

Aplicação de Modelos de Redes Neurais na Elaboração e Análise de Cenários Macroeconômicos

Maurílio Benite

Dissertação apresentada à Escola de Engenharia de São Carlos da Universidade de São Paulo, como parte dos requisitos para obtenção do título de Mestre em Engenharia de Produção

ORIENTADOR: Prof. Dr. Marcelo Seido Nagano

São Carlos

2003

A meus pais, José Maurício e Sônia,

Pelo apoio em todos estes anos

Ao Prof. Dr. Marcelo Seido Nagano, pela orientação segura, pelo incentivo, pela amizade e por tudo aquilo que me ensinou no decorrer da realização deste trabalho.

Ao Prof. Titular João Vitor Moccellin e ao Prof. Dr. Edgard Monforte Merlo, pelos valiosos comentários e sugestões durante o Exame de Qualificação.

Ao Prof. Dr. Renato Vairo Belhot, pelo apoio no início desta caminhada.

À Marisley, por estar sempre presente nos momentos importantes da minha vida, pelo carinho, companheirismo e incentivo desde meu ingresso até a conclusão deste trabalho de Pós-Graduação.

Ao CNPq – Conselho Nacional de Desenvolvimento Científico e Tecnológico, pelo apoio financeiro.

A todos os funcionários da Pós-Graduação do Departamento de Engenharia de Produção da EESC – USP, especialmente José Luís e Silvana, pela paciência, colaboração e boa vontade.

Aos companheiros Gargamel, Leandro e Tião, pela força.

SUMÁRIO

LISTA DE FIGURAS.....	v
LISTA DE TABELAS.....	vi
LISTA DE ABREVIATURAS E SIGLAS.....	viii
LISTA DE SÍMBOLOS.....	x
RESUMO.....	xiii
<i>ABSTRACT</i>.....	xiv
1 INTRODUÇÃO.....	1
1.1 Justificativa.....	3
1.2 Objetivo.....	6
2 CENÁRIOS E COMPLEXIDADE SISTÊMICA.....	8
2.1 Cenários.....	8
2.2 Ambientes complexos e a Cibernética.....	10
3 REDES NEURAIIS ARTIFICIAIS E SUAS APLICAÇÕES.....	13
3.1 Condições e descrição da ativação neural.....	15
3.2 Aprendizado neural.....	18
3.3 Arquitetura e processamento neurais básicos.....	19
3.4 Treinamento de uma rede neural genérica.....	24
3.5 Aplicações em redes neurais artificiais.....	27
4 REDES NEURAIIS AUTO-ORGANIZADAS.....	30
4.1.1 Teoria de Ressonância Adaptativa – Redes ART.....	31

4.1.2	Operação e parâmetros de uma Rede ART-2.....	38
4.1.3	Algoritmo de treinamento de uma Rede ART-2.....	40
4.2.1	Redes SOM.....	41
4.2.2	Conceito de vizinhança em redes SOM.....	44
4.2.3	Operação e algoritmo de uma rede SOM.....	46
4.3	Redes neurais auto-organizadas e a proposta deste estudo.....	49
5	ABORDAGEM NEURAL NÃO SUPERVISIONADA NA ELABORAÇÃO E ANÁLISE DE CENÁRIOS MACROECONÔMICOS.....	50
5.1	Fase 1.....	61
5.2	Fase 2.....	65
5.3	Fase 3.....	68
5.4	Fase 4.....	100
5.5	Análise dos resultados obtidos.....	101
6	CONSIDERAÇÕES FINAIS.....	103
	REFERÊNCIAS BIBLIOGRÁFICAS.....	107
	OBRAS CONSULTADAS.....	114
	APÊNDICE A – FUNÇÕES DE ATIVAÇÃO	
	APÊNDICE B – PAÍSES ESTUDADOS POR CONTINENTE	

LISTA DE FIGURAS

FIGURA 1: Esquema de um neurônio biológico.....	13
FIGURA 2: Fronteiras de classificação linear e neural.....	17
FIGURA 3: Esquema de uma rede neural genérica.....	22
FIGURA 4: Arquitetura de uma rede ART-2.....	35
FIGURA 5: Arquitetura de uma rede SOM.....	43
FIGURA 6: Conceito de região de vizinhança em um arranjo retangular de neurônios.....	45
FIGURA 7: Sistema neural híbrido usado na elaboração e estudo de cenários macroeconômicos.....	52
FIGURA 8: Exemplo de mapa topológico utilizado no estudo.....	70
FIGURA 9: Regiões de ativação neural dos <i>clusters</i> ρ_{4c2} , ρ_{7c2} e ρ_{9c2}	71
FIGURA 10: Regiões de ativação neural dos <i>clusters</i> ρ_{4c3} , ρ_{7c3} e ρ_{9c3}	73
FIGURA 11: Regiões de ativação neural do <i>cluster</i> ρ_{4c4}	75
FIGURA 12: Regiões de ativação neural do <i>cluster</i> ρ_{7c5}	80
FIGURA 13: Regiões de ativação neural do <i>cluster</i> ρ_{9c6}	85
FIGURA 14: Regiões de ativação neural do <i>cluster</i> ρ_{9c7}	87
FIGURA 15: Regiões de ativação neural do <i>cluster</i> ρ_{9c8}	89
FIGURA 16: Regiões de ativação neural do <i>cluster</i> ρ_{9c9}	91
FIGURA 17: Regiões de ativação neural do <i>cluster</i> ρ_{9c10}	93
FIGURA 18: Regiões de ativação neural do <i>cluster</i> ρ_{9c11}	96
FIGURA 19: Regiões de ativação neural do <i>cluster</i> ρ_{9c12}	98

LISTA DE TABELAS

TABELA 1: Países de renda <i>per capita</i> baixa, de acordo com WORLD BANK (1995).....	58
TABELA 2: Países de renda <i>per capita</i> média-baixa, de acordo com WORLD BANK (1995).....	59
TABELA 3: Países de <i>per capita</i> média, de acordo com WORLD BANK (1995).....	59
TABELA 4: Países de <i>per capita</i> média-alta, de acordo com WORLD BANK (1995).....	60
TABELA 5: Países de <i>per capita</i> alta, de acordo com WORLD BANK (1995).....	61
TABELA 6: Quantidade de <i>clusters</i> obtidos para cada valor de ρ empregado no estudo.....	62
TABELA 7: Quantidade de países em cada um dos <i>clusters</i> obtidos para $\rho = 0,4$	63
TABELA 8: Quantidade de países em cada um dos <i>clusters</i> obtidos para $\rho = 0,7$	64
TABELA 9: Quantidade de países em cada um dos <i>clusters</i> obtidos para $\rho = 0,9$	64
TABELA 10: Países contidos em cada cluster, para $\rho = 0,4$	66
TABELA 11: Países contidos em cada cluster, para $\rho = 0,7$	66
TABELA 12: Países contidos em cada cluster, para $\rho = 0,9$	67
TABELA 13: Neurônios vencedores para cada país nos <i>clusters</i> ρ_{4c2} , ρ_{7c2} e ρ_{9c2}	72
TABELA 14: Neurônios vencedores para cada país nos <i>clusters</i> ρ_{4c3} , ρ_{7c3} e ρ_{9c3}	74
TABELA 15: Neurônios vencedores para cada país no <i>cluster</i> ρ_{4c4}	76
TABELA 16: Neurônios vencedores para cada país no <i>cluster</i> ρ_{7c5}	81
TABELA 17: Neurônios vencedores para cada país no <i>cluster</i> ρ_{9c6}	86

TABELA 18: Neurônios vencedores para cada país no <i>cluster</i> ρ_9c7	88
TABELA 19: Neurônios vencedores para cada país no <i>cluster</i> ρ_9c8	90
TABELA 20: Neurônios vencedores para cada país no <i>cluster</i> ρ_9c9	92
TABELA 21: Neurônios vencedores para cada país no <i>cluster</i> ρ_9c10	94
TABELA 22: Neurônios vencedores para cada país no <i>cluster</i> ρ_9c11	97
TABELA 23: Neurônios vencedores para cada país no <i>cluster</i> ρ_9c12	99

