsismo maiores, o que ao mesmo tempo diminui a importância dada pelos nós à activação da camada.

No entanto, este método apresenta também alguns problemas. A ponderação feita entre as duas componentes é controlada pela quantidade de activação recebida pelos outros nós, o que pode tornar o total de *input* interno instável.

Se considerarmos o caso em que um nó, recebe activação externa e a sua activação é colocada a 1, e nos instantes seguintes na ausência de activação externa e propagação de outros nós, esta decai de acordo com o factor de reposição, a chegada de uma quantidade pequena de activação de outros nós, em vez de contribuir para a subida da activação ou para um decaimento mais suave, pode acentuar esse decaimento. Naturalmente, este tipo de situações não é compatível com a simulação de fenómenos como o *Priming*, em que se pretende que activação vinda de outros nós, ainda que em pequenas quantidades, tenha um efeito positivo no nível de activação do nó que a recebe. Este comportamento é demonstrado na secção 5.2.

## 4.4. Aprendizagem

A aprendizagem nesta primeira camada do modelo RANs tem como objectivo principal o estabelecimento de relações associativas entre nós, de modo a que a rede se assemelhe a uma rede semântica. Com o estabelecimento desse tipo de relações, poder-se-á fazer uso do mecanismo Spreading Activation para, após a estimulação de um ou mais nós, propagar essa activação para nós relacionados e simular os fenómenos do *Priming* e DRM.

Nesta fase apenas considerámos *inputs* binários, sendo que a generalidade dos métodos de treino desenvolvidos adapta-se apenas a este género de *inputs*. A generalização dos métodos para *inputs* contínuos será um ponto a ter em conta no futuro desenvolvimento do modelo RANs.

Esses *inputs* representam combinações de ingredientes usados em receitas culinárias. Uma análise a esses dados de *input* é efectuada na secção 5.1.

### *Activation Correlation Simétrica*

A primeira abordagem seguida no desenvolvimento de um método de treino capaz de capturar essas relações foi inspirada na teoria de Hebb. Esta é uma teoria da neurociência que pode ser resumida como “quaisquer duas células ou sistemas de células que estão repetidamente activas ao mesmo tempo tenderão a estar associadas, de maneira a que a actividade de uma facilita a actividade da outra” (Hebb, 1949).

Deste modo, quando é recebido um padrão de *input*, pretende-se reforçar a ligação de nós que estejam simultaneamente activos.



Ao mesmo tempo, sendo também um dos objectivos do modelo RANs a incorporação de fenómenos de inibição entre nós, pretende-se enfraquecer a ligação entre nós que estejam frequentemente dissociados.

A seguinte tabela sumariza as alterações a efectuar aos pesos da ligação  $w(n_i, n_j)$  de acordo com os níveis de activação de cada nó.

$A_{ni}(t)$	$A_{nj}(t)$	
	1	0
1	Reforço	Enfraquecimento
0	Enfraquecimento	Sem alteração

Tabela 3 – Activation Correlation Simétrica: alterações aos pesos

O reforço ou enfraquecimento nos pesos é entao dado pelo ritmo de aprendizagem  $0 \leq \mu \leq 1$  definido para o modelo.

Reforço:  $\Delta w(n_i, n_j) = \mu$

Enfraquecimento:  $\Delta w(n_i, n_j) = -\mu$

Nesta abordagem os pesos poderão evoluir no domínio  $]-\infty, +\infty[$ . É também de salientar que o ritmo de aprendizagem  $\mu$  não influencia o número de ligações positivas e negativas após o treino com o mesmo conjunto de *inputs*, sendo apenas alterada a força dessas ligações. Também é notório que a matriz de pesos será simétrica, isto é,  $w(n_i, n_j) = w(n_j, n_i)$ .

Após o treino da rede com o conjunto total de receitas obteve-se o seguinte número de ligações positivas, nulas e negativas:

Número de Ligações Negativas: 239598 (99,80%)

Número de Ligações Nulas: 490 (0,20%)

Número de Ligações Positivas: 12 ( $\approx 0\%$ )

As ligações nulas correspondem às ligações de cada nó para si próprio, intencionalmente mantidas a zero.

Como é claro pela observação dos resultados, a aplicação deste método conduz a uma quase inexistência de ligações positivas, o que impossibilita a propagação da activação e não é coerente com os objectivos do modelo. Isto deve-se à grande esparsidade dos dados usados para o treino (ver secção 5.1). Sendo que a média de ingredientes numa receita é de aproximadamente 9, num total de 490, na recepção de um padrão de *input* um nó  $n_i$  activo irá em média, reforçar as suas ligações com outros 8 nós, e enfraquecer as suas ligações com 481 nós. Para além disso, os ingredientes mais frequentes terão as suas ligações com outros nós ainda mais enfraquecidas. Essa situação foi verificada, por exemplo, no ingrediente mais frequente, o sal. Também o par mais frequente de todo o conjunto, alho e sal, tem uma ligação  $w(alho, sal) = w(sal, alho) = -455\mu$ . Esse valor é obtido a partir da diferença entre o número de ocorrências do par (2373), em que a sua

ligação é reforçada, e o número de ocorrências de sal sem alho (1298) e de alho sem sal (232), em que a ligação é enfraquecida.

Uma das constatações feitas através desta simples análise foi a da necessidade de tornar o treino assimétrico. Se o ingrediente alho está presente em 1307 receitas, e nesse conjunto o ingrediente sal ocorre 1075 vezes (não ocorre em 232), pretendemos que o nó representativo do conceito alho tenha uma relação positiva com o nó que representa o sal, pois é muito determinante para a sua activação. Por outro lado, o ingrediente sal estando presente em 2373 receitas, é menos influente para a activação do nó sal, pelo que a força da ligação de sal para alho deverá ser menor que a da ligação inversa.

### *Activation Correlation Assimétrica*

Dado o problema exposto anteriormente, partiu-se para uma nova abordagem em que apenas se alteram as ligações de saída de nós activos no padrão a aprender. Assim um nó inactivo não terá a sua ligação para um nó activo enfraquecida.

A seguinte tabela sumariza as alterações aos pesos da ligação  $w(n_i, n_j)$  de acordo com os níveis de activação de cada nó.

Nó $N_i$	Nó $N_j$	
	1	0
1	Reforço	Enfraquecimento
0	Sem alteração	Sem alteração

Tabela 4 - Activation Correlation Assimétrica: alterações aos pesos

O reforço ou enfraquecimento nos pesos continua a ser obtido pelo ritmo de aprendizagem  $\mu$  definido para o modelo.

Reforço:  $\Delta w(n_i, n_j) = \mu$

Enfraquecimento:  $\Delta w(n_i, n_j) = -\mu$

Após o treino da rede com o conjunto total de receitas obteve-se o seguinte número de ligações positivas, nulas e negativas:

Número de Ligações Negativas: 237829 (99,05%)

Número de Ligações Nulas: 830 (0,35%)

Número de Ligações Positivas: 1441 (0,60%)

Como se pode observar, o número de ligações positivas aumentou para 1441, mas ainda representa uma pequena parte do número total de ligações. O caso particular mencionado anteriormente foi resolvido, obtendo-se agora  $w(alho, sal) = 843\mu$  e  $w(sal, alho) = -223\mu$ . No entanto, permanece a influência da elevada esparsidade dos dados, levando a uma larga maioria de relações inibitórias que não consegue capturar inteiramente as relações entre os diferentes conceitos.

### *Activation Correlation Assimétrica Ponderada*

Como tentativa de resolver o problema do excesso de inibição, foi testada uma abordagem em que a rede pudesse adaptar-se à esparsidade dos dados.

O que se pretendeu foi equilibrar os reforços excitatórios e inibitórios das ligações, de acordo com o número de elementos activos e inactivos num padrão de *input*. Assim, a aprendizagem de um padrão com muitos elementos nulos levaria a um maior reforço excitatório do que inibitório, enquanto que no caso contrário, um padrão com muitos elementos activos levaria a um maior reforço inibitório do que excitatório.

A intenção de reforço ou enfraquecimento nos pesos mantém-se como no método anterior, sendo que agora a variação desses pesos é dada não só pelo ritmo de aprendizagem  $\mu$ , mas também pela proporção de nó activos e inactivos no padrão.

$$\text{Reforço: } \Delta w(ni, nj) = \mu * \left(1 - \left(\frac{n^\circ \text{ de nós activos}}{n^\circ \text{ total de nós}}\right)\right)$$

$$\text{Enfraquecimento: } \Delta w(ni, nj) = -\mu * \left(1 - \left(\frac{n^\circ \text{ de nós inactivos}}{n^\circ \text{ total de nós}}\right)\right)$$

Tendo em conta a média aproximada de 9 ingredientes activos num total de 490, nos dados de entrada usados, o reforço será em média de  $0.9816 \mu$  e o enfraquecimento de  $0.0184 \mu$ . Ou seja, um nó activo irá, em média, reforçar a sua ligação com outros 8 nós a um ritmo semelhante ao aplicado no método anterior, e irá enfraquecer a sua ligação com os restantes 481 nós mas em níveis muito mais reduzidos.

Além disso, outra particularidade desta adaptação é a de que a rede irá reforçar mais efectivamente as ligações entre nós de padrões mais simples (com poucos nós activos) do que padrões mais complexos.

Esta abordagem mantém-se genérica, sendo possível a aplicação em outros domínios, onde porventura se registe a situação inversa.

Após o treino da rede com o conjunto total de receitas obteve-se o seguinte número de ligações positivas, nulas e negativas:

Número de Ligações Negativas: 207210 (86,30%)  
 Número de Ligações Nulas: 490 (0,20%)  
 Número de Ligações Positivas: 32400 (13,50%)

As ligações nulas correspondem às ligações de cada nó para si próprio, intencionalmente mantidas a zero.

Para  $\mu = 0.01$

Peso médio de uma ligação:  $-0.0016 \pm 0.1291$

Peso médio de uma ligação positiva:  $0.0725 \pm 0.3307$

Peso máximo: 10.47

Peso médio de uma ligação negativa:  $-0.0131 \pm 0.0349$

Peso mínimo: -0.49

Como se verifica existe um crescimento do número de ligações positivas. A supremacia de ligações inibitórias é compensada pelo facto de estas serem de menor força do que as ligações excitatórias.

Outras conclusões se podem tirar destes dados. Apesar de a ligação média ser muito fraca, a ligação mais forte tem uma intensidade bastante elevada. A alteração do ritmo de aprendizagem apenas altera a escala desses valores, não altera as diferenças proporcionais existentes. Esta é uma consequência das várias alterações cumulativas aos pesos, que não têm limite. Se a rede for treinada com outra repetição dos dados de entrada os pesos irão ter o dobro da sua força, o que torna o comportamento da rede muito dependente do número de padrões de entrada.

Este comportamento não se enquadra por inteiro com os objectivos do modelo RANs. A evolução linear dos pesos levará a rede a demonstrar comportamentos demasiado instáveis, que serão demonstrados na secção 5.2.

Por esse motivo, foram desenvolvidas outras abordagens, de carácter probabilístico com uma aproximação frequencista, em que os pesos se mantivessem no domínio [0,1] permitindo uma maior estabilidade à rede. Outra vantagem destes métodos é dependerem exclusivamente dos dados de entrada, não sendo a aprendizagem influenciada por um ritmo de aprendizagem. Neste tipo de abordagem cada ligação traduz-se directamente uma relação entre o número de ocorrência de dois acontecimentos.

### Conexões positivas frequencistas

Como abordagem inicial foi considerado um método em que todas as conexões  $w(n_i, n_j)$  seriam positivas e corresponderiam ao número de co-ocorrências nos padrões de *input* de nós  $n_i$  e  $n_j$  no total de ocorrências de  $n_i$ . Estas ligações representam a frequência relativa da activação do nó  $n_i$  com o nó  $n_j$  e podem ser interpretadas como a probabilidade condicionada de  $n_j$  ser activado, estando  $n_i$  activo.

$$w(n_i, n_j) = \frac{\#(N_i \cap N_j)}{\# N_i}$$

Onde

- $\#N_i$  é o número de ocorrências do nó  $n_i$
- $\#(N_i \cap N_j)$  é o número de co-ocorrências dos nós  $n_i$  e  $n_j$

Desta forma, quando o nó  $n_i$  estiver activo ele irá propagar a activação para o nó  $n_j$  numa quantidade dependente do número de vezes que  $n_j$  co-ocorreu consigo.

A aplicação deste método de treino a todos os padrões de *input* obteve os seguintes resultados:

Número de Ligações Nulas: 189604 (78,97%)

Número de Ligações Positivas: 50496 (21,03%)

Peso médio de uma ligação:  $0.0194 \pm 0.0766$

Peso médio de uma ligação positiva:  $0.0922 \pm 0.1456$

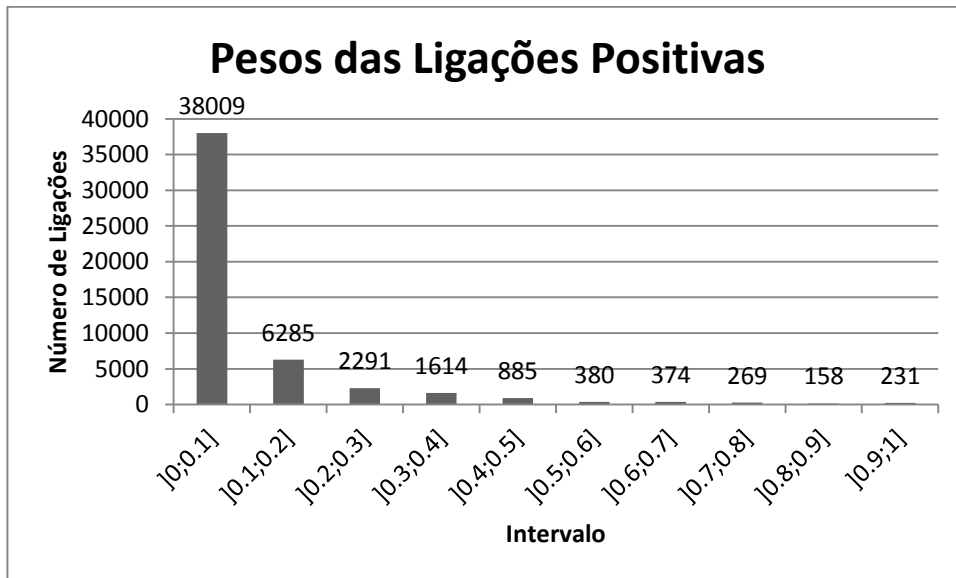


Figura 2 - Conexões positivas frequencistas. Distribuição dos pesos das ligações positivas

Com este método de treino existe uma grande proporção de ligações nulas, entre nós que nunca co-ocorrem, e uma grande concentração das ligações positivas no intervalo ]0 ; 0.1]. Estes resultados reflectem a já referida esparsidade dos dados de entrada.

### Conexões positivas e negativas frequencistas

Um dos objectivos do modelo é o de incorporar inibição entre os nós, o que não era considerado no método anterior.

Como tentativa de incluir essa inibição, a abordagem anterior foi alterada para que cada ligação ponderasse o número de ocorrências com o número de não co-ocorrências. Assim a ligação com o peso  $w(n_i, n_j)$  será positiva se o número de co-ocorrências entre os nós  $n_i$  e  $n_j$  for maior que o número de vezes em que  $n_i$  ocorreu sem o nó  $n_j$ .

$$w(n_i, n_j) = \frac{\#(N_i \cap N_j) - \#(N_i \cap \neg N_j)}{\# N_i}$$

A aplicação deste método de treino a todos os padrões de *input* obteve os seguintes resultados:

Número de Ligações Negativas: 237792 (99,04%)

Número de Ligações Nulas: 896 (0,37%)

Número de Ligações Positivas: 1412 (0,59%)

O elevado (quase total) número de ligações inibitórias torna impossível a propagação de activação, pelo que o método não pode ser aplicado com sucesso.

### Influências excitatórias e inibitórias frequencistas

Foi desenvolvido outro método, que pudesse equilibrar as influências excitatórias e inibitórias numa ligação. A intenção é a de capturar a influência de cada nó na ocorrência ou não de outro nó.

Assim a ligação com o peso  $w(n_i, n_j)$  é ponderada entre a influência positiva do nó  $n_i$  na presença do nó  $n_j$ , calculada através da proporção de co-ocorrências de  $n_i$  e  $n_j$  no total de ocorrências de  $n_j$ , e a influência negativa de  $n_i$  em  $n_j$ , calculada através da proporção de ocorrências de  $n_i$  em que  $n_j$  não ocorre, no total de casos em que  $n_j$  não ocorre. Assim este peso pode interpretar-se com um equilíbrio entre as situações em que  $n_i$  é responsável pela ocorrência de  $n_j$  e em que  $n_i$  é responsável pela não ocorrência de  $n_j$ .

$$w(n_i, n_j) = \frac{\#(N_i \cap N_j)}{\# N_j} - \frac{\#(N_i \cap \neg N_j)}{\#\neg N_j}$$

A aplicação deste método de treino a todos os padrões de *input* obteve os seguintes resultados:

Número de Ligações Negativas: 200948 (83,69%)

Número de Ligações Nulas: 490 (0,20%)

Número de Ligações Positivas: 38662 (16,10%)

As ligações nulas correspondem às ligações de cada nó para si próprio, intencionalmente mantidas a zero.

Peso médio de uma ligação:  $0.0015 \pm 0.0599$

Peso médio de uma ligação positiva:  $0.0691 \pm 0.1116$

Peso médio de uma ligação negativa:  $-0.0115 \pm 0.0291$




Figura 3 - Influências excitatórias e inibitórias frequencistas. Distribuição dos pesos das ligações positivas




Figura 4 - Influências excitatórias e inibitórias frequencistas. Distribuição dos pesos das ligações negativas

Também com este método, o número de ligações positivas é bastante inferior ao número de ligações negativas. Esse facto é contrabalançado pela maior força média das ligações excitatórias, que ainda assim se encontram predominantemente no intervalo ]0 ; 0.1].

## 4.5. Propagação da Activação

Dado um conjunto de pesos, que representam a força das conexões direccionadas entre cada par de nós, com um método de propagação pretende-se calcular a quantidade de activação que cada nó, dado também o seu nível activação actual, irá enviar para os nós com que se relaciona. Tendo em consideração a relação com os métodos de aprendizagem experimentados, foram também testadas diferentes métodos para a propagação da activação, que são em seguida descritos.

### Propagação *FeedForward*

Uma das abordagens testadas corresponde à tradicional propagação nas redes feed-forward. Esta abordagem consiste em calcular a activação que será injectada num nó  $n_i$  através do somatório dos produtos dos níveis de activação dos nós relacionados com  $n_i$  com os pesos das ligações dos nós  $n_j$  para  $n_i$ .

$$\text{Propagação para Nó}(i) = \sum_{j=1}^N A_{nj}(t) * w(nj, ni)$$

De forma a manter a quantidade de activação injectada no nó  $n_i$  dentro dos limites de activação considerados, a activação propagada para cada nó sofre uma transformação através de uma função de activação, usualmente uma função sigmóide (esse processo no modelo RANs é realizado na injeção da propagação).

Esta abordagem permite a contribuição cumulativa de vários nós na activação de um nó, de acordo com o nível de activação actual de cada um deles e com a força da ligação entre os nós. No caso de serem considerados também pesos negativos, a activação positiva de um nó  $n_j$  com uma ligação  $w(nj, ni) < 0$  irá resultar numa contribuição inibitória no somatório apresentado. Se o resultado final foi menor que zero, o nível de activação mínima permitido, a propagação para o nó é colocada a zero. Estas características estão em consonância com aquilo que o nível de activação pretende representar no modelo RANs, e também com os fenómenos que se pretendem modelar.