LISTA DE ABREVIATURAS

ARCH - *Autoregressive Conditional Heteroskedasticity*

ART – *Adaptive Resonance Theory*

BAM – *Bidirectional Associative Memory*

BSB – *Brain State in a Box*

BPI – *Business Periodics Index*

CMAC – *Cerebellar Model Articulation Controller*

DCL – *Differential Competitive Learning*

FIR – *Finite Impulse Response*

GARCH – *Generalized Autoregressive Conditional Heteroskedasticity*

GRNN – *General Regression Neural Network*

IEEE – *Institute of Electrical and Electronics Engineers*

IPVR – *Institute for Parallel and Distributed High Performance Systems*

LVQ – *Learning Vector Quantization*

MLP – *Multi Layer Perceptron*

NN – *Neural Network*

OLS – *Orthogonal Least Squares*

PNN – *Probabilistic Neural Networks*

RBF – *Radial Basis Function*

RPROP – *Recurrent Back-Propagation*

SOM – *Self-Organizing Map*

SNNS – *Stuttgart Neural Network Simulator*

TDNN – *Time Delay Neural Network*

LISTA DE SÍMBOLOS

a - pesos fixos ascendentes da camada F1 em redes ART

a_{ij} - conexão neuronal ascendente da camada F1b à camada F2 em redes
ART

b - pesos fixos descendentes na camada F1 em redes ART

C1 - neurônio de controle de apresentação de dados para F1 em redes
ART

C2 - neurônio de controle de apresentação de dados para F2 em redes
ART

c - peso fixo utilizado no teste de *reset* em redes ART

D - vetor de dados descendente comparado aos padrões contidos em F2
em redes ART

D_j - distância entre as ponderações do padrão d entrada e do neurônio j
em redes SOM

D_n - arranjo dimensional de neurônios em redes SOM

d - ativação da unidade F2 vencedora em redes ART

d_{ij} - conexão neuronal descendente da camada F1b à camada F2 em redes ART

ϵ - parâmetro preventivo de divisão por zero no treinamento de redes ART

F1 - camada de processamento dos vetores de entrada em redes ART

F1a - camada de neurônios de pré-processamento dos dados de entrada em redes ART-2

F1b - camada de neurônios de transmissão de dados pré-processados em redes ART-2

F2 - neurônios representativos de cada categoria em redes ART

I - vetor de dados de entrada em redes ART

L - regra de aprendizagem neuronal em redes SOM

m - neurônio vencedor em redes SOM

n - número de unidades de entrada de uma rede ART

r_i - posição relativa de um neurônio em redes SOM

r_m - posição relativa de um neurônio vencedor em redes SOM

t - número de ciclos do treinamento de redes ART

$V_m(t)$ - região de vizinhança de um neurônio vencedor em redes SOM

W_{ij} - ponderações dos dados de entrada e dos neurônios do mapa topológico em redes SOM

z - número de unidades de *cluster* em redes ART

α - taxa de aprendizagem de uma rede ART

ρ - parâmetro de vigilância de uma rede ART

σ - função de controle de aprendizado da região de vizinhança de redes

SOM

Ω - número de ciclos de treinamento em redes SOM

RESUMO

BENITE, M. (2003). *Aplicação de modelos de redes neurais na elaboração e análise de cenários macroeconômicos*. São Carlos, 2003. 123 p. Dissertação (Mestrado) – Escola de Engenharia de São Carlos, Universidade de São Paulo.

Este estudo versa sobre uma investigação de viabilidade da utilização de redes neurais auto-organizadas na classificação e exploração de dados macroeconômicos. Para tanto, foi elaborado um método no qual foram empregadas topologias neurais auto-organizadas, procurando assim explorar as características de melhor desempenho de cada um dos modelos, sob um enfoque seqüencial e com o intuito de se adquirir conhecimento intermediário em cada uma de suas fases, diminuindo o impacto da complexidade tanto no tempo requerido para realização da tarefa quanto na análise dos resultados. Os próprios resultados obtidos sugerem que a utilização de redes neurais artificiais auto-organizadas na aquisição de conhecimento sobre bases de dados aplicáveis às Ciências Econômicas apresenta desempenho análogo aos modelos paramétricos tradicionalmente empregados na construção de cenários com tais informações.

Palavras-chave: redes neurais auto organizadas; dados macroeconômicos; cenários e complexidade.

ABSTRACT

BENITE, M. (2003). *Application of neural network models in macroeconomic scenarios building and analysis*. São Carlos, 2003. 123 p. Dissertação (Mestrado) – Escola de Engenharia de São Carlos, Universidade de São Paulo.

This study turns on an inquiry of viability of the use of self-organizing neural nets in classification and exploration of macroeconomic data. For this purpose, a method in which had been used self-organized neural topologies was elaborated, looking to explore the better characteristics of performance of each one of the models, under a sequential approach and with objective of acquiring intermediate knowledge in each one of its phases, diminishing the impact of the complexity as in time consuming as in analysis of results. Main results obtained suggest the use of self-organized artificial neural nets in acquisition of knowledge on Economic databases presents analog performance to traditional parametric models in scenarios building.

Keywords: self-organizing neural networks; macroeconomic data; scenarios and complexity.

1 INTRODUÇÃO

A necessidade de conhecer as causas e o desejo de controlar o nível de incerteza que cerca diversos aspectos da vida têm sido temas centrais das relações do Homem com a Natureza e seus eventos futuros. Sob um ambiente de incerteza, freqüentemente torna-se necessária a tomada de decisões enquadradas em circunstâncias as quais se têm pouco conhecimento acerca das conseqüências futuras, o que torna interessante a elaboração de uma perspectiva dos possíveis efeitos que redundarão destas decisões.

De maneira a lidar com este problema, deve haver a possibilidade de se identificar potenciais de sucesso e fracasso ao longo do tempo e, se possível, monitorar e controlar seu processo gerador. Pensando nos diferentes resultados possíveis de um determinado evento a ser realizado como diferentes estados de natureza de um processo, sob uma situação ótima deve haver sempre um plano contingente elaborado através da especificação geral dos vários resultados possíveis deste processo em relação ao futuro (VARIAN, 1994). A mais utilizada forma de se prover a informação requerida para uso em processos decisórios é a utilização de cenários (GODET & ROUBELAT, 1996; GAUSEMEIER, FINK & SCHLAKE, 1998). A elaboração e o gerenciamento de cenários são métodos importantes e amplamente utilizados no acompanhamento de processos de planejamento, e com base em suas projeções são efetuados ajustes e correções nestes processos com o intuito de se alcançar metas e traçar objetivos de maneira satisfatória (GODET, 1987).

Uma metodologia operacional bastante usual de se elaborar um cenário consiste na restrição do campo de estudo a partir da definição e delimitação de um determinado sistema a ser abordado e explorado analiticamente. Um sistema qualquer consiste de um grupo de elementos inter-relacionados, coordenados de maneira a formar um conjunto (GAUSEMEIER, FINK & SCHLAKE, 1998). As estruturas de um sistema, como por exemplo, a rede de relacionamentos entre seus elementos, é essencial na compreensão de sua evolução na medida em que se mantém alguma estabilidade global. O papel de uma análise estrutural é destacar o arranjo dos relacionamentos entre as variáveis envolvidas, independentemente de serem quantificáveis ou não, as quais caracterizam o sistema em questão. Contudo, tais estruturas, além de seu estado momentâneo, por muitas vezes também apresentam uma evolução temporal (GODET, 1987) que apresenta basicamente as seguintes características:

- Tendência à variação: novas tecnologias, regulamentação, intervenção e expectativas são fatores que provocam um aumento contínuo do número de variáveis que influenciam um determinado estado;
- Tendência dinâmica: a interação ao longo do tempo entre as variáveis explicativas causa freqüentes modificações nos processos que geram estados futuros.