Neste tipo de propagação inclui-se também a possibilidade da utilização de *thresholds*, em que um nó  $n_i$  apenas propagará activação se o seu nível de activação for superior ao seu *threshold*.

Tendo em conta os métodos de treino de carácter frequencista foram também testadas outras abordagens para a propagação que se pudessem adaptar ao estilo de aprendizagem aplicado, não tendo sido obtido resultados que coincidissem com o comportamento pretendido para o modelo, e tendo em conta os fenómenos que se pretende modelar. O seguinte método está agora em consideração e a sua experimentação será realizada no futuro.

### Propagação Ponderada pela Activação

$$\text{Propagação para Nó}(i) = \frac{\sum_{j=1}^N A_{nj}(t) * w(nj, ni)}{\sum_{j=1}^N A_{nj}(t)}$$

Interpretando o peso  $w(nj, ni)$  como a probabilidade de o nó  $n_i$  ser activado, dada a activação de  $n_j$ , com esta abordagem o nível de activação dos vários nós que contribuirão para o nível de activação de  $n_i$  funcionam como factor de ponderação. Isto é, um nó que esteja fortemente activado irá contribuir de forma mais relevante com o seu peso, para a activação do nó  $n_i$ .

Considere-se o exemplo em que existe apenas um nó  $n_j$  activo, sendo  $A_{nj}(t) = 1$ , e que foi usado o método de treino das influências excitatórias e inibitórias frequencistas e que o peso da ligação  $w(nj, ni) = 0.5$ , ou seja, o nó  $n_j$  tem uma influência positiva em  $n_i$ , segundo a qual este deveria ter uma activação de 0.5.

Sendo o único nó activo, a propagação de activação para o nó  $n_i$  irá ser efectivamente 0.5. Se considerarmos que existe outro nó  $n_k$  activo, mas com uma activação  $A_{nk}(t) = 0.25$ , e com um peso  $w(nk, ni) = -0.5$ . Este nó tem uma ligação inibitória com o nó  $n_i$ , de igual intensidade à ligação existente entre os outros nós. No entanto, a menor activação de  $n_k$  irá fazer com que este tenha uma menor importância no cálculo da propagação para  $n_i$ . Ainda assim, irá contribuir para diminuir a activação propagada para 0.3.

A grande alteração neste método é a alteração do significado das activações e dos pesos para a propagação. Aqui os pesos são os indicadores da activação que o nó  $n_i$



deverá ter, enquanto que as activações dos nós que propagam funcionam como reguladores da intensidade da activação passada para  $n_i$ .

## 5. Experimentação e Resultados

Neste capítulo são descritas os procedimentos e os resultados obtidos na experimentação do modelo. Esta experimentação consistiu em testes gerais de comportamento do modelo (secção 5.2), testes à modelação dos fenómenos psicológicos pretendidos (secção 5.3) e aplicação ao um use-case de criatividade computacional (secção 5.4).

Antes de detalhar essas experiências começamos, na secção 5.1 por fazer uma breve análise aos dados de entrada que serão usados nalgumas dessas simulações.

### 5.1. Análise dos Dados de Entrada

Nesta secção efectuamos uma análise aos dados de entrada que usamos na fase experimental, o que permitirá uma melhor compreensão dos resultados obtidos no treino da rede e nas várias simulações efectuados com estes dados.

Estes dados, extraídos do website [petiscos.com](http://www.petiscos.com)<sup>3</sup>, dizem respeito a conjuntos de ingredientes, usados em receitas culinárias.

Considerando o conjunto total de receitas extraídas, obteve-se um total de 4351 com 490 diferentes ingredientes, que corresponderão a 490 nós no modelo RANs.

A principal característica deste conjunto de dados é a elevada esparsidade dos padrões de entrada, i.e., uma elevada quantidade de elementos nulos nos padrões de entrada. Essa esparsidade é constatada pelo facto de que uma receita contém entre 1 a 24 ingredientes, ou seja, entre 0,2% e 4,9% do total de ingredientes, sendo que em média o número de ingredientes por receita é  $8,78 \pm 3,53$ .

O desenvolvimento desta primeira versão do modelo RANs não foi constrangido por esta particularidade dos dados de entrada, por ambicionar ser um modelo genérico, passível de aplicação em vários domínios. Contudo, esta não deixou de ter um impacto relevante nos resultados dos métodos de treino.

Outra informação que deve ser considerada é a dos ingredientes que aparecem com maior regularidade. Será importante observar o comportamento da rede com diferentes métodos de treino para conceitos muito ou pouco frequentes.

Ingredientes mais frequentes			
	Nome	Número de receitas em que está presente	Percentagem de receitas em que está presente
1	Sal	2373	54,54%
2	Ovo	1728	39,71%
3	Açúcar	1432	32,91%
4	Azeite	1327	30,50%
5	Alho	1307	30,04%

<sup>3</sup> <http://www.petiscos.com/>

6	Farinha	1089	25,03%
7	Manteiga	1062	24,41%
8	Pimenta	1043	23,97%
9	Leite	1009	23,19%
10	Cebola	922	21,19%
11	Água	742	17,05%
12	Fermento	683	15,70%
13	Natas	624	14,34%
14	Óleo	583	13,40%
15	Margarina	538	12,36%
16	Salsa	487	11,20%
17	Vinho Branco	431	9,90%
18	Batata	431	9,90%
19	Limão	415	9,54%
20	Tomate	385	8,85%

Tabela 5 – Dados de Entrada. Ingredientes mais frequentes

Observando a lista de ingredientes mais frequentes, verifica-se que apenas 16 ingredientes aparecem em mais de 10% das receitas, isto é, quase a totalidade (96,9%) dos ingredientes aparece em menos de 10% dos padrões de entrada. De facto, a presença dos ingredientes em receitas varia entre o máximo presente na tabela (sal, 2373 receitas) e ingredientes que aparecem em apenas 1 receita. Em média, um ingrediente aparece em  $77,95 \pm 211,54$  receitas, o que corresponde a apenas 1,8% do total de padrões de entrada.

Sendo que os métodos de aprendizagem são dependentes da correlação entre ingredientes, incluímos também a lista dos pares de ingredientes que mais frequentemente aparecem em conjunto.

<b>Pares de Ingredientes mais frequentes</b>			
<b>Ingrediente 1</b>	<b>Ingrediente 2</b>	<b>Número de receitas com os dois ingredientes</b>	<b>Percentagem de receitas com os dois ingredientes</b>
Alho	Sal	1075	24,70%
Azeite	Sal	1049	24,10%
Pimenta	Sal	978	22,47%
Açúcar	Ovo	951	21,80%
Alho	Azeite	879	20,20%
Farinha	Ovo	823	18,91%
Ovo	Sal	791	18,17%
Cebola	Sal	761	17,49%
Açúcar	Farinha	649	14,91%
Leite	Ovo	638	14,66%
Manteiga	Ovo	619	14,26%

Alho	Pimenta	616	14,15%
Manteiga	Sal	591	13,58%
Fermento	Ovo	590	13,56%
Azeite	Cebola	581	13,35%
Alho	Cebola	578	13,28%
Azeite	Pimenta	572	13,14%
Açúcar	Leite	542	12,45%
Açúcar	Fermento	538	12,36%
Açúcar	Manteiga	536	12,31%

Tabela 6 – Dados de entrada. Pares de ingredientes mais frequentes

## 5.2. Comportamento Geral do Modelo

Nesta secção analisam-se alguns aspectos particulares do modelo. Em particular, é feita uma comparação entre os dois métodos de injeção de activação propostos, e é discutida a utilizada de *thresholds* na propagação da activação.

### Método de Injeção de Activação: Solipsismo Estático VS Dinâmico

Na secção 4.3 foram descritos os métodos de injeção de activação Injeção de Activação Ponderada e Injeção de Activação com Solipsismo Dinâmico, sendo que o primeiro tem um factor de solipsismo estático e o segundo, tal como o nome indica, um factor de solipsismo dinâmico.

Nessa secção foram também descritas algumas vantagens e limitações de cada um dos métodos.

Por um lado a Injeção de Activação Ponderada não permite a modelação de uma situação em que a activação de um dado nó ocorre na ausência de activação externa e activação da camada. Isto decorre do facto de ser utilizado um factor de solipsismo estático que define quanta importância é dada à activação anterior do nó e à activação recebida pelos outros nós da camada. Para modelar uma situação de estabilidade na activação é necessário que o factor de solipsismo seja igual a 1, o que impedirá esse mesmo nó de receber activação dos outros nós.

Neste método o ritmo de reposição acaba por ter uma importância reduzida, sendo que o factor de solipsismo controla em grande parte o decaimento das activações. Exemplificando com uma situação extrema, com um factor de solipsismo = 0.99 e um ritmo de reposição = 0, activamos um nó com activação externa = 1 ( $t=10$ ) para observar o seu decaimento, bem como a recepção de activação por parte dos outros nós.

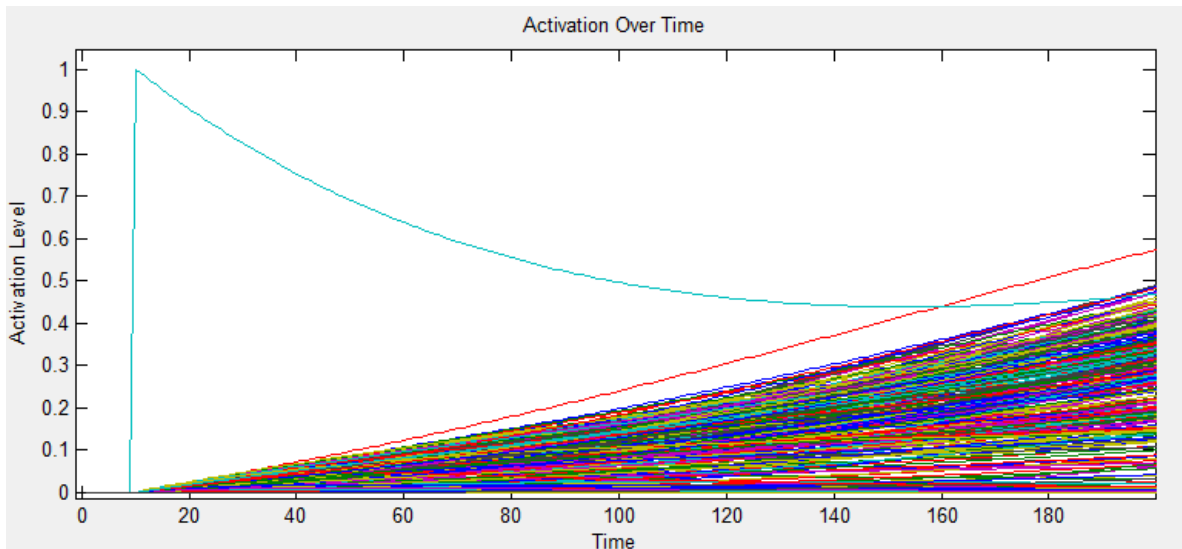


Figura 5 - Injeção de Activação Ponderada

Pode-se observar (Figura 5) que dado o elevado factor de solipsismo, a activação dos restantes nós da rede vai subindo a um ritmo bastante lento.

Realizando a mesma experiência para o método de injeção com solipsismo dinâmico observa-se (Figura 6) que o ritmo de crescimento das activações é bastante mais elevado (note-se que a figura apresenta apenas 10 instantes temporais). No entanto, apesar de o ritmo de reposição ser nulo, o nó activado inicialmente sofre um decaimento de activação. Esse é o problema com do método com o solipsismo dinâmico. Embora consiga modelar uma situação de decaimento nulo, quando o nó recebe activação da camada, a importância que dá à sua anterior activação diminui, o que provoca um decaimento da sua activação total.




Figura 6 - Injeção de Activação com Solipsismo Dinâmico

O fenómeno é observável na seguinte figura (Figura 7) com uma simulação mais simples. A linha vermelha representa um nó activado externamente a 1 no instante  $t=50$ . A sua activação começa a decair lentamente. Quando é activado outro nó que lhe propaga activação (linha tracejada a preto), a activação do primeiro nó cai abruptamente.




Figura 7 – Injecção de Activação com Solipsismo Dinâmico

Conclui-se que o método de injeção com solipsismo dinâmico não é compatível com a simulação dos fenómenos do *Priming* e DRM, sendo que nas seguintes simulações será usado sempre o método de injeção com solipsismo estático.

### Utilização de Thresholds

Como é observável nas figuras anteriores, em que foram utilizados os pesos do método de aprendizagem Influências excitatórias e inibitórias frequencistas, basta que se estimule externamente um nó para que as activações se comecem a propagar pela rede e uma larga quantidade de nós fique activa.

Como é visível na Figura 8, fruto das interações entre os diferentes nós, os níveis de activação vão estabilizando ao longo do tempo, até rede estabilizar num ponto fixo, i.e., um estado cognitivo em que as activações não sendo externamente destabilizadas permanecem estáveis.




Figura 8 – Convergência das ativações para um ponto fixo

Esse é um comportamento interessante, sendo que esse ponto fixo pode ser interpretado como a convergência da rede para um atrator ponto-fixo decorrente dos dados aprendidos. No entanto, a vasta quantidade de nós activa dificilmente nos permite extrair uma interpretação ao nível cognitivo do estado em que a rede estabiliza.

Também com o método de treino Activation Correlation Assimétrica Ponderada, se observa um fenómeno idêntico, em que apenas difere o estado para o qual a rede converge.

Uma forma de evitar esse fenómeno é através da utilização de *thresholds*. A seguinte figura demonstra os resultados de uma simulação idêntica à anterior, com a aplicação de um *threshold* de 0.5 para todos os nós. Com essa aplicação apenas o nó activado externamente propaga activação, sendo o nível de activação dos outros nós uma influência exclusiva do nó activado.




Figura 9 – Aplicação de *thresholds*

Um dos seguintes desafios no desenvolvimento do modelo RANs é o da criação de conceitos numa camada de nível de abstracção superior, que corresponderão a um estado cognitivo na camada agora desenvolvida. Esses conceitos poderão representar a conjunção de vários conceitos, e o momento para essa criação poderá ser o do atingimento de um ponto fixo. Para isso, no entanto, será necessário aprofundar os métodos de treino e propagação de modo a aprimorar as relações os conceitos e a forma como estes ficam activos, ou aplicar fenómenos de regulação que permitam a obtenção de pontos fixos susceptíveis de serem interpretados semanticamente como um novo conceito. Essas formas de regulação poderão passar pelo uso de *thresholds* dinâmicos ou a regulação inibitória que permita restringir a propagação excessiva de activação.

### 5.3. Fenómenos Psicológicos

Nesta secção serão descritos os procedimentos realizados para avaliar a capacidade do modelo em modelar os fenómenos do *Priming* e DRM e serão demonstrados alguns resultados obtidos nessas experiências.

O modelo usado tem como método de injeção de activação o método denominado Injecção de Activação Ponderada e o método de propagação Propagação Feedforward.

Para isolar estes componentes dos métodos de aprendizagem, e da especificidade dos dados de entrada usados foi realizado um conjunto de testes em que os pesos da rede são seleccionados manualmente.

Foi efectuada ainda uma variação dos vários parâmetros do modelo que permitem estudar e comparar a sua influência no comportamento da rede e na modelação dos fenómenos, designadamente, o ritmo de reposição e o factor de solipsismo.

Os testes efectuados englobam, geralmente, a comparação da activação de dois nós (e.g., nó que sofreu priming e nó que não sofreu priming). Estes serão designados por nós origem (nós onde é injectada activação externa) e nós alvo (nós onde se pretende verificar os efeitos dos fenómenos).

Essa comparação será feita através de dois critérios. O primeiro tem em conta a intensidade ou magnitude da resposta a um estímulo, que corresponde no modelo RANs ao nível de activação atingido pelo nó. Esta activação poderá ser proveniente de um estímulo sensorial (exterior à rede), de outros nós, ou de uma conjugação dos dois componentes. Sendo útil comparar de uma forma proporcional as activações, esta medida será o rácio entre os dois valores máximos de activação obtidos durante as simulações e será denominado INT (A,B) (intensidade da resposta do nó A em relação à resposta do nó B).

$$INT(A, B) = \frac{\max(Act_A(\text{tempo da simulação}))}{\max(Act_B(\text{tempo da simulação}))}$$

Além da magnitude da resposta a um estímulo, convém também ter em conta a extensão temporal da resposta, isto é, o número de instantes em que o nível de activação do nó alvo é positivo. Sendo que no modelo RANs o nível de activação sofre geralmente



um decaimento exponencial, contendo durante longos períodos de tempo valores residuais, foi definido um limiar para estas simulações onde a activação passa a ser insignificante. Esse valor é 0.001, um milésimo da activação máxima permitida.

A segunda medida será então a diferença entre as durações temporais das respostas dos nós e será denominada DUR (A,B) (diferença entre duração temporal da resposta do nó A e do nó B).

$$DUR(A,B) = \text{find}(Act_A(\text{tempo da simulação}) < 0.001) \\ - \text{find}(Act_B(\text{tempo da simulação}) < 0.001)$$

### 5.3.1. Priming

#### 5.3.1.1. Priming Perceptual no mesmo nó

No primeiro e mais simples teste de *Priming*, o objectivo é verificar que a exposição prévia a um estímulo igual, tem uma influência positiva na resposta a esse estímulo quando comparado com um estímulo único.

No modelo RANs, isto traduz-se no teste à capacidade da rede em acumular a activação de um nó, tornando a resposta a dois estímulos consecutivos de maior intensidade do que a de um único estímulo através dessa mesma acumulação.

#### Parâmetros Variáveis

##### Modelo:

Ritmo de Reposição, com os seguintes valores {0.01, 0.05, 0.1}

Factor de Solipsismo, de 0.1 a 0.9, com um incremento de 0.1

##### Simulação:

Intensidade do estímulo, de 0.25 a 1, com um incremento de 0.25

Intervalo entre estímulos, com os seguintes valores {1, 2, 4, 8}

#### Procedimento (Figura 10)

- Sem *Priming*:
  - Injecção de padrão no nó alvo com a intensidade defininda no instante  $t = 50$
- Com *Priming*:
  - Injecção de padrão no nó alvo com a intensidade defininda no instante  $t = 50$  - intervalo
  - Injecção de padrão no nó alvo com a intensidade defininda no instante  $t = 50$




Figura 10- Procedimento para *Priming* perceptual no mesmo nó

As seguintes tabelas mostram os resultados médios obtidos em função do ritmo de reposição e do factor de solipsismo aplicado.

Medição de INT (Alvo com priming, Alvo sem priming)

Ritmo de Reposição	Factor de Solipsismo								
	0,1	0,2	0,3	0,4	0,5	0,6	0,7	0,8	0,9
0,01	1,0123	1,0269	1,0442	1,0650	1,0904	1,1223	1,1639	1,2213	1,3051
0,05	1,0117	1,0256	1,0419	1,0614	1,0848	1,1138	1,1509	1,2005	1,2707
0,1	1,0110	1,0240	1,0392	1,0570	1,0782	1,1039	1,1360	1,1777	1,2342

Tabela 7 - Medição média de INT em função do ritmo de reposição e factor de solipsismo

Através da observação dos resultados relativos à intensidade das respostas com e sem priming, é verificável que todas as configurações do modelo produzem, em média, uma resposta mais intensa no nó com priming. Também, como seria de esperar, o factor de decaimento tem uma influência negativa nessa intensidade, levando a que mais activação seja perdida desde o momento do priming até ao momento do segundo estímulo.

Analisando na Tabela 7 a influência do factor de solipsismo, é observável que quanto maior este é, mais forte é, em média, a resposta do nó alvo sob o efeito de priming. Isto deve-se a uma maior acumulação de activação entre os estímulos. Na Tabela 8, podemos verificar que, também fruto dessa acumulação, a diferença temporal da resposta é geralmente superior para factores de solipsismo mais elevados, bem como a influência negativa do decaimento.

Medição de DUR (Alvo com priming, Alvo sem priming)

Ritmo de Reposição	Factor de Solipsismo								
	0,1	0,2	0,3	0,4	0,5	0,6	0,7	0,8	0,9
0,01	0,025	0,025	0,025	0,2	0,075	0,2	0,275	0,925	2,4
0,05	0,025	0	0,075	0,025	0,225	0,1	0,275	0,525	1,475
0,1	0	0,025	0	0,05	0,125	0,2	0,55	0,5	0,975

Tabela 8 - Medição média de DUR em função do ritmo de reposição e factor de solipsismo

Para tornar claro o comportamento do modelo nas situações mais extremas de solipsismo apresentam-se de seguida imagens referentes à activação, ao longo do tempo, dos dois nós, com intervalos entre estímulos de um e dois instantes, e com factores de solipsismo 0.1 e 0.9. O ritmo de reposição para todas as imagens é 0,01.

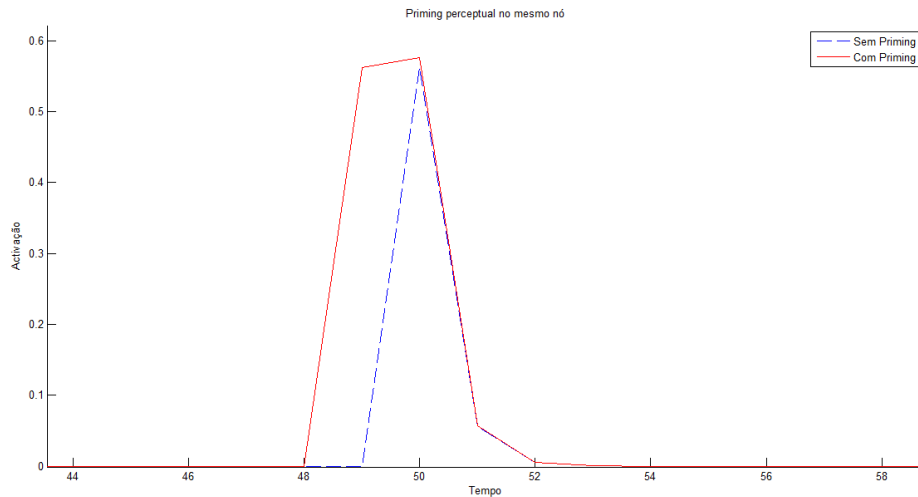


Figura 11 - *Priming*. Solipsismo = 0.1, Intensidade do estímulo = 0.75, Intervalo entre estímulos = 1




Figura 12 - *Priming*. Solipsismo = 0.9, Intensidade do estímulo = 0.75, Intervalo entre estímulos = 1




Figura 13 - *Priming*. Solipsismo = 0.1, Intensidade do estímulo = 0.75, Intervalo entre estímulos = 2




Figura 14 - *Priming*. Solipsismo = 0.9, Intensidade do estímulo = 0.75, Intervalo entre estímulos = 2

### 5.3.1.2. Priming Conceptual

Com este teste pretende-se observar a capacidade do modelo em representar fenómenos de priming conceptual, i.e., facilitar a resposta a um determinado estímulo quando precedido de outro estímulo associado ao primeiro através de uma relação de semelhança ou associação ao nível semântico.

Utilizando o exemplo citados na descrição do fenómeno de priming, este teste corresponderá a testar a resposta ao conceito “apple”, com ou sem o estímulo precedente “fruit”.

No modelo RANs, isto traduzir-se-á na comparação da resposta à injeção de um único padrão num dado nó com a mesma injeção precedida de um estímulo num nó semanticamente relacionado. Este processo é esquematizado na figura 15.

O que se espera é que a activação injectada do nó origem se propague para o nó alvo, através da ligação existente entre os dois e caracterizada pelo peso  $w(O,A)$ , e que essa activação propagada se acumule no nó alvo, proporcionando uma resposta

ligeiramente superior ao nível da magnitude e extensão temporal do que a que existiria sem priming.

**Parâmetros Variáveis**

**Modelo:**

Factor de Solipsismo, de 0.1 a 0.9, com um incremento de 0.1

Pesos das ligações, de 0.25 a 1, com um incremento de 0.25

**Simulação:**

Intensidade do estímulo, de 0.25 a 1, com um incremento de 0.25

Intervalo entre estímulos, com os seguintes valores {1, 2, 4, 8}

**Procedimento (Figura 15)**

- Sem Priming:
  - Injecção de padrão no nó alvo com a intensidade definida no instante  $t = 50$
- Com Priming:
  - Injecção de padrão no nó origem com a intensidade definida no instante  $t = 50 - \text{intervalo}$
  - Injecção de padrão no nó alvo com a intensidade definida no instante  $t = 50$




Figura 15 - Procedimento para Priming conceptual

Medição de INT (Alvo com priming, Alvo sem priming)

Intervalo	Factor de Solipsismo								
	0,1	0,2	0,3	0,4	0,5	0,6	0,7	0,8	0,9
1	1,1051	1,0934	1,0817	1,0700	1,0584	1,0467	1,0350	1,0233	1,0117
2	1,0208	1,0371	1,0486	1,0556	1,0579	1,0555	1,0486	1,0370	1,0208
4	1,0004	1,0029	1,0086	1,0174	1,0284	1,0392	1,0467	1,0465	1,0331
8	1,0000	1,0000	1,0001	1,0009	1,0034	1,0098	1,0216	1,0366	1,0417

Tabela 9 - Medição média de INT em função do intervalo entre estímulos e factor de solipsismo

Medição de DUR (Alvo com priming, Alvo sem priming)

Intervalo	Factor de Solipsismo								
	0,1	0,2	0,3	0,4	0,5	0,6	0,7	0,8	0,9

1	0,5	0,4375	0,6875	1,0625	1,375	1,875	2,5	4,3125	9,0625
2	0,25	0,1875	0,125	0,6875	0,875	1,25	1,9375	3,6875	8,3125
4	0	0	0	0,1875	0,5625	0,5625	1	2,6875	7,125
8	0	0	0	0	0	0,1875	0,1875	1,375	5,375

Tabela 10 – Medição média de DUR em função do intervalo entre estímulos e factor de solipsismo

Através da análise das medidas de intensidade e duração das respostas é possível tirar várias conclusões. Em primeiro lugar, verifica-se que algumas das configurações não são capazes de modelar o priming conceptual com um intervalo entre estímulos igual ou superior a oito instantes. Concretamente, instâncias do modelo com solipsismo inferior ou igual a 0,2 não apresentam um aumento na resposta do conceito sob o efeito de priming, devido ao rápido decaimento da activação do nó origem. Ainda ao nível da intensidade da resposta, para intervalos maiores (quatro e oito), o crescimento do factor de solipsismo ajuda à potenciação do fenómeno, exactamente pelo efeito que tem de não permitir mudanças bruscas no nível de activação, o que implica a propagação de activação durante mais tempo, do nó origem para o nó alvo. Mas para intervalos menores esse efeito torna-se contraproducente, pois acaba por tornar o nó mais resistente à mudança inicial, razão pela qual para simulações com apenas um instante de intervalo entre estímulos, o efeito de priming é mais visível para o factor de solipsismo mais baixo, e para simulações com dois instantes de intervalo o factor de solipsismo mais eficaz é 0.5 (umas das simulações com esta configuração é mostrada na Figura 16), que acaba por atingir um equilíbrio entre a activação recebida pelo nó alvo no primeiro instante, e um decaimento da activação do nó origem não muito rápido permitindo que este propague ainda uma activação significativa para o nó alvo no segundo instante, quando também o nó alvo é estimulado.

Ao nível da resposta temporal, é visível a influência do número de instantes de intervalo e do factor de solipsismo, sendo que para intervalos de oito instantes, apenas factores de solipsismo superiores a 0,5 conseguem proporcionar uma resposta mais duradoura no tempo. Como seria de esperar, os factores de solipsismo mais elevados conduzem a uma resposta mais extensa temporalmente, sendo que a pouca intensidade demonstrada pelo modelo com o factor de solipsismo 0.9 é balanceada com uma resposta, em média, nove instantes de tempo mais extensa.




Figura 16 - Priming. Solipsismo = 0.5, Intensidade do estímulo = 0.75, Peso = 1, Intervalo entre estímulos = 2

Outro factor importante no priming conceptual é o peso entre as ligações. A seguinte tabela apresenta a média de todas as simulações, em função do peso das ligações entre o nó origem e nó alvo.

Medição de INT (Alvo com priming, Alvo sem priming) em função dos pesos

Pesos			
0,25	0,5	0,75	1
1,0138634	1,0277028	1,0414949	1,0552177

Tabela 11 - Medição média de INT em função dos pesos

É possível observar um crescimento da medida INT com o aumento dos pesos, que varia entre uma intensidade média acrescida de 1,38% para os pesos iguais a 0,25 e de 5,5% para os pesos máximos na rede, iguais a um.

O valor máximo de INT obtido para uma simulação foi de 1.3374, com um solipsismo de 0.1, intervalo entre estímulos de um instante, com um estímulo de intensidade = 1 e um peso = 1 (Figura 17). Ao nível de DUR, o máximo obtido foi de 14 instantes e corresponde ao factor de solipsismo 0.9, intervalo entre estímulos de um instante, estímulo de intensidade = 0.25 e um peso = 1 (Figura 18).




Figura 17 - Máxima DUR obtida. Solipsismo = 0.9, Intensidade do estímulo = 1, Peso = 1, Intervalo entre estímulos = 1




Figura 18 - Máxima INT obtida. Solipsismo = 0.1, Intensidade do estímulo = 0.25, Peso = 1, Intervalo entre estímulos = 1

### 6.3.1.3. Priming Conceptual e Perceptual

Neste teste pretende-se incorporar os dois tipos de priming numa só experiência.

Este procedimento envolverá a estimulação prévia de um nó alvo, seguida de uma estimulação de um nó origem que está semanticamente relacionado com o nó alvo e outro nó. O relacionamento do nó origem com os dois nós alvo é de igual intensidade. Pretende-se, assim, observar se a acumulação de activação decorrente do priming do nó alvo fará com que este atinja uma activação superior à do outro alvo, quando o nó origem propagar (a mesma) activação para os dois.



**Parâmetros Variáveis**

**Modelo:**

Factor de Solipsismo, de 0.1 a 0.9, com um incremento de 0.1  
 Pesos das ligações, de 0.25 a 1, com um incremento de 0.25

**Simulação:**

Intensidade do estímulo, de 0.25 a 1, com um incremento de 0.25  
 Intervalo entre estímulos, com os seguintes valores {1, 2, 4, 8}

**Procedimento (Figura 19)**

- Injecção de padrão no nó alvo com a intensidade definida no instante  $t = 50 - \text{intervalo}$
- Injecção de padrão no nó origem com a intensidade definida no instante  $t = 50$

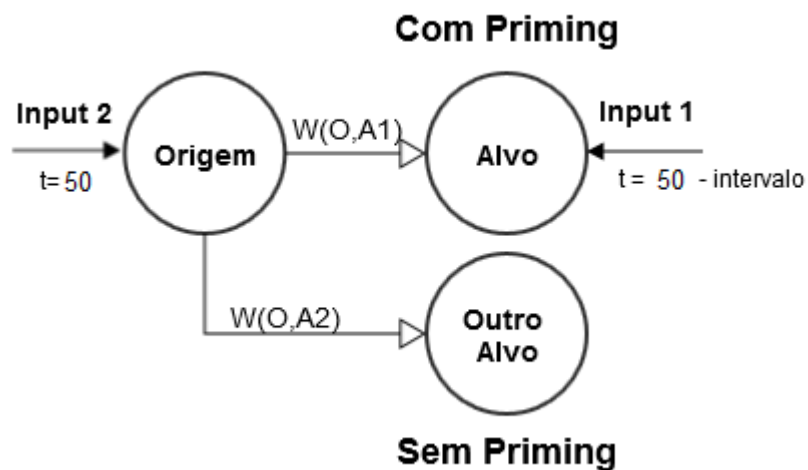


Figura 19 - Procedimento para *Priming* perceptual e conceptual

Medição de INT (Alvo com priming, Alvo sem priming) e DUR (Alvo com priming, Alvo sem priming)

Medida	Factor de Solipsismo								
	0,1	0,2	0,3	0,4	0,5	0,6	0,7	0,8	0,9
INT	1,0126	1,0990	1,2747	1,5974	2,1705	2,7404	3,7446	5,2603	7,9371
DUR	1,7188	2,8281	4,4063	5,9844	9,1094	12,7500	18,6719	29,0156	58,0938

Tabela 12 - Medição média de INT e DUR em função do factor de solipsismo

Nesta simulação fica bem patente aquilo que pode proporcionar um maior factor de solipsismo, que no valor mais elevado (0.9) torna a resposta do nó alvo sob priming

perceptual e conceptual ao estímulo no nó origem, em média aproximadamente oito vezes superior àquela verificada apenas com o efeito de priming conceptual. Também ao nível da DUR, as diferenças são bem esclarecedoras.

Em seguida, analisa-se em mais detalhe a medida de INT, para cada tipo de intervalo.

Medição de INT (Alvo com priming, Alvo sem priming) em relação ao número de instantes de intervalo entre estímulos

Intervalo	Factor de Solipsismo								
	0,1	0,2	0,3	0,4	0,5	0,6	0,7	0,8	0,9
1	1,0458	1,3536	1,9276	2,8186	4,1565	5,2384	6,7131	8,3435	10,4267
2	1,0045	1,0408	1,1573	1,5012	2,2633	3,1728	4,6534	6,6080	9,2902
4	1,0000	1,0016	1,0139	1,0682	1,2479	1,5023	2,4033	4,1647	7,3753
8	1,0000	1,0000	1,0001	1,0017	1,0144	1,0482	1,2087	1,9250	4,6562

Tabela 13 - Medição média de INT em função do intervalo entre estímulos e factor de solipsismo

Pela observação dos resultados referentes à medida INT constata-se que com um factor de solipsismo igual ou superior a 0,5 é possível obter uma magnitude de resposta pelo menos 1% superior com priming, para intervalos de oito instantes.

Como o factor de solipsismo mais elevado, conseguem-se magnitudes entre 4,65 e 10,43 vezes mais elevadas do que sem o efeito de priming (Figura 20, Figura 21).

Pela observação dos resultados referentes à medida INT, é visível, mais uma vez, que para factores de solipsismo muito baixos, a resposta ao estímulo não é potenciada, pelo facto de o decaimento da activação ser demasiado rápido. Isto acontece particularmente quando o intervalo entre estímulo é grande (Figura 22, Figura 23).




Figura 20 - Solipsismo = 0,9, Intensidade do estímulo = 0,75, Peso = 1, Intervalo entre estímulos = 1

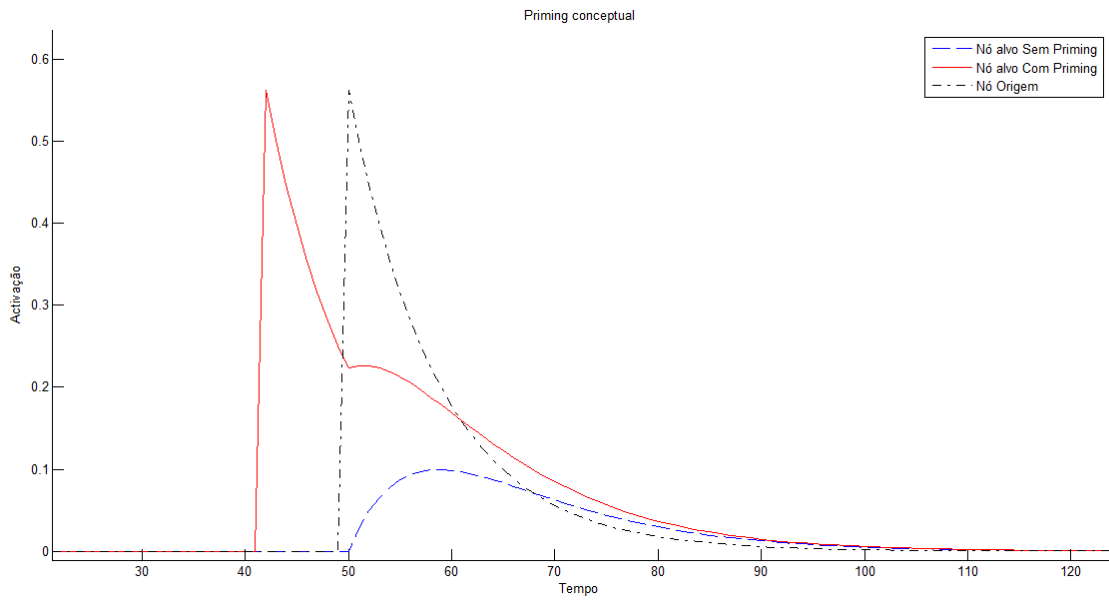


Figura 21 - Solipsismo = 0.9, Intensidade do estímulo = 0.75, Peso = 1, Intervalo entre estímulos = 8




Figura 22 - Solipsismo = 0.1, Intensidade do estímulo = 0.75, Peso = 1, Intervalo entre estímulos = 1




Figura 23 - Solipsismo = 0.1, Intensidade do estímulo = 0.75, Peso = 1, Intervalo entre estímulos = 8

Pelos resultados obtidos, conclui-se que o modelo desenvolvido possibilita a modelação deste fenómeno. O factor de solipsismo é de vital importância e poderá ser útil na simulação de patologias em que os efeitos do *Priming* não são sentidos.

### 5.3.2. Paradigma Deese-Roediger-McDermott

O teste do paradigma Deese-Roediger-McDermott, consiste na injeção de um determinado número de padrões à rede, sendo que todos os nós activos nesses padrões estão semanticamente relacionados com um nó alvo. A esse conjunto de nós chamaremos nós origem. Essa relação traduz-se, no modelo RANs, nos pesos das ligações entre os nós origem e o nó alvo.

#### Parâmetros Variáveis

##### Modelo:

- Ritmo de Reposição, com os seguintes valores = [0.01, 0.05, 0.1]
- Factor de Solipsismo, de 0.1 a 0.9, com um incremento de 0.1
- Pesos das ligações, de 0.1 a 1, com um incremento de 0.1
- Número de nós origem, de 2 a 10, com um incremento de 1

##### Simulação:

- Intensidade do estímulo, de 0.25 a 1, com um incremento de 0.25
- Intervalo entre estímulos, com os seguintes valores {0, 1, 2, 4, 8}

#### Procedimento (Figura 24)

- Injeção de N padrões nos nós alvo com a intensidade definida nos instantes  $t = 50 - (\text{intervalo} * (n-1))$

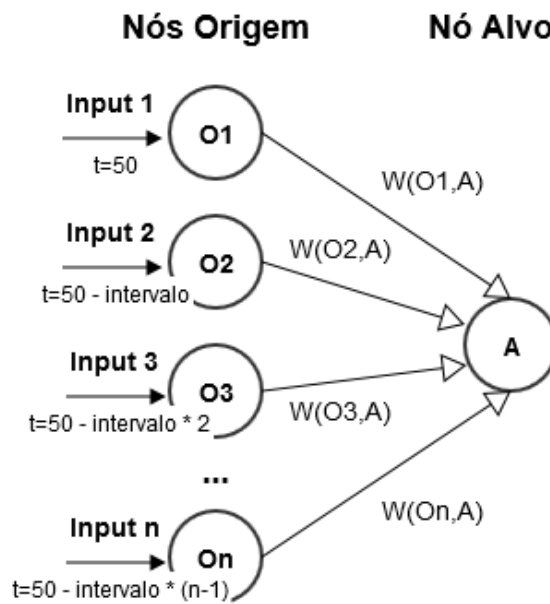


Figura 24 - Procedimento para Paradigma Deese-Roediger-McDermott

Os resultados para a média de todas as simulações efectuadas são apresentados nas seguintes tabelas, em função do ritmo de reposição e factor de solipsismo aplicados.