Muitos sistemas apresentam estas duas tendências simultaneamente, e a união entre as mesmas pode gerar um considerável aumento na sua complexidade, fazendo com que a efetividade de métodos tradicionais de gerenciamento e controle torne-se cada vez menor ao longo do tempo. A interdependência entre os diversos fatores de influência desempenha um papel fundamental na compreensão destes sistemas, e uma abordagem apropriada para seu monitoramento seria a idéia de um conjunto de influências coligadas (GAUSEMEIER, FINK & SCHLAKE, 1998) a serem gerenciadas como um todo.

1.1 Justificativa

A construção de uma metodologia de apoio à decisão baseada na obtenção dos seus possíveis estados e o posterior agrupamento de seus elementos constituintes através do uso de técnicas de processamento exclusivamente matemático, com o intuito de se acompanhar e monitorar tanto o estado quanto a trajetória de um determinado sistema, seria interessante sob o ponto de vista não só de monitoramento e gerenciamento deste sistema bem como da verificação da aplicabilidade da técnica em relação ao problema proposto. Dentre as mais diversas técnicas adequadas a este tipo de aplicação, destacam-se os modelos de redes neurais artificiais como uma alternativa interessante na construção de tecnologias de suporte à decisão. Redes neurais artificiais apresentam características específicas, intrínsecas à sua formulação, que possibilitam a aproximação de qualquer função contínua, inclusive funções não lineares complexas, e também podem generalizar os resultados obtidos para dados previamente desconhecidos, ou seja, produzir respostas coerentes e apropriadas para padrões ou exemplos que não foram utilizados em seu treinamento (FAUSETT, 1994; HAYKIN, 1994; BISHOP, 1995).

Através do uso de modelos de redes neurais, mais especificamente aqueles conhecidos como modelos neurais auto-organizados, podem ser ilustradas as estruturas contidas em uma base de dados arbitrária, que descrevem diferentes aspectos de um determinado fenômeno de interesse. Pode-se citar como exemplo, que em tarefas de reconhecimento de imagens, uma base de dados deve ser trabalhada tendo-se em mente a necessidade de se descrever um determinado estado do sistema que define o conjunto, como no caso de reconhecimento de alvos ou no diagnóstico de doenças. Quando modelos neurais

são usados para representar um estado, esta representação pode ser considerada como um modelo não paramétrico deste sistema, produzido automaticamente (KOHONEN, 1989).

No âmbito da análise dos resultados obtidos, seria desejável a existência de conhecimento que direcione a qualidade dos resultados disponibilizados pelo sistema; contudo este conhecimento pode ser excessivamente complexo, não estar padronizado ou mesmo não existir, e assim poderia-se contar com os resultados obtidos pelo processamento dos dados disponíveis realizado pelo próprio sistema, monitorando-os ao longo do tempo para que seu aperfeiçoamento conduza a resultados cada vez mais aderentes às necessidades dos usuários (LAUDON & LAUDON, 1996).

Como técnica alternativa para a realização deste tipo de tarefa, existem modelos neurais particulares auto-organizados conhecidos como redes SOM (*Self-Organizing Maps*) que podem ser usados em uma apresentação visual das estruturas contidas em qualquer base de dados. Se estes dados descrevem o estado de um mesmo sistema em momentos distintos, como no caso de uma análise de série de tempo, os relacionamentos entre estes casos serão evidenciados. Por outro lado, se os dados descrevem os estados de diferentes sistemas, estes sistemas se tornarão comparáveis entre si (KASKI & KOHONEN, 1996).

Não há dúvidas de que existem técnicas muito diversas para a realização de uma mesma tarefa matemática (ZHANG, PATUWO & HU, 1998), inclusive no caso da elaboração e análise de cenários (GAUSEMEIER, FINK & SCHLAKE, 1998). Existem diversos procedimentos paramétricos consagrados que são largamente utilizados para a análise de dados e suas estruturas subjacentes, dentre os quais pode-se citar:

- Análise Multivariada: técnica estatística, que consiste no estudo dos relacionamentos entre variáveis contidas em arranjos matriciais, sendo possível também sua aplicação na geração e análise de *clusters* (JOHNSON & WICHERN, 1992);
- Metodologia Box-Jenkins: estudo da evolução temporal de uma ou mais variáveis e modelagem de fenômenos através do inter-relacionamento entre variáveis dependentes e independentes ocorrido através do tempo (BOX & JENKINS, 1976);
- Modelos Heterocedásticos ARCH-GARCH: modelos focados no relaxamento da hipótese estatística de variância constante nos dados de diversas amostras de uma população (ENGLE, 2001).

Porém, a despeito de sua inegável utilidade, estes modelos tradicionais apresentam características que geram dificuldades operacionais para sua efetiva aplicação, como o problema inerente em se trabalhar com modelos estatísticos complexos, suas hipóteses restritivas a serem satisfeitas e a dificuldade em se alcançar conclusões e resultados por não especialistas (SERRANO-CINCA, 1996). Modelos de redes neurais artificiais auto-organizados possuem a vantagem de não exigirem do usuário a aplicação de nenhuma teoria acerca da organização destes dados, e podem fornecer subsídios para a atualização ou mesmo formulação de novas teorias acerca do assunto em questão (SARLE, 2001), o que possibilita seu emprego como alternativa a estes modelos.

Desde a última década, redes neurais artificiais têm sido bastante empregadas como estruturas computacionais para apoio à decisão e ganho muita popularidade em diversas áreas como engenharia, filosofia, psicologia, lingüística, estatística, processamento de sinais, previsão de séries temporais e problemas de reconhecimento de padrões (BRAGA,

LUDERMIR & CARVALHO, 2000). A versatilidade apresentada pelo processamento de dados paralelo habilita os modelos neurais a muitos outros campos do conhecimento.

Deste modo, este estudo propõe a utilização de uma abordagem neural na elaboração e análise de cenários macroeconômicos e a discussão de seus resultados em relação à factibilidade dos mesmos. Por meio do uso de técnicas específicas de redes neurais em que o treinamento da rede não possui um resultado desejado correspondente através do qual seus parâmetros de aprendizagem seriam calibrados pelo operador, procura-se investigar as saídas produzidas pelos modelos utilizados através da comparação com aquelas elaboradas usualmente por especialistas ou por modelos paramétricos já consagrados pela literatura.

Este tipo de questão é vastamente explorado por vários estudiosos da Computação Neural. Contudo, tanto em âmbitos de aplicação quanto em bases de dados relacionados às Ciências Humanas, sua disseminação é muito limitada devido às características específicas da sua estrutura, pois sendo a tarefa classificatória realizada por um modelo de caixa-preta baseado exclusivamente em critérios numéricos de aproximação de padrões, existe certa resistência relativa à aceitação da sua aplicação, já que a classificação neural é puramente numérica e iterativa.

1.2 Objetivo

O objetivo deste estudo é a investigação acerca da viabilidade de elaboração de cenários através do uso de modelos de redes neurais auto-organizadas, bem como sua análise sob uma ótica econômica. Para tanto, utiliza-se uma base de dados macroeconômicos por país obtida no *World Development Report*, publicação anual editada pelo *World Bank*, na versão editada em 1999.

Fazendo uso de algumas características dos modelos neurais, especialmente aquelas relativas à classificação de padrões, a possibilidade da geração de autômatos reconhecedores de características redundantes para a identificação de grupos de países baseados em sua conjuntura econômica será apresentada. Procurar-se-á também demonstrar como um mapa auto-organizado pode ser obtido e empregado na descrição visual das estruturas contidas em um sistema macroeconômico. Assume-se a restrição de não haver conhecimento prévio relacionado à quantidade ou os tipos de categorias existentes, buscando saídas definidas por um processo próprio auto-organizativo gerado pelo processamento neural e que atuaria independente de supervisão ou crítica, gerando resultados que poderiam ser comparados às classificações obtidas por especialistas ou mesmo outros modelos mais empregados com esta finalidade.