Medição de INT (Alvo, Origem)

Ritmo de Reposição	Factor de Solipsismo								
	0,1	0,2	0,3	0,4	0,5	0,6	0,7	0,8	0,9
0,01	0,4759	0,4445	0,4186	0,4006	0,394	0,4077	0,4261	0,451	0,4687
0,05	0,4751	0,4424	0,4142	0,3923	0,3785	0,3813	0,3826	0,381	0,3418
0,1	0,4741	0,4399	0,4091	0,3829	0,362	0,3524	0,3405	0,3172	0,2508

Tabela 14 - Medição média de INT em função do ritmo de reposição e factor de solipsismo

Medição de DUR (Alvo, Último Nó Origem)

Ritmo de Reposição	Factor de Solipsismo								
	0,1	0,2	0,3	0,4	0,5	0,6	0,7	0,8	0,9
0,01	0,2069	0,2611	0,3521	0,5437	0,7257	0,9639	1,3563	2,2528	4,5729
0,05	0,1944	0,2326	0,2958	0,4479	0,6132	0,834	1,1972	1,6417	2,6993
0,1	0,1792	0,1896	0,2931	0,3979	0,6042	0,7486	1,0778	1,2806	1,616

Tabela 15 - Medição média de DUR em função do ritmo de reposição e factor de solipsismo

Como seria de esperar, uma reposição mais forte provoca uma resposta menor em magnitude e acentuadamente menor em termos de duração temporal. Já o factor de solipsismo, que pode ser visto como uma resistência à mudança tem uma influência

interessante nos resultados para o fenómeno DRM. Para o valor de reposição mais baixo, a magnitude da resposta não tem um comportamento monótono, sendo decrescente até ao valor de solipsismo 0.5 e crescente a partir desse valor.

As medições para a duração temporal da resposta ajudam a explicar esse fenómeno. Para factores de solipsismo muito baixos, o nó dá uma grande importância à activação recebida dos nós origem, respondendo de uma forma rápida e acentuada aos estímulos. No entanto, o mesmo comportamento é verificado na fase de decaimento: a activação do nó decai rapidamente originando uma resposta com uma menor duração.

Pelo contrário, factores de solipsismo mais elevados proporcionam transições entre estados mais suaves, o que leva a uma resposta temporalmente mais duradoura, mas permitindo em média obter respostas com magnitude semelhante à de factores de solipsismo baixos.

Tendo em conta que os valores obtidos para a magnitude da resposta representam que, no melhor dos casos, a resposta do conceito alvo atinge apenas uma magnitude correspondente a 47,5% da activação dos conceitos origem, iremos em seguida detalhar a análise, verificando para que determinados intervalos, número de nós de origem, força de estímulos e pesos é possível obter magnitudes semelhantes às dos conceitos origem.

Nesta análise iremos apenas considerar as instâncias do modelo com o ritmo de reposição 0.01 e solipsismo 0.1 e 0.9.

Em primeiro lugar, verificaremos qual o número de nós e intervalo entre estímulos necessário para que as medidas INT e DUR atinjam valores satisfatórios.

#### Medição de INT (Alvo, Origem), para simulações com solipsismo = 0.1

Intervalo	Número de Nós Origem								
	2	3	4	5	6	7	8	9	10
0	0,4693	0,6701	0,8484	1,0081	1,1528	1,2854	1,4078	1,5216	1,6282
1	0,2913	0,2983	0,2992	0,2993	0,2993	0,2993	0,2993	0,2993	0,2993
2	0,2509	0,251	0,251	0,251	0,251	0,251	0,251	0,251	0,251
4	0,2439	0,2439	0,2439	0,2439	0,2439	0,2439	0,2439	0,2439	0,2439

Tabela 16 - Medição média de INT em função do intervalo entre estímulos e número de nós origem

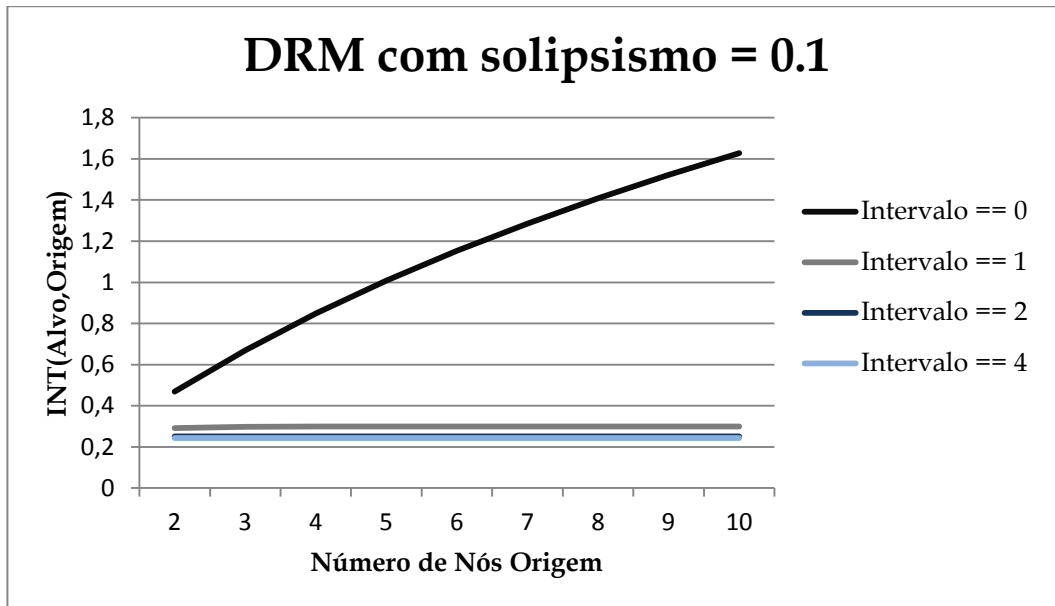


Figura 25 - Medição média de INT em função do intervalo entre estímulos e número de nós origem

Pela análise dos resultados, verifica-se que a activação do nó alvo passa a ser superior à injectada nos nós origem quando o total de nós origem é igual ou superior a cinco, no caso em que todos os nós são activos simultaneamente (Figura 25, exemplo de simulação na Figura 26).




Figura 26 - DRM. Solipsismo = 0.1, Intensidade do estímulo = 0.75, Pesos = 1, Intervalo entre estímulos = 0, Número de nós origem = 5

Para este factor de solipsismo, activar os nós origem com intervalos de um ou mais instantes, leva a uma não acumulação da activação no nó alvo, independentemente do número de nós origem.

Desta forma com um factor de solipsismo tão reduzido, apenas é possível modelar o paradigma DRM com uma injeção simultânea de todos os estímulos.

Medição de INT (Alvo, Origem), para simulações com solipsismo = 0.9

Intervalo	Número de Nós								
	2	3	4	5	6	7	8	9	10
0	0,1914	0,2797	0,3621	0,4392	0,5114	0,5795	0,6439	0,705	0,7633
1	0,1915	0,2803	0,3636	0,442	0,5152	0,5847	0,65	0,7112	0,7695
2	0,191	0,2784	0,3589	0,4328	0,5003	0,5607	0,6157	0,664	0,7073
4	0,188	0,2674	0,3343	0,3884	0,4305	0,4633	0,4871	0,5041	0,5169

Tabela 17 - Medição média de INT em função do intervalo entre estímulos e número de nós origem




Figura 27 - Medição média de INT em função do intervalo entre estímulos e número de nós origem

Com um factor de solipsismo elevado, verifica-se uma acumulação das activações propagadas pelos nós origem, levando a um crescimento assintótico da medida INT. Para o maior intervalo usado (quatro instantes entre estímulos), com o crescimento do número de nós origem a medida INT tende para 0,55, o que indica um intervalo demasiado grande para a acumulação das activações (Figura 27).

Não tendo o número de nós origem sido suficiente para, em média, nas simulações com intervalos menores se verificar para que valor tende a medida INT, nem em que momento se aproxima de 1, foram extendidas estas simulações para um maior número de nós origem.



Intervalo	Número de Nós Origem										
	10	11	12	13	14	15	16	17	18	19	20
0	0,7633	0,819	0,8723	0,9235	0,9728	1,0203	1,0663	1,1107	1,1537	1,1954	1,2359
1	0,7695	0,8244	0,8757	0,9246	0,9708	1,0139	1,0541	1,0925	1,1285	1,1622	1,1935
2	0,7073	0,7453	0,778	0,8067	0,8318	0,8531	0,8712	0,8863	0,899	0,9098	0,9192

Tabela 18 - Medição média de INT em função do intervalo entre estímulos e número de nós origem




Figura 28 - Medição média de INT em função do intervalo entre estímulos e número de nós origem

Para intervalos de dois instantes entre estímulos, a resposta do conceito alvo não chega a ser igual à dos conceitos origem, mesmo com mais de dez nós de origem. No entanto a medida INT estabiliza em valores superiores a 0.9, com aproximadamente vinte nós, o que pode ser considerado suficiente para modelar com sucesso o DRM (Figura 28). Para intervalos entre estímulos com um instante ou para estímulos simultâneos, o conceito alvo tem uma resposta superior à dos conceitos origem a partir de um conjunto de origem com quinze nós. Tendo em conta que esta medida é uma média das simulações efectuadas com diferentes pesos e diferentes forças de estímulos, haverá casos em que o fenómeno consegue ser representado com uma menor quantidade de nós origem.




Figura 29 - Solipsismo = 0.9, Intensidade do estímulo = 0.75, Pesos = 1, Intervalo entre estímulos = 0, Número de nós origem = 10

Para estímulos simultâneos, com intensidades = 0.75, dez nós origem são suficientes para que INT seja maior que 1, ou seja, para que a resposta do nó alvo ultrapasse o pico de activação obtido pelos nós origem (Figura 29).

Seria intuitivo pensar que com uma força de estímulo = 1, o fenómeno se verificasse mais facilmente. Contudo, essa situação não se verifica. A resposta do nó alvo é de facto superior nesse caso (atinge valores próximos de 0.7, enquanto que no caso anterior apenas se aproxima de 0.6), mas é menor quando comparada com a activação dos nós origem. Esta situação decorre do uso da função sigmóide como função de activação, que torna a relação entre activação total propagada para um nó e a sua resposta não linear (Figura 30).




Figura 30 - Solipsismo = 0.9, Intensidade do estímulo = 1, Pesos = 1, Intervalo entre estímulos = 0, Número de nós origem = 10

De facto, com esta configuração do modelo, para um nó obter a activação máxima através de propagação dentro da camada, teria de ter um factor de solipsismo igual a zero,

dando total importância à activação vinda dos outros nós (e seria necessário também que o valor dessa activação após ser aplicada a função sigmóide fosse 1), o que implicaria a total perda da activação no instante seguinte.

Para estímulos não simultâneos, de intensidade 0.75, um conjunto de 10 nós é também suficiente para que a medida INT seja superior a 1, tanto para intervalos de um (Figura 31) como de dois instantes (Figura 32), nesta configuração com um solipsismo = 0.9.




Figura 31 - Solipsismo = 09, Intensidade do estímulo = 0.75, Pesos = 1, Intervalo entre estímulos = 1, Número de nós origem = 10




Figura 32 - Solipsismo = 0.9, Intensidade do estímulo = 0.75, Pesos = 1, Intervalo entre estímulos = 2, Número de nós origem = 10

Pelos resultados obtidos conclui-se que a estrutura do modelo desenvolvida possibilita a modelação de paradigma DRM, em que a activação acumulada no nó alvo pode ser interpretada como uma falsa memória. O factor de solipsismo é um parâmetro decisivo na modelação deste fenómeno e a sua variação poderá ser utilizada na representação de casos em que determinada pessoa apresenta ou não a ocorrência de falsas memórias no paradigma DRM.

### 5.3.2.1. Aplicação com treino da rede

Para testar por completo a aplicabilidade do modelo na modelação do paradigma DRM, foi desenvolvida uma experiência semelhante à anterior, incluindo desta vez os nós representativos de todos os ingredientes e os pesos obtidos através do treino com o método denominado “Influências excitatórias e inibitórias frequencistas”.

Tendo obtidos os melhores resultados no teste anterior com a configuração do modelo com um factor de solipsismo = 0.9 e um ritmo de reposição = 0.01, essa configuração foi mantida. Os estímulos aplicados nos nós origem são de intensidade 0.75.

Dado o comportamento da rede demonstrado na secção 5.2, em que sem a utilização de thresholds a activação dos nós converge para um ponto fixo, foram incluídos thresholds nesta simulação, o que limitará a propagação de activação quando o nível for inferior a 0.5.

Como o número de nós origem é condicionado pelas ligações existentes, este foi fixado em 10 nós.

O procedimento consiste em encontrar, para cada nó  $n_i$ , os maiores pesos positivos  $w(n_j, n_i)$ , ou seja, o conjunto de dez ingredientes mais fortemente relacionado com cada ingrediente. De seguida, aplica-se a procedimento efectuado na experiência anterior.

Convém salientar, que as ligações entre todos os nós continuarão a ser consideradas, pelo que existirá propagação e inibição entre os diferentes nós, e não apenas directamente entre os nós origem e o nó alvo.

Nestas condições foram encontrados 483 nós, ou seja, apenas sete nós não continham o número suficiente de ligações positivas de entrada, sendo que entre os 483 nós escolhidos a força média destas ligações é de 0.2665.

As seguintes tabelas sumarizam os resultados obtidos, para as medidas INT e DUR, de acordo com o intervalo em que se insere a média dos pesos das ligações de entrada.

#### Medição de INT (Alvo, Origem) e DUR (Alvo, Origem)

Medida Média	Média dos Pesos				
	]0-0.2]	]0.2-0.4]	]0.4-0.6]	]0.6-0.8]	]0.8-1]
INT	0.0967	0.1695	0.2768	0.3715	0.4699
DUR	-19.6962	-14.7588	-10.1695	-7.4000	-6

Tabela 19 - Medição média de INT e DUR em função do intervalo em que se situa a média dos pesos

Como é possível observar, a magnitude da resposta do nó alvo consegue apenas atingir pequenas fracções da activação obtida pelos nós origem. Também a duração da resposta é sempre inferior à do último nó origem a ser estimulado.

No melhor caso observado, a média dos pesos das ligações seleccionadas é de 0.9, INT = 0.4884 e DUR = -6. Este caso particular não corresponde ao melhor conjunto de pesos (existem casos de ligações médias de 0.9471 em que INT=0.4629 e DUR=-6), mas a obtenção do melhor resultado é fruto das interacções que ocorrem na rede desde a activação do primeiro nó origem.

Contudo, o factor mais decisivo na obtenção destes resultados é a aplicação de thresholds. Estes limitam a propagação dos nós origem para o nó alvo, a partir do momento em que a activação cai para valores inferiores ao threshold.

Deste ponto de vista apresentam-se três soluções: a mais imediata é a procura de um valor de threshold que maximize a modelação do fenómeno, evitando ainda assim a convergência da rede para um ponto fixo.

Realizando a experiência com a aplicação de um threshold = 0.1 para todos os nós, é possível evitar a convergência das activações em 106 casos (22%).

Analisando esses casos, em que a média da medida INT sobe para 0.5122 e DUR para 4.1887, verificam-se já três casos em que INT > 1 e 78 casos em que DUR > 0.

Outras alternativas a explorar são ou o uso de mecanismos de regulação para evitar a convergência dos valores de activação, que podem incidir, por exemplo, em thresholds dinâmicos diferentes para cada um dos nós, ou a experimentação de outros métodos de treino e propagação que possam modelar o fenómeno, evitando o comportamento referido.

## 5.4. Use-Case de Criatividade

### Procedimento

Para simular o fenómeno da criatividade, foi usado o seguinte procedimento:

Como ponto de partida para a selecção do primeiro ingrediente, consideramos as probabilidades individuais de cada nó, isto é, o grau de confiança para a presença de cada nó numa receita. Esta probabilidade é dada pelo número de vezes que o nó esteve presente numa receita, dividido pelo total de receitas aprendidas pela rede.

$$P(N_i) = \frac{\# N_i}{\# Total}$$

Como este conjunto de probabilidades não é independente, i.e., a sua soma não corresponde a 1, é calculada a soma de todas as probabilidades e dividida cada uma destas pela soma, para que passem a totalizar 1. Desta forma, podemos associar a cada ingrediente um intervalo para a sua escolha, de acordo com a sua probabilidade:

$$Escolha (N_1) = \left[ 0 ; \frac{P(1)}{Total} \right]$$

$$Escolha (N_2) = \left] Escolha (N_1) ; Escolha (N_1) + \frac{P(2)}{Total} \right]$$

$$Escolha (N_{n-1}) = \left] Escolha (N_{n-2}) ; Escolha (N_{n-2}) + \frac{P(n-1)}{Total} \right]$$

$$Escolha (N_n) = \left] Escolha (N_{n-1}) ; 1 \right]$$

O procedimento é esquematizado na Figura 33.




Figura 33 – Processo de Criatividade. Selecção do primeiro ingrediente

O nó escolhido receberá um *input* externo no primeiro instante da simulação, e será o primeiro nó a ser considerado para a receita.

Em seguida este nó irá propagar a sua activação aos nós com que está associado, de acordo com a força das ligações aprendidas. No instante seguinte, esses mesmos nós repetiram a propagação, como em qualquer simulação do modelo RANs. Passado um intervalo de tempo determinado, a rede encontrar-se-á num determinado estado, em que os vários nós diferentes níveis de activação, e nesse momento voltaremos a escolher um novo nó, desta vez de acordo com o nível de activação de cada nó.

$$Escolha (N_1) = \left[ 0 ; \frac{Act_1(t)}{Total} \right]$$

$$Escolha (N_2) = \left] Escolha (N_1) ; Escolha (N_1) + \frac{Act_2(t)}{Total} \right]$$

$$Escolha (N_{n-1}) = \left] Escolha (N_{n-2}) ; Escolha (N_{n-2}) + \frac{Act_{n-1}(t)}{Total} \right]$$

$$Escolha (N_n) = \left] Escolha (N_{n-1}) ; 1 \right]$$

O procedimento é esquematizado na Figura 34.




Figura 34 – Processo de Criatividade. Selecção dos ingredientes seguintes

Após a escolha do novo nó, podemos injectar um estímulo neste nó, ou simultaneamente no novo nó e também no anterior. Ambas as variantes serão testadas. O processo repete-se até se obter um desejado número de ingredientes.

Analisando o processo da criatividade, o método apresenta alguma aleatoriedade, factor que poderá introduzir a componente de novidade que se espera num processo criativo. Contudo, essa aleatoriedade é controlada pela força das ligações entre os nós, ou seja, pelo conhecimento adquirido pela rede. O suporte para a criação de combinação de ingredientes que possam conter o critério da novidade parece estar garantido. Quanto ao critério do valor, pretende-se que seja atingido através da escolha adequada de ingredientes proporcionada pela propagação da activação, estando dependente dos métodos de aprendizagem e propagação.

Na simulação da criatividade através deste processo, as ligações inibitórias adquirem especial importância, pois, para a criação de uma receita em que já estão definidos alguns ingredientes, será de maior importância a inibição de ingredientes completamente não relacionados, do que a escolha entre ingredientes relacionados. Um aspecto a ter em conta no futuro desenvolvimento das RANs será possibilitar que a propagação de uma quantidade negativa de activação (que funciona como inibição) possa ser propagada novamente ou armazenada, para que a sua influência seja mantida ao longo de vários instantes temporais.

#### 5.4.1. Avaliação dos Resultados

A avaliação de artefactos produzidos por processos ou sistemas criativos é um tema recorrente e de elevada importância no campo da investigação em criatividade computacional.

Apesar da crescente menção do critério da surpresa como uma forma de avaliar a criatividade, usualmente esta avaliação consiste na medição de dois critérios: novidade e valor (Pereira, 2007) (Jordanous, 2012). O critério da novidade corresponde a uma medição de quão diferente é o artefacto criado daquilo que o sistema criativo tem conhecimento. Pode também ser referido como originalidade. O critério do valor pretende medir a adequação do artefacto criado ao domínio em que se aplica, podendo ser uma avaliação da sua eficiência, grau de correcção, validade, beleza estética, etc. Pode também ser referido como utilidade.

É também frequente associar estes dois critérios a dois processos cognitivos opostos, considerados necessários para a criação de um produto criativo: pensamento divergente e pensamento convergente.

O pensamento divergente caracteriza-se pela exploração de muitas soluções, através do desafio da lógica, do estabelecimento de associações inesperadas ou contraditórias, de um encadeamento fluído de ideias que são geradas de uma forma emergente. A este tipo de processo está associado o critério da novidade.

O pensamento convergente foca-se na procura da solução correcta para um problema, através do pensamento lógico, seguimento de normas, metodologia e objectividade. A este tipo de processo está associado o critério do valor.

### **Novidade**

A medida de novidade pretende definir em que medida o artefacto criado difere dos artefactos existentes. Considerando cada artefacto como um ponto no espaço conceptual multidimensional, a novidade poderá ser medida como uma diferença entre o artefacto criado e outro ponto que permita o estabelecimento de uma comparação.

Algumas das abordagens frequentemente utilizadas (Maher, et al., 2012) consideram esta medida como:

- A diferença do artefacto criado para o vizinho mais próximo do novo artefacto – este é um tipo de abordagem com ligações individuais, ou seja, o novo artefacto é avaliado tendo em conta outro artefacto específico.
- O rácio entre a distância do artefacto criado para o seu vizinho mais próximo e a média das distâncias entre vizinhos mais próximos no conjunto prévio de artefactos. Esta abordagem tem em conta informação sobre todo o conjunto.
- A distância entre o artefacto criado e a centróide de todos os pontos no espaço conceptual. Esta centróide é um ponto teórico no espaço conceptual, que representa uma média dos atributos de todos os artefactos.
- A distância entre o artefacto criado e a centróide mais próxima, considerando o caso de ser efectuado um agrupamento de todos os artefactos com  $k$  clusters.

Optou-se pela última abordagem referida, efectuando um clustering usando o método K-Means, variando o número de clusters entre 2 e 100, procurando obter qual o



número de clusters que minimizava a soma das distâncias de cada receita ao centróide que lhe era atribuído pelo algoritmo.

Para cada número de clusters, o algoritmo foi ainda repetido 5 vezes, tendo em conta diferentes pontos de partida para o algoritmo, que podem provocar a obtenção de um mínimo local na minimização de distâncias.

Foi considerada a distância de Hamming, por ser mais apropriada para o uso de dados binários, como são os conjuntos de ingredientes usados.

A seguinte figura mostra os resultados obtidos para os diferentes números de clusters.

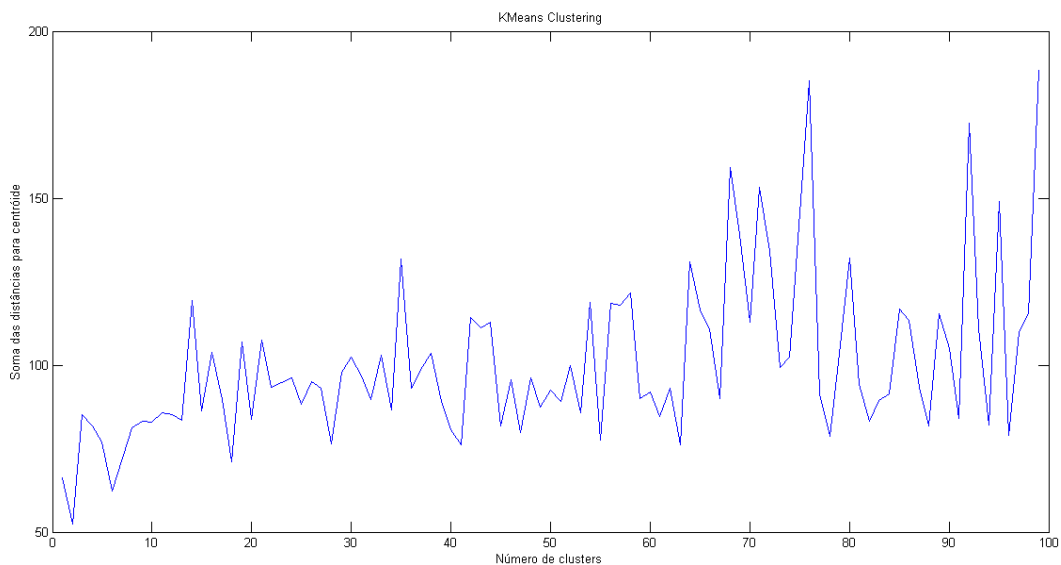


Figura 35 – Soma das distâncias para centróide em função do número de clusters

A soma das distâncias é minimizada com 3 clusters, num total de 52,43, o que significa uma distância média de cada ponto para o centróide do cluster atribuído de 0.0099.

A avaliação da novidade de uma nova receita implicará então o cálculo do cluster mais adequado para a receita e a medição da distância para com esse centróide.

Se tivermos em consideração a distância máxima de uma receita atribuída ao cluster poderemos estabelecer um rácio de novidade para a receita X:

$$Novidade (X) = \frac{\text{distância} (X, \text{centróide mais próximo})}{\text{distância} (Y, \text{centróide mais próximo})}$$

Onde

- Y é a receita mais afastada do respectivo centróide.

### Parâmetros Variáveis

#### Modelo:

Factor de Solipsismo, de 0.1 a 0.9, com um incremento de 0.1

### **Simulação:**

- Número de Ingredientes a seleccionar, com os seguintes valores {2, 5, 10, 15, 20}
- Intervalo entre escolha de ingredientes, com os seguintes valores {1, 2, 5}
- Estimulação com ingredientes isolados / Acumulação de ingredientes nos padrões
- Número de Repetições por cada configuração: 50

### **Resultados Obtidos**

A novidade média obtida no conjunto das simulações é de 2.7299. Analisando os vários parâmetros variados, verifica-se que apenas o parâmetro do número de ingredientes causa diferenças no grau médio de novidade observado. A média das simulações observando a variação dos outros parâmetros mantém-se estável e muito próxima da média total do conjunto de simulações.

### **Média Novidade das Receitas Criada em função do número de ingredientes**

<b>Número de Ingredientes</b>	<b>2</b>	<b>5</b>	<b>10</b>	<b>15</b>	<b>20</b>
<b>Novidade Média</b>	0,7149	1,4467	2,6642	3,843	4,9799
<b>Desvio Padrão</b>	0,1213	0,1492	0,2224	0,3413	0,5404

Tabela 20 – Medição da Novidade Média e Desvio Padrão em função do número de ingredientes seleccionados

Pode observar-se que o grau de novidade cresce de acordo com o aumento de ingredientes escolhidos para a receita. Este fenómeno será explicado pela crescente divergência associada a um maior número de ingredientes. Tendo em conta a quantidade de ingredientes existentes (490), o número de receitas aprendidas (4351), e tendo um nó em média 79 ligações de saída positivas, dois ingredientes são suficientes para que as suas possíveis combinações ultrapassem o total de receitas aprendidas. Aumentando o número de nós, aumenta o tamanho espaço conceptual, e a possibilidade de divergir das receitas aprendidas.

Esse facto não seria um problema, se com o aumento do número de nós, se mantivesse o critério na selecção dos ingredientes, ou seja, se mecanismos de produção convergente actuassem simultaneamente. Esses mecanismos no modelo RANs aplicado à criatividade serão os métodos de treino e propagação, e futuramente, os processos de regulação.

### **Valor**

A medição do critério do valor é de grande importância na avaliação dos resultados de um processo criativo. Contudo, essa medição é também de considerável dificuldade, tendo em conta a subjectividade inerente à avaliação de um determinado artefacto, à definição de uma escala apropriada e a dependência desse processo de medição do domínio em que se inserem os resultados do processo criativo. Não existindo uma heurística independente do domínio de aplicação, a medição deste valor geralmente é realizada através de uma avaliação por utilizadores do artefacto criado, por experts no domínio ou através de medidas específicas associadas ao domínio

Para a avaliação de receitas consideramos duas formas possíveis para realizar a medição do valor de um artefacto criado:

- Avaliação manual por expert(s) através da observação das receitas criadas – este processo seria difícil de implementar, sobretudo pela dificuldade em avaliar uma grande quantidade de receitas.
- Avaliação através da aprendizagem de classificações introduzidas por utilizadores – esta alternativa poderá ser implementada no futuro, e consiste em obter receitas que tenham sido avaliadas por utilizadores. A aprendizagem seria feita com um passo adicional, em que um nó responsável pelas avaliações estaria conectado com todos os outros nós, e quando fosse injectado um padrão com uma receita, o nó receberia a avaliação associada e treinaria as ligações para com os nós dos ingredientes, usando o método da regra-delta para a actualização dos pesos. No fundo, seria incorporar uma pequena rede para classificação no modelo.

No momento da criação de uma nova receita, a rede faria a classificação da mesma, obtendo-se assim uma medida de valor para o conjunto de ingredientes seleccionado, com base em todas as avaliações realizadas por utilizadores nas receitas aprendidas.

Sem uma avaliação quantitativa do critério do valor não podemos afirmar categoricamente que aumentando o número de ingredientes, a receita produzida terá menor valor. Mas tendo em conta a observação humana dos resultados produzidos, constatamos que os resultados nesse critério não são satisfatórios. A título de exemplo, a selecção de ingredientes que dificilmente estariam juntos numa receita (e.g., vários tipos de carne e peixe) permite antecipar um fraco valor nas receitas criadas. O facto de os outros parâmetros não serem uma influência no critério da novidade acaba por não ser surpreendente, pois a expectativa é que tenham mais influência no critério do valor.

O intervalo entre escolha de ingredientes tem como efeito a propagação de activação durante mais instantes na rede. Comparando o caso em que o ingrediente é seleccionado um instante após o estímulo do ingrediente anterior com um caso em que haja um maior intervalo entre as selecções, é expectável que no primeiro caso os nós com mais activação sejam aqueles directamente relacionados com o nó escolhido previamente, o que aumentará a sua probabilidade de selecção. Se a activação se propagar durante vários instantes, através de sucessivas relações positivas entre nós, aumentar a probabilidade da selecção de um ingrediente não relacionado com o escolhido anteriormente. Nesta mesma lógica, o factor de solipsismo poderá ter uma importância relevante, controlando o rápido decaimento e porventura mantendo as escolhas mais estáveis.

A acumulação de conceitos poderá também ser um factor que influencie positivamente o critério do valor. Na escolha do n-ésimo ingrediente, a activação de todos os ingredientes prévios irá à partida aumentar a probabilidade de escolhas de ingredientes relacionados com a totalidade da receita.

## 6. Implementação do Modelo e Aplicação

Neste capítulo são descritos os aspectos relacionados com a implementação do modelo e com a aplicação desenvolvida para suporte à experimentação no desenvolvimento futuro do modelo RANs. A secção 6.1 mostra a arquitectura geral do sistema, incluindo os passos efectuados para a obtenção dos dados de entrada. A secção 6.2 detalha aspectos relativos à implementação do modelo. A secção 6.3 diz respeito à descrição da interface gráfica do software desenvolvido.

### 6.1. Arquitectura do Sistema

Um dos objectivos definidos para esta Tese de Mestrado foi a aplicação do modelo desenvolvido num caso de uso, onde pudesse ser testada a aplicabilidade do modelo com dados não abstractos, isto é, não gerados aleatoriamente, sem qualquer significado.

O caso de uso definido foi no domínio das receitas culinárias.

Para esse efeito, foi necessário proceder a operações envolvendo a extracção, limpeza e transformação de informação, de modo a tornar a mesma utilizável pelo modelo RANs.

Nesta secção é descrita a arquitectura do sistema desenvolvido, assim como cada um dos passos necessários para transformar um conjunto de receitas culinárias descritas textualmente por utilizadores de um website num conjunto padrões de entrada do modelo RANs.

A arquitectura do sistema pode ser descrita sucintamente como englobando três componentes: a extracção da informação, a limpeza e transformação desses dados, e o seu carregamentos para a aplicação das RANs. A Figura 36 Figura 1 fornece uma visão geral do sistema.

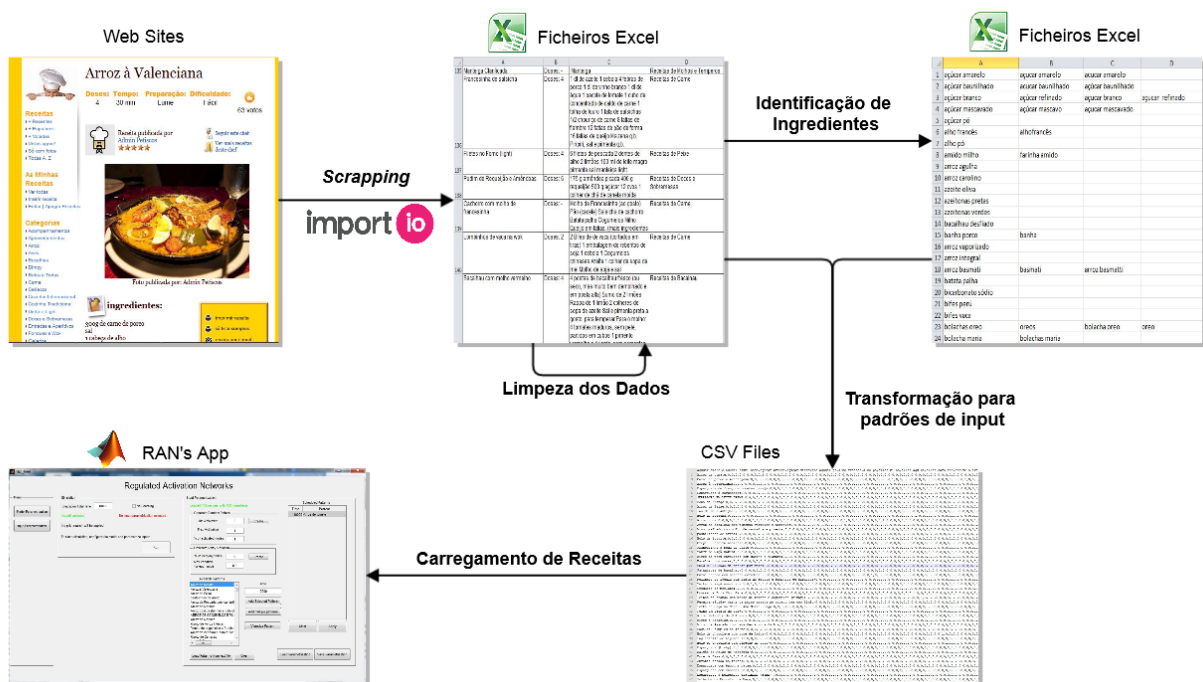


Figura 36 – Arquitectura do Sistema

Em seguida, são descritas as várias operações realizadas.

**Scrapping** – A obtenção da informação, neste caso conjuntos de ingredientes de receitas de culinária, foi realizada com o auxílio da ferramenta import.io, que permite a extracção automática de informação de websites, após uma breve configuração manual. A fonte de informação usada foi o website de língua portuguesa petiscos.com, do qual foram extraídas 5000 receitas. Para cada uma das receitas foi obtida a lista de ingredientes necessários para a confecção, o número de doses individuais a que corresponde a receita, a descrição textual da preparação, a categoria a que corresponde a receita e, naturalmente, o nome da receita. Todos estes dados foram armazenados num ficheiro excel. Destes dados apenas foram usados o nome da receita, a categoria e a listade ingredientes, sendo que os restantes poderão ser necessários em futuras experimentações com o modelo.

**Limpeza dos Dados** – Dado que a introdução de receitas em websites é tipicamente feita por utilizadores regulares, e não havendo garantias de que essa informação tenha sofrido uma revisão, foram detectadas algumas situações em que a informação não correspondia ao esperado. Designadamente, a existência de campos vazios (especialmente listas de ingredientes e número de doses), campos com informação inapropriada (listas de ingredientes que remetiam para outras receitas ou para o campo da preparação), links para outros websites, etc.

Foi necessário proceder a uma detecção dessas situações e a uma limpeza dos dados, tendo resultado desta operação um total de 4351 receitas válidas.

**Identificação de Ingredientes** – Dado o reduzido nível de estruturação dos dados introduzidos nas listas de ingredientes foi necessário dispendir algum tempo na detecção dos ingredientes utilizados nas receitas. Também a inexistência de uma fonte estruturada de ingredientes na língua portuguesa (por exemplo, uma ontologia de alimentos) que pudesse servir de suporte a esta tarefa levou a que esta fosse realizada de uma forma praticamente manual. Este foi o processo usado: Foram analisadas todas as listas de ingredientes, contabilizando o número de utilizações de cada palavra, formando assim uma lista ordenada de palavras. Dessa lista foram retirados termos não relacionados com os ingredientes como preposições, advérbios e verbos e alguns adjectivos utilizados para descrever os ingredientes (pequeno, grande, maduro,...). No entanto, alguns adjectivos são mantidos por serem parte da designação do ingrediente (e.g., carne picada).

De seguida, a lista foi analisada manualmente, para a detecção de palavras que eram efectivamente ingredientes. O mesmo processo de contagem e selecção foi repetido para pares de palavras, permitindo a obtenção de ingredientes de duas palavras.

Por fim, a lista foi ainda analisada tendo em conta diferentes designações para o mesmo ingrediente (e.g., do português para o português brasileiro), ou mesmo admitindo erros comuns de ortografia.

**Transformação para padrões de *input*** – Este processo visa a transformação da descrição textual dos ingredientes de uma receita num vector binário, indicando a presença ou ausência de um determinado ingrediente numa dada receita, com os valores 1 e 0, respectivamente. Toda esta transformação está automatizada, sendo apenas necessário

para a sua execução o carregamento das receitas e da lista de ingredientes para Matlab e a execução de um script.

Consiste num parsing iterativo, sendo procurado cada possível designação de um ingrediente em cada receita, e sendo os resultados armazenados num ficheiro txt. No caso de um dado ingrediente não constar em nenhuma receita, este é excluído do resultado final. A primeira linha do ficheiro corresponde ao nome dos vários ingredientes e cada linha seguinte a uma receita, num ficheiro com o seguinte formato:

```

Ingrediente1, Ingrediente2, ... , IngredienteN
Receita1;1,0,...,0
Receita2;0,1,...,0
...
ReceitaM;0,0,...,1
```

Figura 37 – Formato de um ficheiro de *input*

Este processo é generalizável e aplicável a outros domínios, podendo futuramente ser utilizável para o parsing de diferentes *inputs* não estruturados (textos) a partir de uma determinada lista de conceitos com múltiplas designações.

**Carregamentos das Receitas** – O carregamento das receitas é um processo simples, podendo ser efectuado pelo utilizador através da interface construída, seleccionando o ficheiro txt que pretende importar. A leitura da primeira linha do ficheiro fornece à aplicação o nome de cada um dos ingredientes que poderão estar presentes nas receitas, que são armazenados num vector. Para cada uma das seguintes linhas é lido o nome da receita, e em seguida, o conjunto de valores binários indicando a presença ou ausência de um determinado ingrediente na receita em questão. Estes valores são armazenados numa matriz  $M \times N$ , sendo  $M$  o número de receitas e  $N$  o número de ingredientes.

## 6.2. Implementação do Modelo

Nesta secção são descritos os aspectos relacionados com a implementação do modelo.