Este trabalho se encontra dividido em seis Capítulos, sendo este o primeiro deles, que trata da apresentação, justificativa e objetivos do estudo. No Capítulo 2, discute-se a problemática relativa à elaboração de cenários e a complexidade inerente ao gerenciamento de vastas bases de dados, relacionadas aos problemas e ambientes ilustrados através destes cenários. No Capítulo 3, apresentamos um resumo do funcionamento das redes neurais artificiais, sua estrutura, seu modo de aprendizagem e as principais topologias utilizadas, bem como alguns exemplos de aplicações clássicas nas quais o uso de redes neurais artificiais é largamente empregado e aceito pelas comunidades científica e de negócios. O Capítulo 4 apresenta as topologias neurais utilizadas no estudo: a Teoria da Ressonância Adaptativa e os modelos neurais derivados da mesma, particularmente o modelo ART-2 (*Adaptive Resonance Theory*), utilizado neste trabalho, e as redes SOM, empregadas na obtenção de mapas topológicos para os *clusters* gerados pelas rede ART-2. Os resultados

obtidos pela abordagem neural aqui proposta estão contidos no Capítulo 5, e as considerações finais do estudo são apresentadas e discutidos no Capítulo 6.

2 CENÁRIOS E COMPLEXIDADE SISTÊMICA

Conforme mencionado no Capítulo anterior, a elaboração de cenários consiste atualmente na técnica mais comum empregada na descrição de sistemas diversos, sendo também aplicada no estudo de alternativas de planejamento e controle dos mesmos. Assim, é descrita a seguir uma metodologia bastante empregada na elaboração e análise de cenários de qualquer escopo, de acordo com GODET & ROUBELAT (1996) e GAUSEMEIER, FINK & SCHLAKE (1998).

2.1 Cenários

Um cenário é um estudo prospectivo acerca do futuro aliado à organização das informações obtidas, de modo a oferecer um conjunto de informações coerente, sistemático, compreensível e plausível, com o objetivo de descrever um determinado evento e oferecer instrução e suporte à tomada de decisões (COATES, 2000). Duas grandes categorias podem ser identificadas (GODET & ROUBELAT, 1996) quando se depara com os mais diversos cenários produzidos:

- Cenário exploratório: estudo que considera as tendências observadas no passado e no momento atual, concluindo com a geração de um provável estado futuro;

- Cenário antecipatório ou normativo: construído com base em diferentes pontos de vista acerca do futuro, procura traçar diretrizes para que determinado estado seja alcançado ou evitado.

Tanto cenários exploratórios como cenários antecipatórios podem e devem ser direcionados por diversas alternativas e depois contrastados entre si e com o ambiente contemporâneo, à medida que incorporam mudanças mais ou menos prováveis, para que se possa efetuar um julgamento acerca de sua plausibilidade. De fato, a palavra “cenário” é muitas vezes mal utilizada e serve para qualificar qualquer tipo de hipótese acerca de um ambiente qualquer analisado, podendo ser este tanto estático quanto dinâmico.

Deste modo, é razoável considerar-se, em uma abordagem operacional, que cenários são formatados através do encadeamento de uma ou diversas técnicas de análise de informações, dispostas em uma seqüência lógica, com o intuito de se prover material organizado e útil como apoio à tomada de decisões. Assim, os elementos comuns a qualquer elaboração de cenários seriam seqüencialmente os seguintes (WOLLENBERG, EDMUNDS & BUCK, 2000):

1. Definição do propósito dos cenários a serem elaborados;
2. Informação sobre a estrutura do sistema em questão e dos grandes direcionadores de mudanças;
3. Geração dos cenários, através da organização estruturada das informações disponíveis;
4. Implicações dos cenários e posterior utilização pelos tomadores de decisão.

O trabalho resultante desta operação, assim, seria basicamente um estudo que possibilitaria ao seu usuário final a tomada de decisões fundamentado em seus pressupostos e conclusões, tanto no aspecto de controle e monitoramento, realizados através de ajustes aos desvios da trajetória esperada, como no aspecto da análise gerencial das informações contidas. De fato, a elaboração e o uso de cenários têm sido cada vez mais utilizados pelas mais diversas organizações a partir dos anos 70 (GAUSEMEIER, FINK & SCHLAKE, 1998), tanto na orientação do planejamento estratégico de procedimentos, quanto na definição de atitudes pró-ativas em relação ao ambiente.

Contudo, e especialmente no âmbito das Ciências Humanas, a interpretação de cenários antecipatórios ou exploratórios é permeada por aspectos de análise qualitativa, e por consequência de pontos de vista extremamente particulares sobre determinados problemas, que por sua vez dependem de várias características subjetivas relacionadas ao(s) analista(s) envolvidos na tarefa, tornando sempre suas conclusões passíveis de discussão e limitando a existência de trabalhos orientando sua elaboração mais específica e adequada a determinados tipos de ambientes distintos (BEER, 1979), especialmente quando o assunto trata de temas complexos.

As implicações desta complexidade resultam em que muitas vezes não existem metodologias baseadas em análise qualitativa que sejam suficientemente seguras do ponto de vista analítico: via de regra, os cenários obtidos através de análise qualitativa carecem de uma metodologia padronizada, já que são baseadas em pontos de vista personalizados. Isso nos remete ao objetivo deste estudo, que procura apresentar uma alternativa baseada em um processamento numérico de elaboração de cenários compostos por dados estudados em Humanidades. A identificação de relacionamentos *a posteriori* realizada por modelos neurais auto-organizados mostra-se uma ferramenta aplicável em uma vasta gama de estudos

prospectivos, e assim sua aplicabilidade pode significar um passo na direção desta padronização, ainda que os resultados obtidos careçam de formalismo paramétrico.

2.2 Ambientes complexos e a Cibernética

A construção de cenários é uma tarefa envolvida em uma situação complexa, causada não apenas pelas diferentes características contidas nas diversas informações utilizadas, mas também pela interdependência e influência dos dados entre si e pela instabilidade gerada por estes relacionamentos (WILLIAMS, 1999), que aumentam exponencialmente à medida que mais informação é adicionada. A maneira mais usual de se lidar com esta complexidade é a construção de sistemas de informação que produzam resultados compatíveis e aceitáveis (LAUDON & LAUDON, 1996; TURBAN & ARONSON, 2001) com a necessidade final expressa na elaboração dos cenários em questão (GAUSEMEIER, FINK & SCHLAKE, 1998). A abordagem sistêmica utilizada trata-se de uma escolha gerencial, tomada no sentido de se prover apoio aos processos de planejamento, previsão, monitoramento e controle de projetos cuja complexidade intrínseca se constitui em um grande desafio. Esta escolha se concentra em basicamente um dos três métodos apresentados abaixo (LAUDON & LAUDON, 1996; WILLIAMS, 1999);

- Metodologia clássica: consiste na decomposição descendente do sistema em direção aos seus elementos estruturais;
- Metodologia holística: baseada na composição ascendente do sistema a partir de seus elementos básicos;
- Uso de elementos de Tecnologia de Informação e Pesquisa Operacional: objetivo de se buscar novos relacionamentos nos dados que possam indicar resultados não facilmente perceptíveis.

Quaisquer das três alternativas apresentadas possuem vantagens e desvantagens na busca de semelhanças estruturais relacionadas à existência de propriedades gerais, que podem ser ou não aplicáveis às mais diversas formas sistêmicas (DURATEX S.A., 1985). Porém, o grande complicador de uma análise sistêmica consiste na dificuldade em se apontar com segurança quais propriedades identificadas em um determinado sistema podem ser generalizadas para um outro sistema em particular, e este problema aumenta à medida que se adicionam mais e mais dados na composição da análise. Existe ainda um caráter probabilístico envolvido na tarefa decisória: como de fato parece ser impossível lidar com a complexidade inerente aos sistemas de uma maneira geral, deve haver uma probabilidade associada a cada cenário oriundo da análise de um determinado sistema.

Muito embora vários modelos possam ser desenvolvidos com vista à tomada de decisões em um ambiente de complexidade crescente, neste estudo é utilizada a abordagem proposta na Cibernética conforme BEER (1979): a complexidade inerente à interação entre os dados estruturais de um sistema, associada à possibilidade de erro inerente à incerteza decorrente de uma análise específica, deve ser tratada como um modelo de caixa preta, ou seja, assume-se que não seria de fato plausível que uma análise qualquer seria a mais adequada (o que de fato pode ser um argumento em favor da personalização). Entretanto, alternativas das mais diversas teriam sua efetividade observada pelos resultados obtidos independentemente da metodologia empregada. Aqui nota-se a possibilidade alternativa oferecida pelos modelos de redes neurais artificiais.

Dentre as alternativas relativas especificamente ao terceiro método relacionado às diversas abordagens sistêmicas de construção de cenários apresentado acima (como por exemplo, o emprego da Análise Multivariada), os modelos de redes neurais artificiais destacam-se como uma abordagem numérica e de processamento paralelo que apresentam

resultados bastante positivos na busca e classificação de padrões de dados semelhantes, e que desde os anos 80 têm ganho crescente popularidade entre o meio acadêmico e o mundo dos negócios. No próximo capítulo será descrita a estrutura geral dos modelos neurais, bem como apresentam-se algumas aplicações clássicas em que estes modelos são empregados, através dos quais procurar-se-á clarificar a razoabilidade da proposição deste estudo.

3 REDES NEURAIS ARTIFICIAIS E SUAS APLICAÇÕES

Uma rede neural artificial é um sistema de processamento de informações que apresenta certas características em comum com as redes neurais biológicas que formam o sistema nervoso dos seres vivos. Basicamente, estas características são formuladas através do estudo da célula fundamental do cérebro, o neurônio, e reproduzidas através de algoritmos que procuram simular o funcionamento de um conjunto de neurônios. É apresentado na figura abaixo um exemplo simplificado de um neurônio.




FIGURA 1: Esquema de um neurônio biológico. Adaptado de HAYKIN (1994).

O funcionamento de um neurônio biológico pode ser resumido basicamente da seguinte maneira: os dendritos recebem sinais de entrada vindos de outras células, o soma e os próprios dendritos integram e processam estes sinais, a informação é transmitida ao longo do axônio para outros neurônios por meio das sinapses, que são as ligações entre os dendritos de neurônios diferentes.

Os neurônios biológicos atuam em conjunto na realização de suas funções nos seres vivos, através de uma arquitetura paralela composta por bilhões de células realizando um processamento concomitante. Esta formatação particular torna o sistema nervoso capaz de realizar determinadas tarefas com resultados melhores do que os obtidos por um processamento computacional em série, como por exemplo, modelagem e identificação de padrões e processamento de imagens e sinais (BRAGA, LUDERMIR & CARVALHO, 2000). Assim, modelos de redes neurais artificiais foram motivados pelo desejo de se entender e simular o funcionamento do cérebro humano, e têm sido desenvolvidos através de generalizações via modelos matemáticos inspirados na cognição humana ou na biologia neural (FAUSETT, 1994), com base nas seguintes hipóteses genéricas:

- O processamento de informações ocorre em elementos simples chamados neurônios;
- São transmitidos sinais entre os neurônios através de conexões (sinapses) existentes entre eles;
- Cada conexão tem associada a si uma ponderação, a qual, em uma rede neural típica, processa o sinal transmitido; o conjunto destas ponderações pode ser visto como o conhecimento armazenado na rede, contido em uma memória distribuída;
- Neurônios que desempenham função semelhante durante o processamento da informação recebida são dispostos em uma mesma camada; assim, camadas

sucessivas são criadas na rede neural com o intuito de se realizar em cada uma delas uma fase distinta do processamento (redes multicamadas);

- A cada neurônio se aplica uma função de ativação (geralmente não linear) que computa seu sinal de saída a partir dos dados recebidos.

No seguimento deste capítulo apresentamos as características comuns relativas às arquiteturas e ao processamento presentes nos modelos de redes neurais artificiais mais empregados, conforme FAUSET (1994), HAYKIN (1994), BISHOP (1995), BRAGA, LUDERMIR & CARVALHO (2000) e SARLE (2001).

3.1 Condições e descrição da ativação neural

O processamento realizado pelos neurônios, além de estar disposto em uma arquitetura paralela, também lança mão de uma propagação seqüencial na qual os neurônios de camadas posteriores recebem como sinal de entrada o resultado do processamento ocorrido nas camadas anteriores (redes multicamadas). Contudo, este sinal deve ser forte o suficiente para que o neurônio seguinte seja estimulado a continuar realizando a transmissão do impulso, caso contrário o processamento é interrompido (HAYKIN, 1994). Podemos citar, como exemplo biológico, a reação à temperatura de um objeto tocado por uma pessoa; se esta temperatura estiver dentro de parâmetros que não agridem o organismo, apenas a sensação de toque é transmitida, enquanto a sensação da temperatura fica em um segundo plano sensorial. Nos modelos de redes neurais artificiais, estas características são simuladas através da adoção de estado, função e limiar de ativação.

O estado de ativação representa o próprio estado de cada um dos neurônios da rede - ativado ou em repouso - e indica qual o formato dos dados que a rede é capaz de processar,

podendo estes serem compostos por valores binários (0 ou 1), bipolares (-1 ou +1) ou reais; este estado é definido através de funções de ativação.

As funções de ativação realizam o processamento dos sinais recebidos por cada neurônio individualmente e o transformam em um estado de ativação neural. Assim, várias unidades de processamento de uma rede neural transformam seus dados de entrada usando uma função escalar, gerando um valor chamado de valor de ativação, que é propagado através das conexões sinápticas a uma ou mais unidades de processamento. A função de ativação é chamada também de função de transferência, e a ativação do neurônio funciona através da aplicação de funções matemáticas, envolvendo adições, comparações e/ou transformações numéricas, como por exemplo, o uso de uma função degrau, tangente hiperbólica ou logística (Apêndice A). Se uma unidade não transforma sua entrada, é dito que se aplica uma função identidade ou função de ativação linear. A razão para o uso de funções de ativação diferentes da função identidade reside na necessidade de se limitar os valores de saída da rede, bem como na simulação de um limiar de ativação para que um neurônio propague seu sinal adiante. O uso de diferentes tipos de funções de ativação, portanto, consiste na delimitação da amplitude do sinal de saída do neurônio, e a escolha deve ocorrer através de um método experimental. A principal vantagem apresentada por modelos de redes neurais artificiais, quando comparados aos tradicionais modelos lineares, consiste justamente na plasticidade de processamento decorrente de seu paralelismo e da ajustabilidade de suas funções de ativação, que atuando em conjunto geram fronteiras de classificação não lineares, conforme mostrado na figura abaixo:

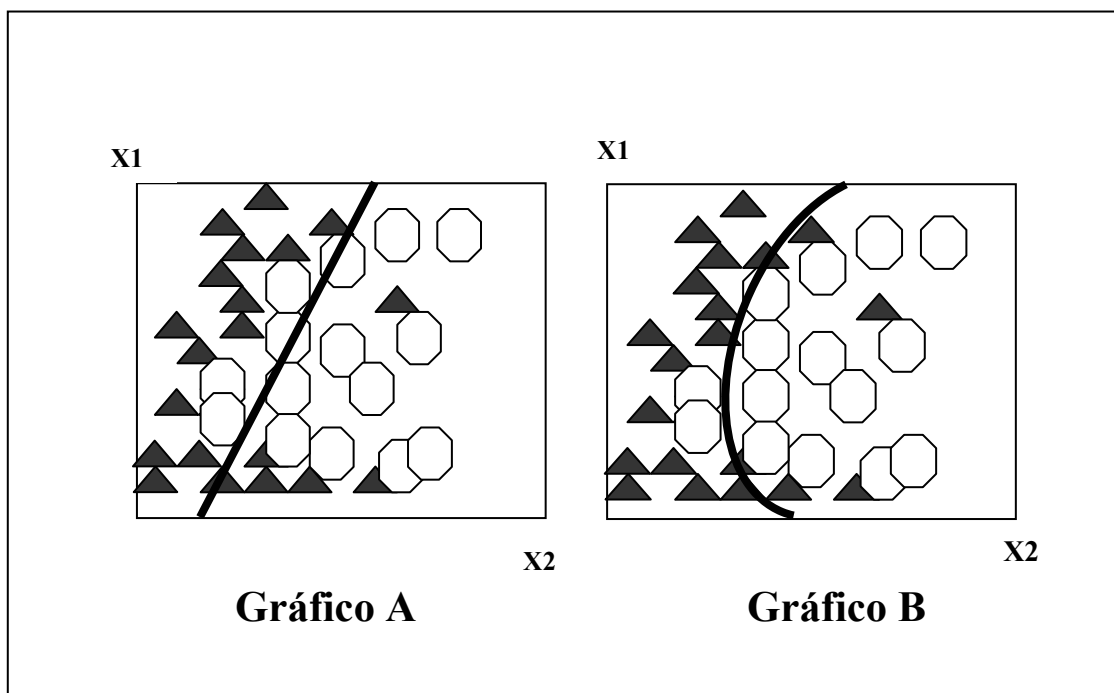


FIGURA 2: Fronteiras de classificação linear e neural: o Gráfico A mostra a divisão entre duas classes de dados distintas obtidas por um modelo linear, e o Gráfico B mostra uma divisão para as mesmas classes obtida por um modelo não linear.

Já o limiar de ativação consiste em um valor obtido pela função de ativação que determina o disparo ou a inibição da atividade do neurônio, conforme descrito acima, e a conseqüente propagação do sinal pela rede, podendo consistir em um valor de corte em um ponto de máximo ou de mínimo.

Algumas redes adotam também a aplicação de uma função de saída, que modula o estado de ativação de um neurônio em seu valor de saída, porém geralmente é aplicada uma função identidade.

3.2 Aprendizado neural

A mais distinta propriedade das redes neurais artificiais é sua habilidade em aprender com o ambiente, e melhorar sua performance através deste aprendizado. Esta

melhoria ocorre através de um processo iterativo e cíclico de ajustes realizados em suas conexões sinápticas e em seu limiar de ativação (HAYKIN, 1994; BRAGA, LUDERMIR & CARVALHO, 2000).

Geralmente, uma rede neural produz resultados cada vez melhores à medida que existe uma maior quantidade de informação (dados) inseridos e disponíveis em seu processo de aprendizado. O conjunto de regras e procedimentos numéricos adotados para obtenção de estabilidade nos parâmetros da rede neural, através de um ajuste contínuo dos pesos das conexões que definem os procedimentos para a solução de um problema de aprendizado, é chamado de algoritmo de treinamento. Os algoritmos de treinamento mais empregados são os seguintes:

- Aprendizado via correção de erro: utiliza uma função de custo associada aos erros de processamento obtidos pela rede, e realiza os ajustes nos pesos sinápticos baseados na gravidade deste erro, atingindo uma solução estável quando as ponderações passam a mudar pouco a cada ciclo de treinamento;
- Aprendizado competitivo: os neurônios competem entre si pela atividade de processamento através de mecanismos de comparação entre os dados e suas ponderações, levando à especialização individual dos neurônios;
- Aprendizado Hebbiano: baseado no fortalecimento ou depressão sináptica em função da existência ou ausência de propagação do sinal entre neurônios conectados.

Contudo, independentemente do conjunto de regras empregado na obtenção do aprendizado neural, os dados de treinamento disponíveis podem apresentar ou não pares de entrada e saída que orientem os ajustes dos pesos sinápticos no sentido de que a rede produza

a saída desejada. Este aspecto diz respeito especialmente à interação entre a rede neural empregada e seu ambiente, e esta particularidade é modelada através de paradigmas de aprendizado.

Paradigmas de aprendizado são métodos de gerenciamento dos resultados produzidos pela rede neural, constituídos basicamente pelo paradigma de aprendizado supervisionado, o qual supõe a existência de um direcionador externo que orienta a rede para as saídas desejadas, e pelo paradigma de aprendizado não supervisionado, no qual inexisteste direcionador, fazendo com que os resultados produzidos pela rede sejam considerados como sendo o melhor processamento possível obtido a partir dos dados disponíveis.

3.3 Arquitetura e processamento neurais

Os modelos de redes neurais artificiais mais amplamente empregados na resolução dos mais diversos tipos de problemas apresentam algumas estruturas genéricas e outras particulares que desempenham funções específicas no processamento neural. São apresentadas abaixo as estruturas genéricas que compõem a imensa maioria das topologias neurais, bem como o papel desempenhado pelas mesmas no processamento. Em respeito às estruturas particulares, estas são em quantidade tão grande que seu detalhamento foge do escopo deste trabalho. As estruturas genéricas são as conexões entre os neurônios e o arranjo entre as camadas de neurônios da rede. Já os atributos básicos do processamento neural são a conectividade, o padrão de propagação do sinal e o padrão de manutenção da sua topologia (HAYKIN, 1994; BRAGA, LUDERMIR & CARVALHO, 2000).

As conexões entre os neurônios podem ser do tipo ascendente ou acíclico, conectando o neurônio a outro(s) neurônio(s) que executem uma etapa posterior do

processamento, e descendente ou cíclico, conectando o neurônio a outro(s) neurônio(s) que executem uma etapa anterior do processamento, como por exemplo em um mecanismo de retroação do erro de classificação obtido. Via estas conexões interneuronais ocorre a propagação do sinal de processamento na rede, que pode ocorrer de maneira direta, ou seja, o sinal é sempre ascendente em direção à camada de saída, e a retropropagação, que ocorre quando o impulso sináptico retorna pela rede com o intuito de se corrigir o erro da resposta obtida em relação à desejada. Esta inovação foi a grande responsável pelo grande incremento na capacidade de generalização apresentada por redes neurais multicamadas - o famoso algoritmo *Backpropagation* descrito em RUMELHART, HINTON & WILLIAMS (1986).

Em relação à conectividade da rede, a mesma pode apresentar uma estrutura fraca ou parcialmente conectada, quando nem todos os neurônios se conectam entre si, completamente conectada, no caso onde todos os neurônios estão interconectados, e ainda existem os modelos de redes neurais sem pesos, que se utilizam de tabelas-verdade armazenadas em cada um dos neurônios da rede, sem existir entre estes conexão ponderada ajustável.

Em relação à existência e arranjo das camadas de neurônios, característica esta que geralmente batiza suas topologias representativas, a mesma consiste na maneira com que os neurônios são estruturados, podendo ser redes de neurônio único – o famoso modelo McCulloch-Pitts -, redes multicamadas (ver Figura 3), redes recorrentes, as quais possuem conexões ligando a saída de um neurônio à entrada de outro neurônio da mesma camada, de uma camada anterior ou de si mesmo, e estruturas neuronais matriciais, que consistem em camadas dispostas de maneira multidimensional. Finalmente, não é absolutamente necessário que o operador de uma rede neural deva ficar restrito ao padrão topológico adotado inicialmente: pode-se incorrer na adoção de um padrão de manutenção da topologia através

do qual determina-se uma estrutura fixa, de modo que a disposição e quantidade dos neurônios e das conexões permanece imutável ou redes neurais construtivas, ou seja, redes com regras que permitem a otimização de sua estrutura para cada problema específico, através do uso de algoritmos genéticos, técnicas de poda e algoritmos construtivos, onde novas estruturas são adicionadas à rede ou eliminadas (BRAGA, LUDERMIR & CARVALHO, 2000).

Apresenta-se na Figura 3 abaixo um esquema genérico utilizado desde os primeiros modelos neurais propostos na década de 50 até hoje em algumas das topologias mais utilizadas, como *Multilayer Perceptron* com algoritmo *Backpropagation* (RUMELHART, HINTON & WILLIAMS, 1986), composto por uma rede neural artificial multicamadas totalmente conectadas entre si.