O facto de o cálculo numérico, designadamente com operações matriciais, ser uma das principais componentes na execução de simulações com o modelo RANs, foi uma das principais razões que levaram à decisão de implementar o modelo num ambiente MATLAB. Outros factores incluídos nesta decisão incluem a facilidade em visualizar graficamente os resultados obtidos e a possibilidade de desenhar interfaces gráficas para interacção com o utilizador.

Foi utilizada a versão MATLAB R2013a 64-bit.

A linguagem MATLAB é tradicionalmente uma linguagem de programação procedimental. No entanto, há vários anos que suporta também programação orientada a objectos. O facto de as simulações do modelo RANs consistirem em conjuntos de

operações computacionais sobre um conjunto de dados, bem como um dos requisitos estabelecidos para a implementação do modelo ser a sua estruturação e modularidade, levou a que se desenvolvesse um programa de carácter essencialmente procedimental.

Contudo, também foram usadas algumas classes, sobretudo como forma de estruturar e agrupar informação relacionada. Em seguida é apresentado o diagrama de classes, e uma descrição de cada atributo nelas contido.

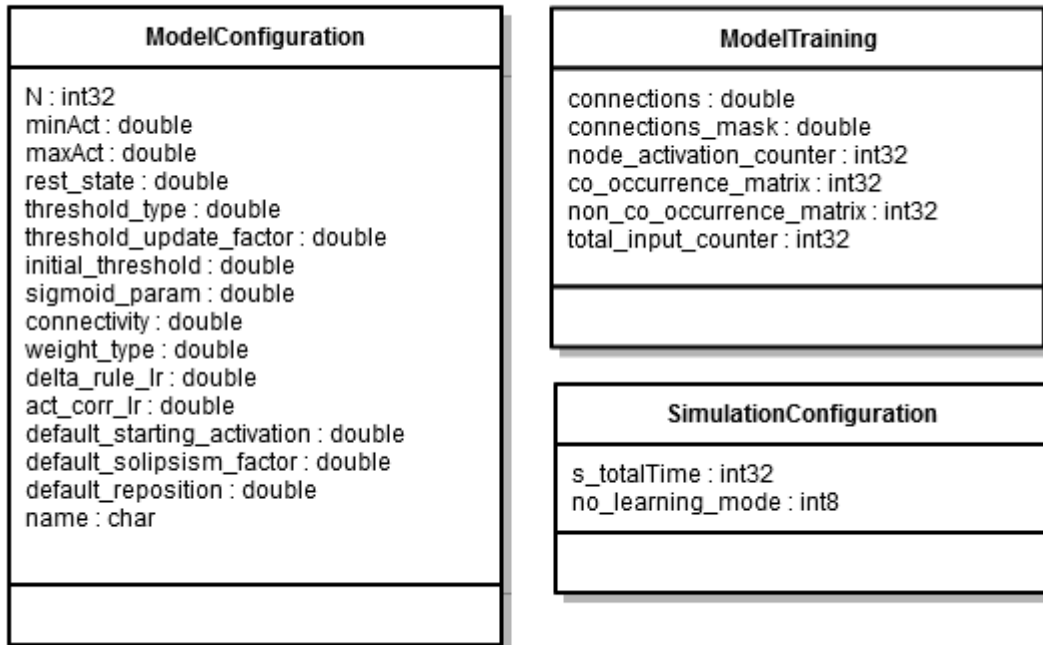


Figura 38 – UML: Diagrama de Classes

**Model Configuration** – Uma instância da classe ModelConfiguration representa uma configuração possível do modelo. Cada atributo da classe representa uma propriedade variável do modelo. Em seguida estas propriedades são descritas:

- N – número de nós no modelo
- minAct, maxAct – activação mínima e máxima permitidas, respectivamente
- rest\_state – *Rest state* do modelo
- threshold\_type – tipo de thresholds utilizados. Neste momento são considerados dois tipos: thresholds inexistentes (representado com 0) e threshold estáticos com um valor definido.
- threshold\_update\_factor – ritmo de actualização dos thresholds (será necessário para a futura aplicação de thresholds dinâmicos)
- initial\_threshold – valor inicial para os thresholds
- sigmoid\_param – parâmetro a ser usado nas funções sigmóide
- connectivity – parâmetro usado na máscara de conectividade, e que representa o número de ligações de output que um nó pode ter como uma percentagem do total de nós na rede. Se connectivity for igual a 1, a conectividade permitida é total.

- `weight_type` – tipo de pesos usados. Neste momento apenas é considerado um tipo.
- `delta_rule_lr` – ritmo de aprendizagem para métodos de treino baseados no erro.
- `act_corr_lr` – ritmo de aprendizagem para métodos baseados na relação entre as activações dos nós.
- `default_starting_activation` – activação inicial para todos os nós
- `default_solipsism_factor` – factor de solipsismo inicial para todos os nós
- `default_reposition` – grau de reposição inicial para todos os nós
- `name` – nome do modelo

**Model Training** – Classe que engloba todas as variáveis relacionadas com o treino do modelo com as seguintes propriedades:

- `Connections` – Matrix NxN em que cada célula (i,j) representa a força da ligação do nó  $n_i$  para o nó  $n_j$ .
- `Connections_mask` – Matrix NxN preenchida por 0's e 1's usada como máscara de conexões com a função de assegurar após um método de treino que as ligações de um nó para sim mesmo permanecem nulas, e no caso de a conectividade não ser total, assegurar que conexões proibidas permanecem também nulas. Se a célula (i,j) é igual a 1, é permitido o estabelecimento de uma conexão do nó  $n_i$  para o nó  $n_j$ . Em caso contrário, essa conexão não é permitida.
- `Node_activation_counter` – vector 1xN que guarda o número de vezes que cada nó esteve activo nos padrões externos aprendidos pela rede.
- `Co_occurrence_matrix` – matrix NxN em que na célula (i,j) guarda o número de co-ocorrências dos nós  $N_i$  e  $N_j$  nos padrões externos aprendidos pela rede.
- `Non_co_occurrence_matrix` – matrix NxN em que na célula (i,j) guarda o número de vezes que o nó  $N_i$  ocorreu e o nó  $N_j$  não ocorreu, nos padrões externos aprendidos pela rede.
- `Total_input_counter` – guarda o total de padrões externos aprendidos pela rede.

**Simulation Configuration** – Classe que guarda todas as variáveis respectivas à execução da simulação:

- `s_totalTime` – número de instantes temporais que a simulação irá durar.
- `No_learning_mode` – parâmetro que permite a execução de uma simulação em que todos os processos de treino são descartados. Para determinar esse efeito é-lhe atribuído o valor 1.

O uso destas classes permite uma fácil alteração ou expansão das características e propriedades do modelo, sem a necessidade de alterações substanciais no código desenvolvido. É também útil para que a passagem e retorno de parâmetros para as diferentes funções seja feita de uma forma mais estruturada.



Além de uma instância de cada uma destas classes, existem também outras estruturas de dados essenciais à execução das simulações no modelo. São elas:

- **Nodes** – Matrix tri-dimensional que indica as propriedades de cada nó para cada instante temporal. A primeira dimensão corresponde aos nós, a segunda dimensão ao instante temporal e a terceira dimensão às diferentes propriedades, designadamente, o nível de activação, o ritmo de reposição, o factor de solipsismo, o parâmetro usado nas funções sigmóide, e o threshold do nó. É, portanto uma matrix de dimensão  $N \times T \times 5$ , sendo  $N$  o número de nós e  $T$  o número de instantes temporais total em que irá decorrer a simulação. Por exemplo, a activação do quinto nó, no instante temporal  $t=100$ , encontra-se na célula  $nodes(5,100,1)$ .
- **I\_patterns** – Matrix bidimensional que guarda todos os padrões de *input* a ser usados na simulação, sendo que cada linha corresponde a um padrão de *input*. É, portanto uma matrix  $M \times N$ , sendo  $M$  o número total de padrões de entrada e  $N$  o número de nós do modelo.
- **I\_schedule** – Vector unidimensional  $1 \times T$  que indica para cada instante de tempo, a existência ou inexistência de um padrão de *input*. Em caso afirmativo o padrão correspondente é indicado através de um número inteiro que corresponde à linha desejada da matrix *i\_patterns*.

Passamos agora a descrever como é realizado o procedimento de uma simulação-

O seguinte diagrama de actividade sumariza as principais acções de alto nível inerentes à realização de uma simulação do modelo RANs.

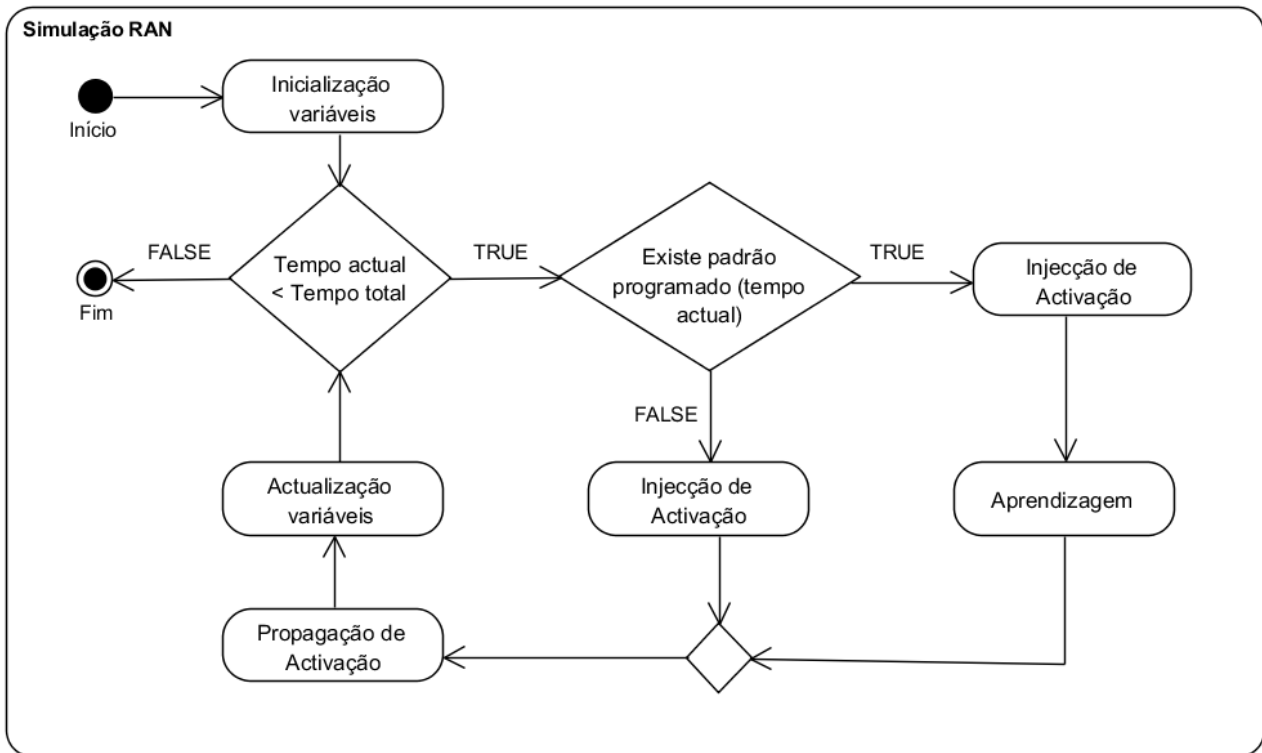


Figura 39 - UML: Diagrama de Actividade. Procedimento de uma simulação

Em primeiro lugar, são inicializadas algumas variáveis necessárias para o decorrer da simulação, e.g., tempo inicializado a 1.

A partir desse momento a simulação entra no ciclo temporal, isto é, um conjunto de passos que se repete até que a variável tempo exceda o tempo indicado pelo utilizador para terminar a simulação.

Esse conjunto de passos inicia-se por, a cada instante, verificar se existe um padrão de *input* programado. No caso de existir, é realizada a injeção de activação seguida do processo de treino. No caso de não existir, é realizada apenas a injeção de activação, com a diferença de essa injeção não incluir um padrão. O passo seguinte é a propagação da activação, tendo já em conta a actualização dos níveis de activação e, se caso disso, os pesos, dos passos anteriores. Em seguida, pode ser recolhida e guardada informação sobre o estado actual da rede, e são actualizadas as variáveis.

Para que se possa entender com mais detalhe a tradução deste conjunto de acções nas funções desenvolvidas, em seguida, apresentamos dois diagramas de sequência. Em ambos, os participantes, que tradicionalmente numa abordagem orientada a objectos representam instâncias de classes, representam as diferentes funções/módulos da aplicação. Desta forma, as mensagens são interpretadas como chamadas a funções onde são explicitados os parâmetros de chamada e retorno.

O primeiro diagrama explicita as interacções do utilizador com os diferentes ecrãs da interface gráfica. Quando a aplicação é inicializada, é mostrado o ecrã principal (GUI\_RAN). O utilizador interage com os diferentes componentes da interface que reage

a estas interações com a chamada interna a funções de *callback* que se traduzem em mudanças na interface.

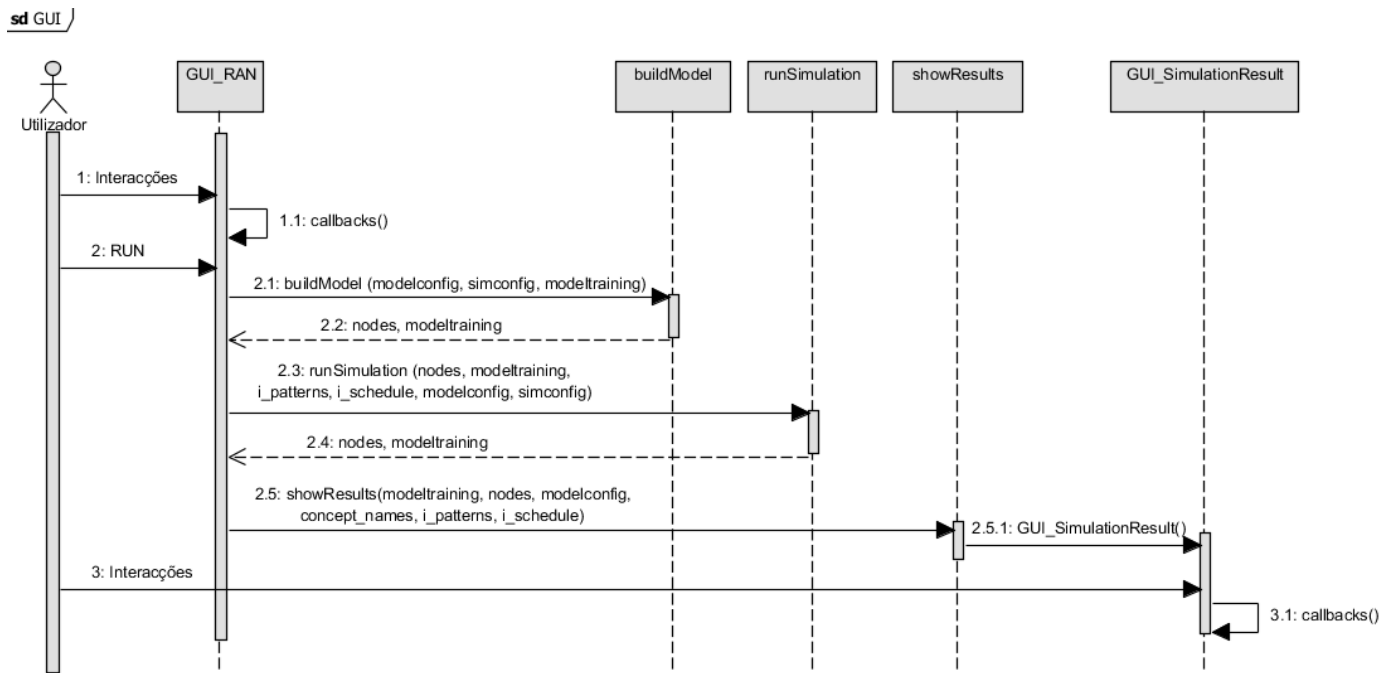


Figura 40 - UML: Diagrama de Sequência. Interação do utilizador com GUI

Quando o utilizador inicia a simulação através do botão “Run” o primeiro passo é a inicialização das estruturas de dados na função *buildModel*. Esta recebe a configuração do modelo (*modelconfig*) carregada ou criada pelo utilizador na interface, as opções da simulação (*simconfig*) e os dados de treino iniciais (*modeltraining*) no caso de terem sido carregados. A partir destas informações é construída a matrix tri-dimensional *nodes*, e no caso de não existirem pesos iniciais carregados, é instanciada a classe *ModelTraining* com os dados de treino vazios. Com estas estruturas o módulo da interface inicia a simulação, com a chamada ao método *runSimulation*, para o qual é também enviado as estruturas de dados correspondentes à parametrização de *inputs*.

O procedimento interno desta função está esquematizado no seguinte diagrama, por questões de visibilidade. Tal como referido anteriormente, este procedimento consiste num conjunto de passos executados a cada instante do ciclo temporal  $\text{while time} < \text{simconfig.s\_totalTime}$ . O primeiro passo é a verificação da existência de um padrão de *input* programado ( $\text{i\_schedule}(\text{time}) \sim 0$ ). Caso este exista, é chamada a função *activationInput* que recebe além das estruturas de dados já referidas, o padrão a injectar (*pattern*) e o vector *node\_inputs* que contém a activação interna a receber por cada nó, i.e., a activação propagada pelor todos os nós no instante anterior.

Esta função calcula os níveis de activação para cada nó de acordo com os métodos descritos na secção 4.3, e no caso de receber um padrão externo invocará as funções de aprendizagem *updateTrainingCounters*, responsável pela alteração das matrizes de co-ocorrência e pelas contagens total de *inputs* e de *input* para cada nó, e *trainConnections* que altera apenas a matriz de conexões entre os nós. Todas estas informações estão contidas no objecto *modeltraining*.

A função `trainConnections`, na realidade, é uma função wrapper, que invoca a função de treino pretendida, correspondente aos diferentes métodos de treino descritos na secção 4.4. Deste modo preserva-se a modularidade e expansibilidade do código do modelo, sendo que por exemplo a adição de um novo método de treino apenas requer a criação de uma função com o método e a sua escolha na função wrapper, sem que o *core* do modelo precise ser alterado.

Caso não exista um padrão de entrada no instante actual ( $i\_schedule(time) \neq 0$ ) as funções de treino não são invocadas.

Por último, é chamado o método `activationOutput`, que de acordo com os novos níveis de activação (em nodes) e os possíveis novos pesos (em `modeltraining`) irá calcular o vector `node_inputs` que quantifica a activação a receber por cada nó da camada no instante seguinte. A estrutura `nodes` pode também ser alterada, por exemplo, no caso de serem considerados `thresholds` dinâmicos que variam de acordo com a propagação dos nós. Mais uma vez trata-se de uma função wrapper que invoca funções correspondentes aos métodos de propagação descritos na secção 4.5.

No final do ciclo temporal são devolvidas as estruturas `nodes` e `modeltraining`, assim como qualquer outra informação pretendida e recolhida durante a simulação (informação variável, e por isso, omitida na figura).

O módulo `GUI_RAN` invoca, então, o método `showResults` que cria uma nova janela `GUI_SimulationResult` com os resultados, e desenha graficamente as informações pretendidas. O utilizador pode interagir com este ecrã segundo a mesma lógica de aplicação de callbacks usada no ecrã principal.

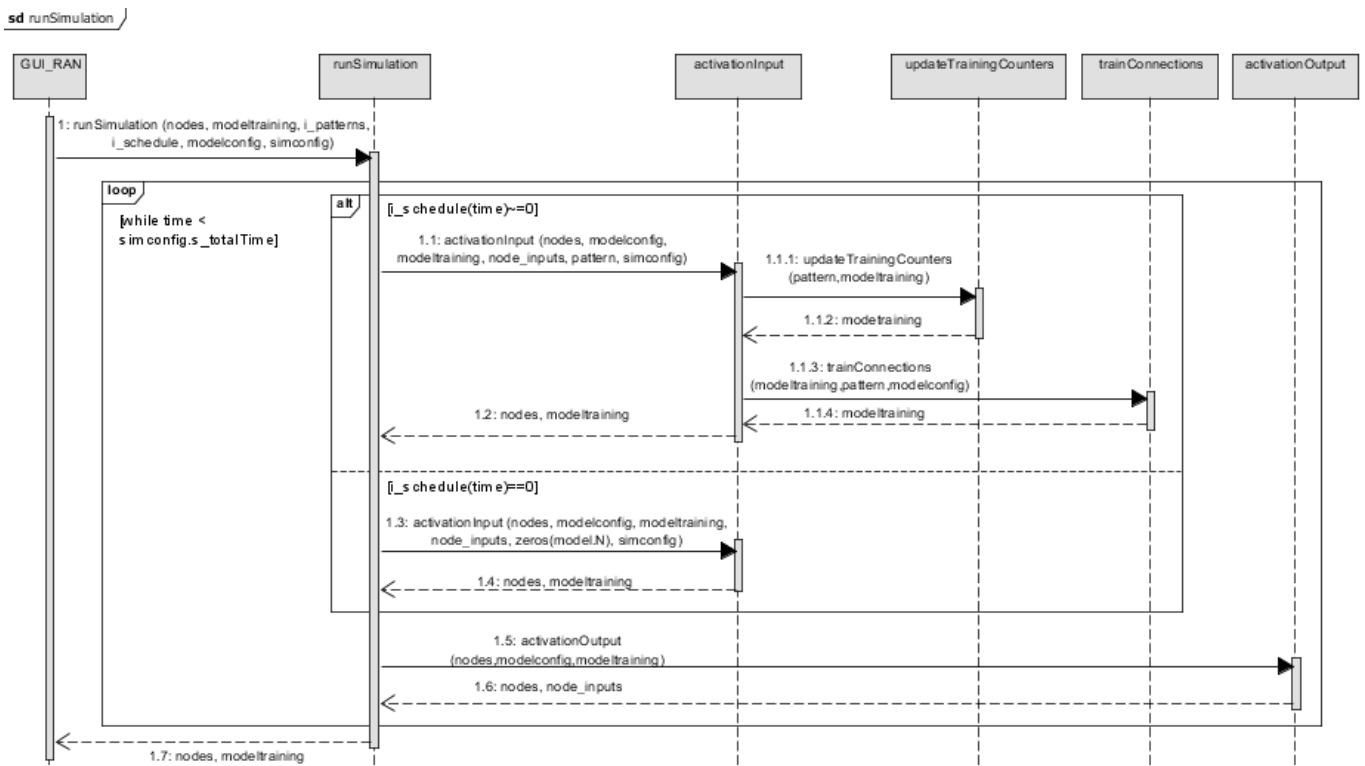


Figura 41 - UML: Diagrama de Sequência. Processo de uma Simulação

A estrutura da aplicação, que acaba de ser descrita, teve como principal preocupação a modularidade e expansibilidade do código, através da separação dos diferentes componentes que correspondem também a diferentes componentes do modelo.

A experimentação de diferentes métodos de injeção, treino, ou propagação deverá requerer apenas a implementação do método pretendido.

## 6.3. User Interface

A interface gráfica implementada é uma ferramenta que torna a execução de simulações um processo mais acessível e sistemático. Além disso, permite a criação de instâncias do modelo, assim como de parametrizações de *inputs*.

Nesta secção são descritas as funcionalidades de que dispõe, e é feita uma descrição de como usar os diferentes painéis que a compõem.

### 6.3.1. Menu

O menu situado na faixa esquerda a selecção dos painéis visíveis (Figura 42).

Para criar, carregar ou editar uma instância do modelo, escolha o painel “Model Parametrization” através do botão correspondente.

Para definir a programação de dados de *input* para uma simulação, carregar e visualizar dados de *input* de ficheiros ou gerar padrões de *input* aleatórios selecione o painel “Input Parametrization” através do botão correspondente.

O painel relativo à configuração e início da simulação está sempre disponível, podendo ser alternado entre uma simulação normal ou uma simulação de criatividade através do botão “Creativity”.

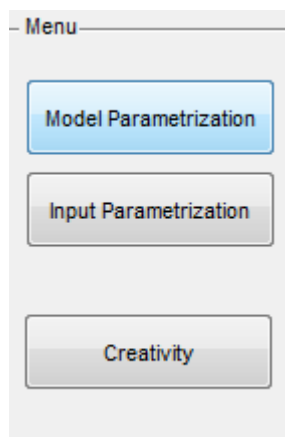


Figura 42 – GUI: Menu de escolha de painéis

### 6.3.2. Configuração do Modelo

O painel de parametrização no modelo diz respeito à configuração de todos os parâmetros relativos ao modelo (Figura 43).

Figura 43 – GUI: Painel de Parametrização do modelo

No canto superior esquerdo (de cima para baixo) é possível definir o nome do modelo, número de nós a criar na rede, rest state, factor de solipsismo inicial e ritmo de reposição inicial para todos os nós. De seguida pode optar entre não utilizar thresholds ou utilizar thresholds estáticos, definindo o seu valor.

No canto superior direito encontram-se as opções relativas à aprendizagem.

É possível definir a percentagem de conectividade, escolhendo um valor no domínio  $[0,1[$  para especificar a percentagem de nós a que cada nó se poderá ligar, ou o valor 1 para uma conectividade total.

O botão “Load Initial Weights” permite o carregamento de um conjunto de pesos que tenha sido guardado após a execução de outra simulação. O carregamento desses pesos pode ser anulado com o botão “Erase Initial Weights”.

No campo “Activation Correlation Learning Rate” pode ser definido o ritmo de aprendizagem para os métodos de Activation Correlation caso estes estejam activos.

Todas as configurações efectuadas podem ser guardadas com o botão “Save Model” e carregadas a partir do botão “Load Model”.

O botão “Grid-Search” torna visível o Painel de Grid-Search (Figura 44) que permite definir diferentes simulações de acordo com a variação de alguns parâmetros da rede. Para isso basta seleccionar o parâmetro a variar e especificar o conjunto de valores a testar com o formato Mínimo:Incremento:Máximo. Após a edição carregue no botão “Apply”.

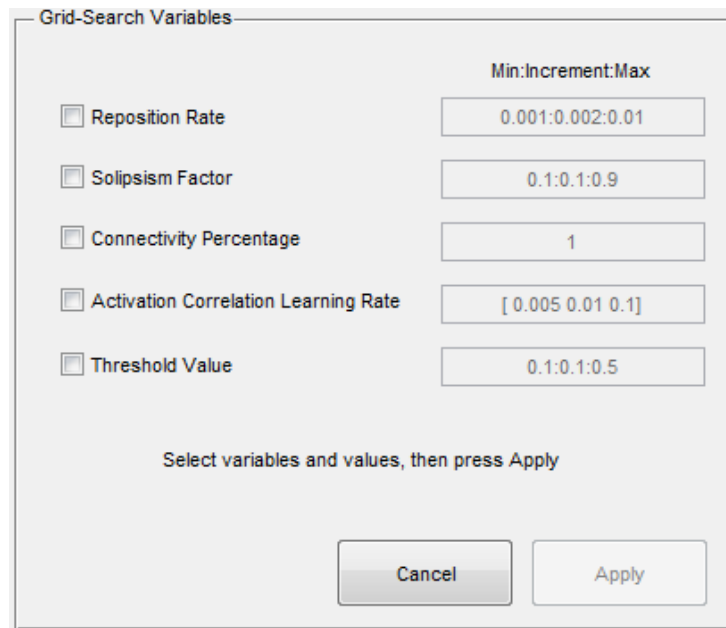


Figura 44 – GUI: Painel de Grid-Search

Terminada a configuração do modelo carregue no botão “Apply”.

### 6.3.3. Parametrização de *Inputs*

O painel de parametrização de *inputs* (Figura 45) permite ao utilizador a programação de padrões de *input*, simulando a entrada de informação sensorial na rede. Em seguida são descritas as funcionalidade suportadas neste painel.

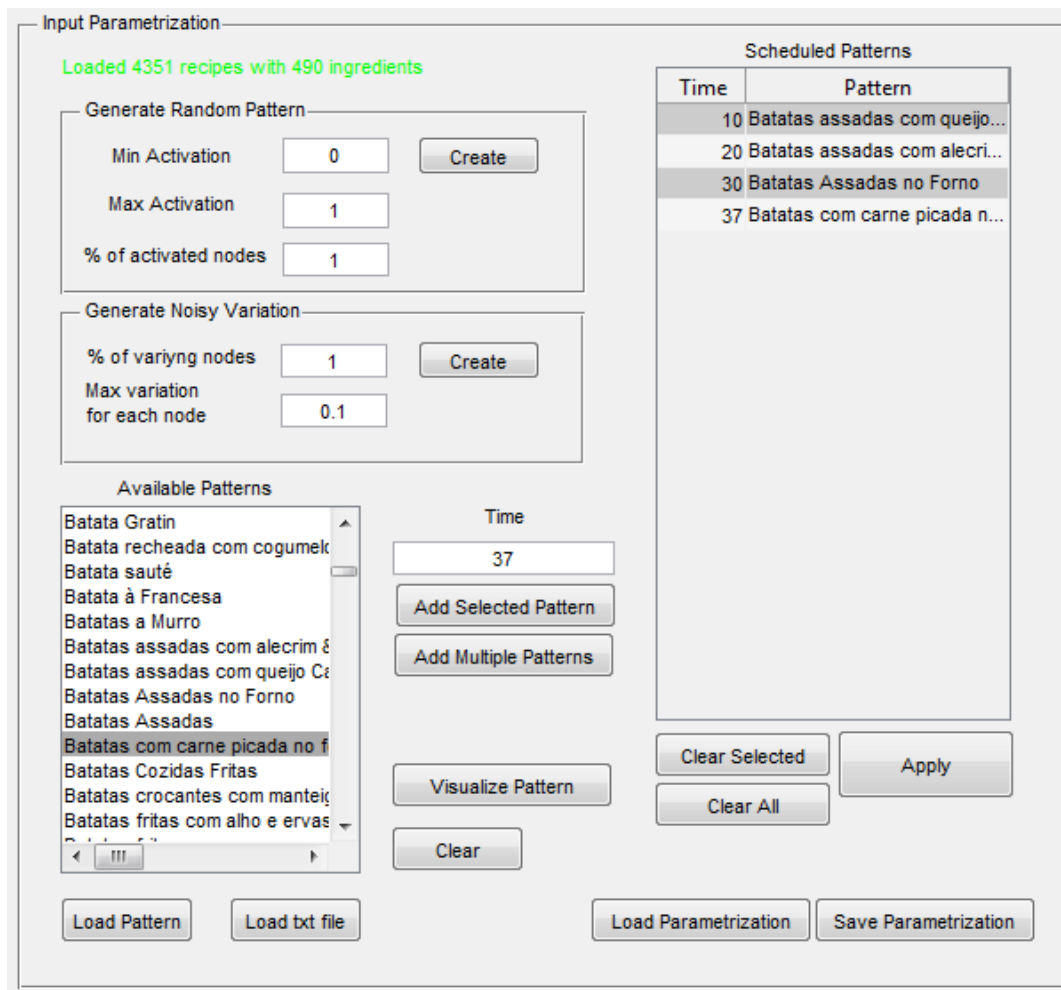


Figura 45 – GUI: Painel de Parametrização de Inputs

- Geração de Padrões Aleatórios** – No canto superior esquerdo do painel “Input Parametrization” é possibilitada a geração de padrões de *inputs* aleatórios, permitindo a definição de activação mínima e máxima desejada, assim como a percentagem de nós que estarão activos, no painel “Generate Random Pattern”. O padrão criado será adicionado à lista “Available Patterns”. No painel “Generate Noisy Variation” é possível criar uma variação com ruído de um padrão. Para isso é necessário seleccionar um padrão da lista “Available Patterns”, definir a percentagem de nós que sofrerão a variação, e a variação máxima a considerar. O padrão criado será adicionado à lista “Available Patterns”.
- Carregamento de Padrões a partir de um ficheiro de texto** – Através do botão “Load txt file” é possível o carregamento de padrões a partir de um ficheiro de texto. Os padrões carregados serão adicionados à lista “Available Patterns”.
- Carregamento de Padrões** – Através do botão “Load pattern” é possível o carregamento de padrões guardado num formato mat. Os padrões carregados serão adicionados à lista “Available Patterns”.



- **Lista de Padrões Disponíveis** – A lista “Available Patterns” no canto inferior esquerdo do painel “Input Parametrization” contém todos os padrões que são possíveis usar na simulação. Esta pode ser limpa usando o botão “Clear”. Qualquer padrão da lista pode ser visualizado, depois de seleccionado, através do uso do botão “Visualize Pattern”. Surgirá o painel “Pattern Visualization” (Figura 46) onde pode ser observado o nível de activação de cada um dos conceitos.

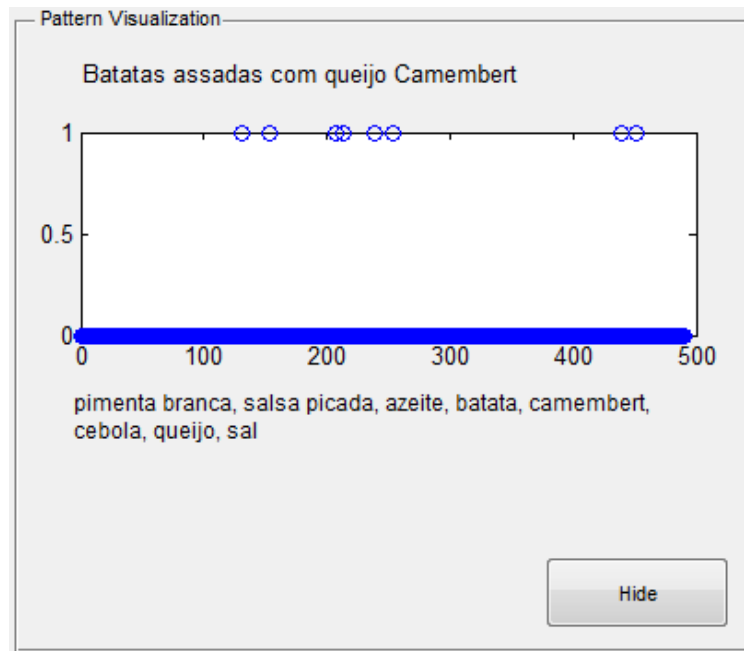


Figura 46 – GUI: Painel de Visualização de Padrões

Um padrão seleccionado na lista pode ser programado para a simulação preenchendo o campo “Time” em que deverá ser indicado o(s) instante(s) em que se pretende programar o padrão e usando o botão “Add Selected Pattern”.

No caso de apenas ser indicado um inteiro (Figura 47) o padrão será programado para esse instante. Para programar uma repetição do mesmo padrão pode ser usada a sintaxe *Início:Incremento:Fim* (Figura 48).




Figura 47 – GUI: Adição de um padrão




Figura 48 – GUI: Adição de um padrão com repetições

Para adicionar simultaneamente vários padrões a mesma sintaxe terá de ser usada em conjunto com o botão “Add Multiple Patterns”.

Os padrões programados são exibidos na tabela “Scheduled Patterns”.

- **Tabela de Padrões Programados** – Nesta tabela encontram-se todos os padrões programados para uma simulação. Esta pode ser totalmente limpa com o botão “Clear All” ou pode apagar um padrão seleccionado com o botão “Clear Selected”. Esta parametrização temporal dos padrões pode ser guardada, para uso em futuras simulações, através do botão “Save Parametrization”, assim como carregado através do botão “Load Parametrization”.

Quando terminada a parametrização deve clicar no botão “Apply”.

### 6.3.4. Execução de Simulação

No painel de simulação o utilizador tem *feedback* sobre a configuração do modelo e a parametrização de *inputs*, passos necessários para a realização da simulação, assim como sobre a opção de grid-search (Figura 49).

Para a realização da simulação deverá escolher o tempo total da simulação (campo “Simulation Total Time”), optar por uma simulação com ou sem aprendizagem (opção “No Learning”) e clicar no botão “Run”.

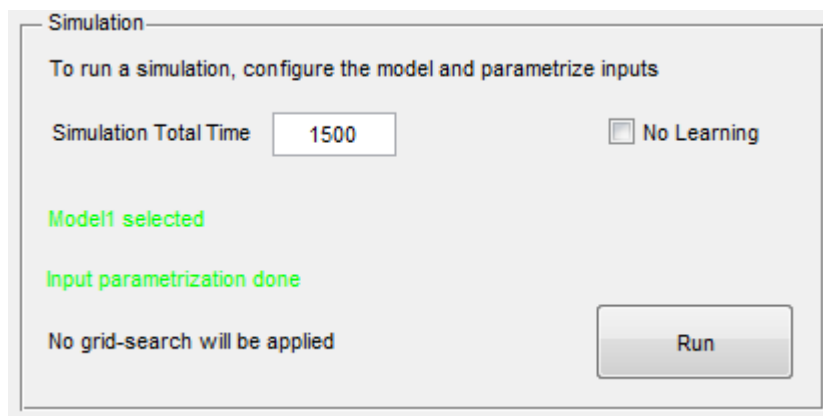


Figura 49 – GUI: Painel de Execução de Simulação

Semelhante ao painel de simulação, o painel para as simulações de criatividade, fornece *feedback* sobre as configurações prévias necessárias para a simulação que são a configuração do modelo e o carregamento de um ficheiro de pesos (Figura 50).

O campo “Simulation Total Time” define o tempo total da simulação, o campo “Time between inputs” especifica o intervalo entre estímulos na simulação, e o campo “Number of concepts” define o número máximo de conceitos que serão seleccionados.

Também aqui é possível escolher uma simulação com ou sem aprendizagem (opção “No Learning”) e optar entre estímulos com apenas o conceito seleccionado no momento, ou acumular os conceitos formando *inputs* com os vários nós seleccionados activos (opção “Accumulate concepts in patterns”).

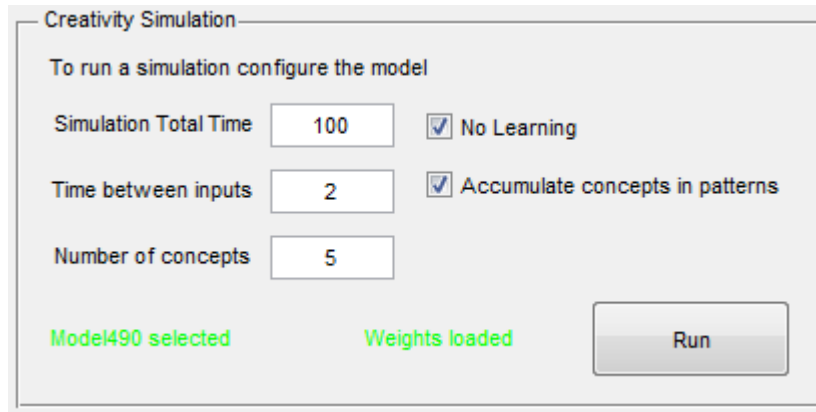


Figura 50 – GUI: Painel de Execução de Simulação de Criatividade

### 6.3.5. Visualização de Resultados

Quando é finalizada uma simulação surge o ecrã de visualização de resultados (Figura 51).

Neste ecrã são demonstrados graficamente vários resultados da simulação efectuada. No canto superior esquerdo, o gráfico de maior dimensão apresenta a evolução do nível de activação para cada um dos nós do modelo.