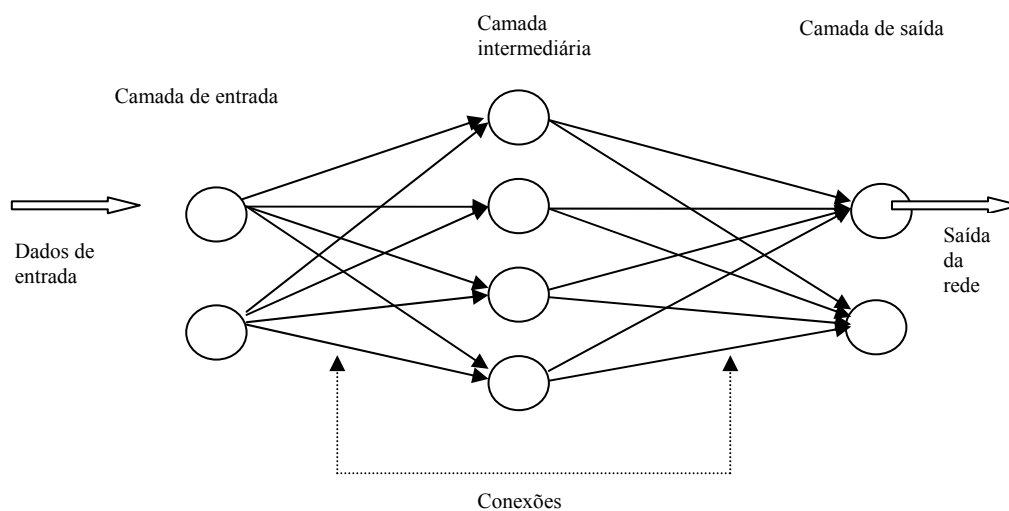


FIGURA 3: Esquema de uma rede neural genérica. Adaptado de ZELL *et al.* (2001).

Lista-se abaixo as topologias neurais mais utilizadas e conhecidas, conforme levantamento disponível em SARLE (2001), subdivididas de acordo com o paradigma de aprendizado adotado, o que demonstra a imensa diversidade de topologias existentes que realizam processamento neural:

1 Algoritmo Supervisionado:

- 1.1 *Feedforward*: Linear, Hebbiano (Hebb,1949; Fausett (1994), *Perceptron* (Rosenblatt,1958; Minsky & Papert,1969; Minsky & Papert, 1988; Fausett,1994; Adaline (Widrow & Hoff, 1960; Fausett, 1994), *Higher Order* (Bishop,1995) *Functional Link* (Pao,1989), MLP - *Multilayer perceptron* (Bishop,1995; Reed & Marks, 1999; Fausett,1994), *Backprop* (Rumelhart, Hinton, & Williams,1986), *Cascade Correlation* (Fahlman & Lebiere, 1990; Fausett, 1994),*Quickprop* (Fahlman, 1989), RPROP (Riedmiller & Braun,1993), Redes RBF (Bishop, 1995; Moody & Darken, 1989; Orr,1996); OLS - *Orthogonal Least Squares* (Chen, Cowan & Grant, 1991), CMAC - *Cerebellar Model Articulation Controller* (Albus, 1975; Brown & Harris, 1994);
- 1.2 Somente Classificadoras: LVQ - *Learning Vector Quantization* (Kohonen, 1988; Fausett, 1994), PNN - *Probabilistic Neural Network* (Specht, 1990; Masters, 1993; Hand, 1982; Fausett, 1994);
- 1.3 Somente Regressão: GRNN - *General Regression Neural Network* (Specht, 1991; Nadaraya, 1964; Watson, 1964), *Feedback* (Hertz, Krogh, & Palmer, 1991; Medsker & Jain,2000), BAM - *Bidirectional Associative Memory* (Kosko, 1992; Fausett, 1994), *Boltzman Machine* (Ackley *et al.*, 1985; Fausett, 1994);

- 1.4 Séries de Tempo Recorrentes: *Backpropagation through time* (Werbos, 1990), Elman (Elman, 1990), FIR - *Finite Impulse Response* (Wan, 1990), Jordan (Jordan, 1986), *Real-time recurrent network* (Williams & Zipser, 1989), *Recurrent backpropagation* (Pineda, 1989; Fausett, 1994), TDNN - *Time Delay NN* (Lang, Waibel & Hinton, 1990);
- 1.5 Competitivas: ARTMAP (Carpenter, Grossberg & Reynolds, 1991), Fuzzy ARTMAP (Carpenter et al., 1992; Kasuba, 1993), *Gaussian ARTMAP* (Williamson, 1995), *Counterpropagation* (Hecht-Nielsen, 1987; Hecht-Nielsen, 1988; Hecht-Nielsen, 1990; Fausett, 1994), *Neocognitron* (Fukushima, Miyake & Ito, 1983; Fukushima, 1988; Fausett, 1994).

2 Algoritmo Não-Supervisionado:

- 2.1 Competitivo: *Vector Quantization* (Grossberg, 1976; Kohonen, 1984), *Conscience* (Desieno, 1988), *Self-Organizing Maps* (Kohonen, 1995; Fausett, 1994), *Local Linear* (Mulier & Cherkassky, 1995);
- 2.2 *Adaptive resonance theory*: ART-1 (Carpenter & Grossberg, 1987a; Moore, 1988; Fausett, 1994), ART-2 (Carpenter & Grossberg, 1987b; Fausett, 1994), ART-2A (Carpenter, Grossberg & Rosen, 1991a), ART-3 (Carpenter & Grossberg, 1990), *Fuzzy ART* (Carpenter, Grossberg & Rosen, 1991b), DCL - *Differential Competitive Learning* (Kosko, 1992);
- 2.3 *Dimension Reduction*: (Diamantaras & Kung, 1996), Hebbiano (Hebb, 1949; Fausett, 1994), Oja (Oja, 1989), Sanger (Sanger, 1989), Hebbiano Diferencial (Kosko, 1992);

2.4 Autoassociação: *Linear autoassociator* (Anderson et al., 1977; Fausett, 1994), BSB - *Brain State in a Box* (Anderson et al., 1977; Fausett, 1994), Hopfield (Hopfield, 1982; Fausett, 1994)

3.4 Treinamento de uma rede neural genérica

Conforme abordado acima uma rede neural é essencialmente caracterizada através dos padrões de suas conexões entre os seus neurônios - a arquitetura da rede -, pelo seu método de determinação das ponderações presentes nas conexões - seu algoritmo de treinamento ou aprendizagem - e por sua função de ativação (BRAGA, LUDERMIR & CARVALHO, 2000). Como forma de proceder ao treinamento das redes neurais para o desempenho da função desejada, os dados utilizados são geralmente particionados em:

- Amostra de treinamento: utilizada para efetivamente treinar a rede, isto é, para ajustar as ponderações das conexões entre os neurônios de cada camada;
- Amostra de validação: utilizada para verificar a consistência do aprendizado da rede e para a seleção das variáveis a serem utilizadas;
- Amostra de teste: utilizada para controle da estimativa dos erros produzidos pela rede.

Algumas das características mais proeminentes presentes nos modelos neurais são relativas à sua capacidade de aprendizado através de exemplos, sem que seja necessária a adoção de um algoritmo específico para uma aplicação específica, e a conseqüente generalização da informação aprendida, utilizável através da extrapolação dos resultados obtidos para eventos inéditos de um mesmo problema. Isso ocorre basicamente através da detecção de características comuns contidas em conjuntos de dados, gerando grupamentos e

categorias (HAYKIN, 1994; BISHOP, 1995). Conforme explicado acima, existem dois paradigmas de aprendizagem sob os quais os mais diversos algoritmos de processamento têm sido desenvolvidos: o aprendizado supervisionado e o aprendizado não supervisionado (SARLE, 2001). O primeiro lança mão de um supervisor externo que direciona a resposta desejada para o problema, ajustando-se assim os parâmetros da rede de acordo com sua orientação; o segundo não possui nenhuma orientação externa, o que leva a rede a gerar representações internas dos dados a partir de regularidades estatísticas detectadas nos dados de entrada. A escolha do paradigma de aprendizado depende do tipo de aplicação a que a rede neural será utilizada e às limitações relativas à topologia da rede (HAYKIN, 1994).