Em baixo, podem ser mostradas diversas informações, como por exemplo, a evolução dos pesos ao longo da simulação.

No lado direito do ecrã, é apresentado o estado final da rede, com a respectiva representação gráfica e com a lista de conceitos e respectivo nível de activação. É possível ainda analisar cada instante de tempo da simulação, preenchendo o campo “Time” e usando o botão “Show”, ou alternar entre instantes usando os botões “+1” e “-1”.

O padrão com as activações do estado final, ou qualquer outro instante temporal pode ser guardado através do botão “Save Pattern”.

É possível ainda guardar os dados da aprendizagem efectuada durante a simulação, para posterior uso, através do botão “Save weights”, e toda a imagem através do botão “Save FIG”.

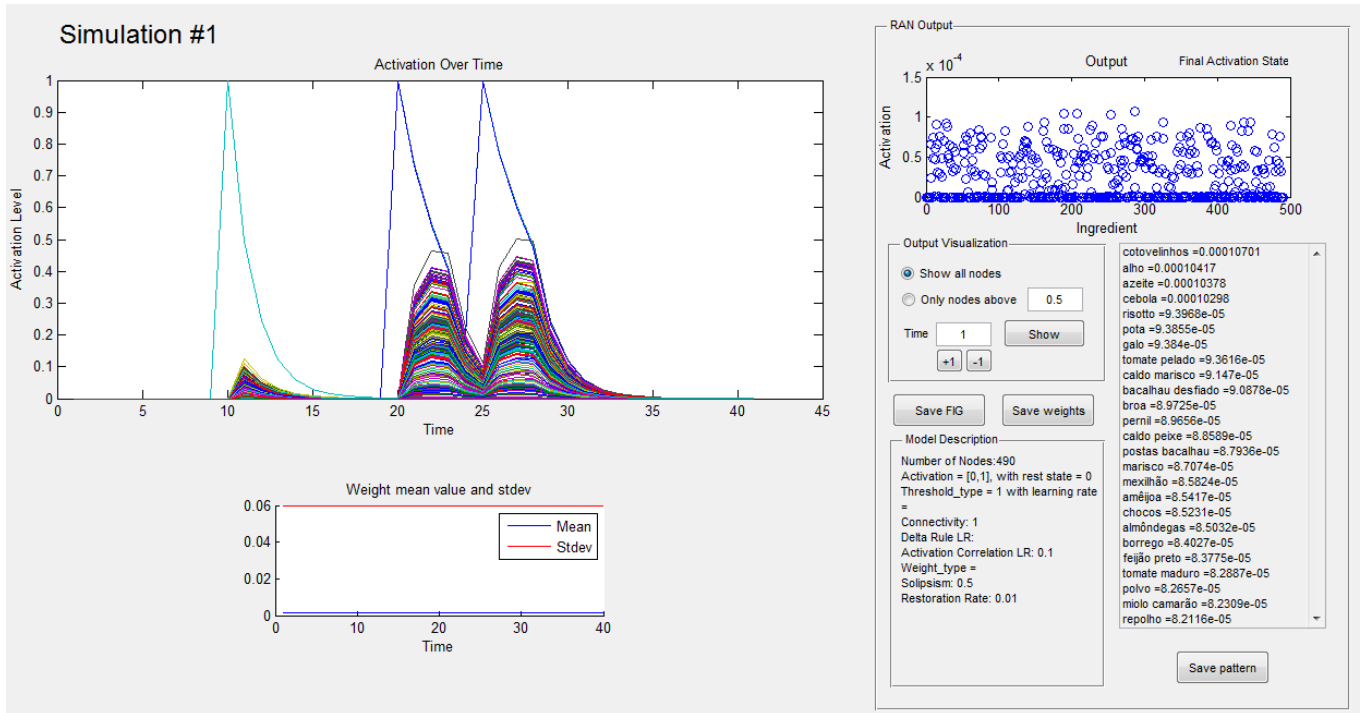


Figura 51 – GUI: Painel de Visualização de Resultados

## 7. Conclusões e Trabalho Futuro

Nesta tese, definimos uma primeira versão reduzida do modelo cognitivo RANs.

Foram explorados diferentes métodos relativos à injeção de activação, aprendizagem e propagação de activação, possibilitando a análise da importância dos parâmetros definidos para o modelo bem como a sua aplicação na modelação dos fenómenos do *Priming* e DRM. Destaca-se a conclusão de que o factor de solipsismo definido para a rede tem uma grande importância na modelação destes fenómenos e poderá ser aplicado na simulação de patologias em que os efeitos deste fenómeno não se verificam. Por outro lado, não ficou constatada uma importância conclusiva do factor de reposição, não tendo sido provada a sua importância para a modelação dos fenómenos. Neste momento, podemos afirmar que o modelo consegue com sucesso representar conceptualmente estes fenómenos. Para uma avaliação mais criteriosa destes fenómenos, poder-se-á considerar futuramente uma contribuição de experts no domínio da psicologia que atestem a validade dos resultados obtidos.

Quanto à aplicação do modelo na simulação de fenómenos criativos, o primeiro passo futuro será o desenvolvimento de um processo para a medida do critério do valor dos artefactos criados. Com essa avaliação quantitativa, poderão ser tiradas mais conclusões sobre a qualidade dos processos convergentes da rede, designadamente, a qualidade dos métodos de aprendizagem e propagação e a sua aplicabilidade na simulação de processos criativos.

Durante os trabalhos efectuados nesta Tese, o artigo *Principles of Regulated Activation Networks*, onde são descritos os princípios gerais do modelo RANs, foi submetido com sucesso à conferência *International Conference on Conceptual Structures (ICCS 2014)*. A validação obtida por parte da comunidade científica e o progresso verificado desde então, permitem-nos estar optimistas em relação às potencialidades do modelo a longo prazo.

Num futuro próximo, será escrito um segundo artigo sobre a modelação do *Priming* e DRM, após mais testes com diferentes regras de aprendizagem e métodos de propagação.

Foi também desenvolvida uma ferramenta de suporte à experimentação do modelo. Esta revelou-se bastante útil durante a efectuação de experiências, contribuindo para a sua sistematização e eficiência. O desenvolvimento teve em conta a sua futura utilização por parte de um estudante de doutoramento que foi integrado neste projecto, com o qual foi estabelecida uma cooperação ao nível da análise de requisitos.

Para trabalho futuro, poder-se-á considerar a adição de um módulo mais avançado para a edição de padrões de *input*, e o acompanhamento da ferramenta em relação à evolução do modelo.

# Referências

- Almeida, José Miguel Caldas de e Xavier, Miguel. 2012.** *Estudo Epidemiológico Nacional De Saúde Mental*. Lisboa : Faculdade de Ciências Médicas, Universidade Nova de Lisboa, 2012.
- Anderson, J. R., et al. 2004.** An integrated theory of the mind. *Psychological Review*. 2004, Vol. 111, 4.
- Bengio, Yoshua, et al. 2011.** Deep Learners Benefit More from Out-of-Distribution Examples. *Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics (AISTATS 2011)*. 2011.
- Bowers, K. S., Farvolden, P. e Mermigis, L. 1995.** Intuitive antecedents of insight. [autor do livro] S. M. Smith, T. B. Ward e R.A. Finke. *The creative cognition approach*. Cambridge, MA : MIT Press, 1995.
- Braver, Todd S., Barch, Deanna M. e Cohen, Jonathan D. 1999.** Cognition and Control in Schizophrenia: A Computational Model of Dopamine and Prefrontal Function. *Biol Psychiatry*. 46, 1999, Vol. 3.
- Cardoso, Amílcar, Veale, Tony e Wiggins, Geraint A. 2009.** Converging on the Divergent: The History (and Future) of the International Joint Workshops in Computational Creativity. *AI Magazine*. 2009, Vol. 30, 3, pp. 15-22.
- Chambers, Richard, Gullone, Eleonora e Allen, Nicholas B. 2009.** Mindful emotion regulation: An integrative review. *Clinical Psychology Review*. 2009, Vol. 29, 6, pp. 560-572.
- Chittajallu, Ramesh, Pelkey, Kenneth A. e McBain, Chris J. 2013.** Neurogliaform cells dynamically regulate somatosensory integration via synapse-specific modulation. *Nature Neuroscience*. 2013, Vol. 16.
- Colton, Simon e Wiggins, Geraint A. 2012.** Computational Creativity: A Final Frontier? *Proceedings of ECAI*. 2012.
- Costa, Ernesto e Lopes, Rui L. 2012.** The Regulatory Network Computational Device. *Genetic Programming and Evolvable Machines*. 2012, Vol. 13, 3.
- Creating false memories: Remembering words not presented in lists.* **Roediger, Henry L. e McDermott, Kathleen B. 1995.** 4, 1995, *Journal of Experimental Psychology: Learning, Memory, and Cognition*, Vol. 21.
- Elman, Jeffrey L. 1990.** Finding structure in time. *Cognitive Science*. 1990, Vol. 14, 2.
- . **1993.** Learning and development in neural networks: the importance of starting small. *Cognition*. 1993, Vol. 48, 1.
- Erickson, R. P. 1984.** Ohrwall, Henning and von Skramlik; the foundations of the four primary positions in taste. *Neuroscience & Biobehavioral Reviews*. 1984, Vol. 8, 1.
- Fum, Danilo, Del Missier, Fabio e Stocco, Andrea. 2007.** The cognitive modeling of human behavior: Why a model is (sometimes) better than 10,000 words. *Cognitive Systems Research*. 2007, Vol. 8, 3.
- Gärdenfors, Peter. 1997.** Symbolic, conceptual and subconceptual representations. [autor do livro] V. Cantoni, et al. *Human and Machine Perception: Information Fusion*. New York : Plenum Press, 1997, pp. 255-270.
- Gerstner, Wulfram, Kempter, Richard e Van Hemmen, J. Leo. 1999.** Hebbian Learning of Pulse Timing in the Barn Owl Auditory System. *Pulsed Neural Networks, chapter 14*. s.l. : MIT Press, 1999.

**Goela, Vinod, Pullara, David e Grafman, Jordan. 2001.** A computational model of frontal lobe dysfunction: working memory and the Tower of Hanoi task. *Cognitive Science*. 2001, Vol. 25, 2.

**Grady, Robert B. 1992.** *Practical Software Metrics for Project Management and Process Improvement*. Upper Saddle River, NJ, USA : Prentice-Hall, 1992. 0-13-720384-5.

**Gross, J. J. 1998.** The emerging field of emotion regulation: An integrative review. *Review of General Psychology*. 1998, Vol. 2, 3.

**H.U. Wittchen, F. Jacobi, J. Rehm, A. Gustavsson, M. Svensson, B. Jönsson, J. Olesen, C. Allgulander, J. Alonso, C. Faravelli, L. Fratiglioni, P. Jennum, R. Lieb, A. Maercker, J. van Os, M. Preisig, L. Salvador-Carulla, R. Simon, H.-C. Steinhausen. 2011.** The size and burden of mental disorders and other disorders of the brain in Europe 2010. *European Neuropsychopharmacology*. 2011, Vol. 21, 9.

**International Institute of Business Analysis. 2009.** *A Guide to the Business Analysis Body of Knowledge® (BABOK® Guide)*. Toronto, Ontario, Canada : International Institute of Business Analysis, 2009. 978-0-9811292-1-1.

**Jacoby, L.L. 1983.** Perceptual Enhancement: Persistent Effects of an Experience. *Journal of Experimental Psychology: Learning, Memory, and Cognition*. 1983, Vol. 9.

**John E. Laird, Karen J. Coulter , Olph M. Jones , Patrick G. Kenny , Frank Koss , Paul E. Nielsen. 1998.** Integrating intelligent computer generated forces in distributed simulation: TacAir-Soar. in *STOW-97. Proceedings of the 1998 Simulation Interoperability Workshop*. 1998.

**Jordanous, Anna Katerina. 2012.** *Evaluating Computational Creativity: A Standardised Procedure for Evaluating Creative Systems and its Application*. Brighton, UK : University of Sussex, 2012.

**Just, Marcel A. e Carpenter, Patricia A. 1992.** A capacity theory of comprehension: Individual differences in working memory. *Psychological Review*. 1992, Vol. 99, 1.

**Just, Marcel Adam e Varma, Sashank. 2007.** The organization of thinking: What functional brain imaging reveals about the neuroarchitecture of complex cognition. *Cognitive, Affective, & Behavioral Neuroscience*. 2007, Vol. 7, 3, pp. 153-191.

**Just, Marcel Adam, Carpenter, Patricia A. e Hemphill, Darold D. 1996.** Constraints on processing capacity: Architectural or implementational. *Mind matters: A tribute to Allen Newell*. 1996.

**Kohonen, Teuvo. 1982.** Self-organized formation of topologically correct feature maps. *Biological Cybernetics*. January (II), 1982, Vol. 43.

**Kokinov, B. 1994.** The DUAL cognitive architecture: A hybrid multi-agent approach. [ed.] A. Cohn. *Proceedings of the Eleventh European Conference on Artificial Intelligence*. 1994.

**Kokinov, B., Nikolov, V. e Petrov, A. 1996.** Dynamics of Emergent Computation in DUAL. [ed.] A. Ramsay. *Artificial intelligence: Methodology, systems, applications*. 1996.

**Kyaga, Simon e Mikael Landén, Marcus Boman, Christina M. Hultman, Niklas Långström, Paul Lichtenstein. 2013.** Mental illness, suicide and creativity: 40-Year prospective total population study. *Journal of Psychiatric Research*. 2013, Vol. 47, 1.

**Laird, J. E. e Congdon, C. B. 2012.** *The Soar User's Manual Version 9.3.2*. Computer Science and Engineering Department, University of Michigan. 2012.

**Laird, John E., Newell, Allen e Rosenbloom, Paul S. 1987.** SOAR: An architecture for general intelligence. *Artificial Intelligence*. 1987, 33.

- Lennie, Peter. 2003.** The Cost of Cortical Computation. *Current Biology*. 2003, Vol. 13.
- Luchins, Abraham S. 1942.** Mechanization in problem solving: The effect of Einstellung. . *Psychological Monographs*. 1942, Vol. 54, 6.
- Maher, M. L. e Fisher, D. H. 2012.** Using AI to evaluate creative designs. In *Proceedings of International Conference on Creative Design*. 2012.
- Marinier, R. P. e Laird, J. E. 2004.** Toward a comprehensive computational model of emotions and feelings. 2004. pp. 172-177.
- Matsukawa, Junko, Snodgrass, Joan Gay e Doniger, Glen M. 2005.** Conceptual versus perceptual priming in incomplete picture identification. *Journal of Psycholinguistic Research*. 2005, Vol. 34, 6.
- McClelland, James L. e Rumelhart, David E. 1981.** An Interactive Activation Model of Context Effects in Letter Perception: Part 1. An Account of Basic Findings. *Psychological Review*. 1981, Vol. 88.
- . **1982.** An Interactive Activation Model of Context Effects in Letter Perception: Part2. The Contextual Enhancement Effect and Some Tests and Extensions of the Model. *Psychological Review*. 1982, Vol. 89.
- . **1986.** On Learning the Past Tenses of English Verbs. [autor do livro] James L. McClelland, and CORPORATE PDP Research Group David E. Rumelhart. *Parallel distributed processing: explorations in the microstructure of cognition, vol. 2*. Cambridge : MIT Press, 1986.
- McCulloch, Warren S. e Pitts, Walter. 1943.** A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*. 1943, Vol. 5, 4.
- Millodot, Michel. 2009.** *Dictionary of Optometry and Visual Science, 7th Edition*. s.l. : Butterworth-Heinemann, 2009. 978-0-7020-2958-5.
- Newell, A. 1990.** *Unified Theories of Cognition*. Cambridge : Harvard University Press, 1990.
- Ochsner, Kevin N., Silvers, Jennifer A. e Buhle, Jason T. 2012.** Functional imaging studies of emotion regulation: a synthetic review and evolving model of the cognitive control of emotion. *Annals of the New York Academy of Sciences*. 2012, Vol. 1251, 1.
- Oláh, Szabolcs, et al. 2009.** Regulation of cortical microcircuits by unitary GABAergic volume transmission. *Nature*. Outubro de 2009, Vol. 461, 7268.
- O'Reilly, Randall C. 2006.** Biologically Based Computational Models of High-Level Cognition. *Science*. 2006, Vol. 314, 5796.
- Organization, World Health. 2011.** *Global burden of mental disorders and the need for a comprehensive, coordinated response from health and social sectors at the country level*. 2011.
- Panzanelli, Patrizia, et al. 2011.** Distinct mechanisms regulate GABAA receptor and gephyrin clustering at perisomatic and axo-axonic synapses on CA1 pyramidal cells. *The Journal of Physiology*. 2011, Vol. 589, 20.
- Pereira, Francisco Câmara. 2007.** *Creativity and AI: A Conceptual Blending Approach*. Berlim : Mouton de Gruyter, 2007. 978-3-11-018609-3.
- Rankin, Catharine H., et al. 2009.** Habituation Revisited: An Updated and Revised Description of the Behavioral Characteristics of Habituation. *Neurobiol Learn Mem*. 2009, Vol. 92, 2.
- Roediger, Henry L. e Blaxton, Teresa A. 1987.** Effects of varying modality, surface features, and retention interval on priming in word-fragment completion. *Memory & Cognition*. 1987, Vol. 15, 5.



**Rolls, Edmund T., et al. 2008.** Computational models of schizophrenia and dopamine modulation in the prefrontal cortex. *Nature Reviews Neuroscience*. 9, 2008.

**Rubioff, R. e Lehman, Jill Fain. 1994.** Real-time natural language generation in NL-Soar. *INLG '94 Proceedings of the Seventh International Workshop on Natural Language Generation*. 1994.

**Seifert, C. M., et al. 1994.** Demystification of cognitive insight: Opportunistic assimilation and the prepared-mind perspective. [autor do livro] R.J. Sternber e J.E. Davidson. *The nature of insight*. Cambridge, MA : MIT Press, 1994.

**Smith, Steven M. e Ward, Thomas B. 2012.** Cognition and the Creation of Ideas. [ed.] K. Holyoak & R. Morrison. *Oxford Handbook of thinking and reasoning*. s.l. : Oxford University Press, 2012, pp. 456-474.

**Sommerville, Ian. 2011.** *Software Engineering - 9th Edition*. s.l. : Addison-Wesley, 2011. 978-0-13-703515-1.

**Sun, Ron. 2003.** A Tutorial on CLARION 5.0. 2003.

–. 2008. *The Cambridge Handbook of Computational Psychology*. Cambridge : Cambridge University Press, 2008.

–. 2006. The CLARION cognitive architecture: Extending cognitive modeling to social simulation. *Cognition and Multi-Agent Interaction*. New York : Cambridge University Press, 2006.

**Thibadeau, Robert, Just, Marcel Adam e Carpenter, Patricia A. 1982.** A Model of the Time Course and Content of Reading. *Cognitive Science*. 1982, Vol. 6.

**Thorpe, Simon J., Delorme, Arnaud e VanRullen, Rufin. 2001.** Spike-based strategies for rapid processing. *Neural Networks*. 2001, Vol. 14.

**Wang, X. e Sun, Q.Q. 2012.** Characterization of axo-axonic synapses in the piriform cortex of *Mus musculus*. *J Comp Neurol*. 2012, Vol. 520, 4.

**Watt, Douglas F. 2004.** Consciousness, emotional self-regulation and the brain: Review article. *Journal of Consciousness Studies*. 2004, Vol. 11, 9.

**Watts, Duncan J. e Strogatz, Steven H. 1998.** Collective dynamics of 'small-world' networks. *Nature*. 393, 1998.

**Wei, Gang e Yu, Zheyuan. 2007.** Storage Capacity of Letter Recognition in Hopfield Networks . 2007.