O primeiro fator de diferenciação da escolha do paradigma de aprendizado refere-se a que os algoritmos supervisionados apresentam um comportamento sensível ao aumento da escala computacional. Esta limitação advém do ajuste das ponderações das conexões sinápticas sofrerem um efeito exponencial causado pela quantidade de informações recebidas pelo neurônio, ou seja, sendo C_i o número de conexões de entrada de um determinado neurônio, quanto maior C_i , maior o tempo computacional requerido pela realização da tarefa (esse efeito é conhecido como o Problema da Dimensionalidade). O segundo fator de diferenciação seria devido à própria natureza da aplicação requerida, já que existem diversas situações em que não existe conhecimento *a priori* do problema a ser solucionado, como por exemplo no caso do uso de radares e localização de alvos (HEILEMAN, GEORGIOPOULOS & HWANG, 1994), ou mesmo, no caso de tarefas de classificação, não é possível se examinar todas as possibilidades de agrupamento possíveis (JOHNSON & WICHERN, 1992). Assim, a possibilidade de um processamento neural realizar este tipo de tarefa torna-se interessante, especialmente em tarefas de obtenção de aprendizado. Nestes casos, a adoção de um algoritmo não supervisionado é uma alternativa realizável.

No caso da escolha do operador recair sobre a utilização de um paradigma de aprendizado não supervisionado, existem topologias neurais conhecidas como modelos auto-organizados, que foram formuladas para serem utilizadas como instrumentos de descoberta de conhecimento, ou seja, o processo iterativo global de descoberta e extração de novos padrões ou estruturas em uma base de dados. Tal procedimento pode disponibilizar a obtenção de conhecimento implícito, previamente desconhecido e potencialmente útil a partir dos dados empregados. Assim, a principal fonte de interesse no emprego destes modelos seria sua capacidade de trabalhar uma base de dados sem a necessidade de reduzir a quantidade de informação contida nestes dados, ou seja, não é necessário o descarte de informação para que seja possível um melhor desempenho do modelo e obtenha-se resultados plausíveis a partir deste.

3.5 Aplicações de redes neurais artificiais

Após um período, entre as décadas de 60 e 80, no qual houve uma frustração generalizada devido à incapacidade das topologias empregadas à época (neurônio único ou vários neurônios dispostos em apenas uma camada) em realizar classificações de padrões não linearmente separáveis, o sucesso da proposição de uma arquitetura multicamadas com ajuste dos pesos sinápticos via retropropagação do erro obtido deram um enorme impulso à aplicabilidade de redes neurais artificiais (HAYKIN, 1994). Especificamente no caso das arquiteturas multicamadas, estudos comprovaram que duas camadas intermediárias são suficientes para aproximar qualquer função matemática (CYBENKO, 1988; CHESTER, 1990), o que indica serem estes modelos classificadores universais de funções.

Contudo, existem várias arquiteturas neurais propostas, e cada uma delas gera resultados melhores para determinados tipos de problemas, o que faz a experimentação destes modelos em relação ao desempenho de certas tarefas um procedimento necessário e

interessante na medida que são identificados os melhores usos para cada uma das arquiteturas existentes. Esta plasticidade operacional torna os modelos de redes neurais passíveis de realizarem as mais diversas aplicações, o que as torna amplamente difundidas em diversas áreas do conhecimento, desde aquelas ligadas à pesquisa científica e tecnológica quanto aos negócios. Sendo assim, o campo de atuação de um pesquisador através do estudo de redes neurais artificiais acaba se tornando multidisciplinar (FAUSETT, 1994), em virtude de que as aplicações em que são empregadas são de cunho geral e engloba a conceituação simultânea de diversas áreas do conhecimento (BRAGA, LUDERMIR & CARVALHO, 2000). Assim, de acordo com (KOHONEN, 1989), a grande contribuição dos modelos neurais se dá nas áreas de representação do conhecimento e reconhecimento de padrões.

A opção por modelos de redes neurais artificiais na solução de tarefas diversas se dá geralmente por conta da complexidade inerente à mesma; sistemas excessivamente complexos e/ou compostos por conjuntos de dados vastos, complexos e inter-relacionados são mais satisfatoriamente resolvidos com o uso desta metodologia (SMITH & GUPTA, 2000; BRAGA, LUDERMIR & CARVALHO, 2000). A razão principal repousa no fato de que, quanto maior a quantidade de informações disponível, maior a dificuldade na modelagem do sistema representado por esta informação (BRAGA, LUDERMIR & CARVALHO, 2000).

Com o objetivo de ilustrar a diversidade de aplicações nas quais redes neurais artificiais têm sido usadas, lista-se abaixo alguns dos usos em que modelos de redes neurais artificiais são largamente empregados, de acordo com as áreas de concentração nas quais foram apresentados estudos durante a *IEEE International Conference On Neural Networks*, realizada em 1994 em Washington, nos Estados Unidos:

- Sistemas híbridos (PARK, 1994);
- Inteligência Computacional (TAKAHASHI *et. al.*, 1994);
- Neurobiologia (HEILEMAN, GEORGIPOULOS & HWANG, 1994);
- Ciência cognitiva (MAHONEY, 1994);
- Controladores inteligentes (WEIERICH & VON ROSENBERG, 1994);
- Aprendizado e reconhecimento de padrões (BARTFAI, 1994);
- Previsão de séries de tempo (ENGLISCH & HIEMSTRA, 1994);
- Economia e negócios (VISHWAKARMA, 1994);
- Sistemas de energia (TSAI, TAI & REYNOLDS, 1994);
- Análise de movimento (MITRA, 1994);
- Processamento e transmissão de sinais (SPECHT & ROMSDAHL, 1994);
- Estimação e identificação (KANE & MILGRAM, 1994).

Pode-se ainda citar uma grande quantidade de estudos nas áreas de Ciências Econômicas, Ciências Contábeis e Administração, segundo levantamentos realizados por WONG & SELVI (1998), VELLIDO, LISBOA & VAUGHAN (1999) e WONG, LAI & LAM (2000). Dentre estas aplicações, encontra-se, segundo os autores acima, trabalhos realizados em Auditoria, Finanças, Recursos Humanos, Sistemas de Informação, *Marketing* e Distribuição, Produção e Operações, Atuária, Administração Geral, Varejo, Política Tributária e Mercado de Capitais, em um total de mais de 483 artigos relacionados em cerca de 54 periódicos científicos e livros-texto, além dos trabalhos constantes nas bases de dados ABI/INFORM e *Business Periodical Index* (BPI).

Todos estes usos possíveis para modelos de redes neurais se devem à sua adaptabilidade às tarefas mais distintas e às diversas arquiteturas propostas, que empiricamente são testadas e têm seus resultados comparados entre si e entre outros modelos

utilizáveis para a mesma finalidade. Este é um trabalho enorme e que ainda tem muito a retribuir à medida em que mais e mais sistemas complexos são estudados sob a ótica do processamento neural.

4 REDES NEURAI AUTO-ORGANIZADAS

Existem, conforme abordado anteriormente, muitos casos em que sistemas complexos são analisados sem que haja um conhecimento *a priori* das saídas relacionadas às informações disponíveis para estudo. Desta forma, incorre-se em uma escolha entre duas possibilidades: um estudo realizado sob uma ótica tradicional, composta por modelos vastamente conhecidos e debatidos, mas que contudo nem sempre apresentam uma especificidade desejável na abordagem da tarefa, ou a utilização de um modelo de caixa-preta em que as saídas são obtidas de acordo com a Teoria Cibernética (BEER, 1979). No segundo caso, redes neurais artificiais são uma das alternativas mais interessantes, já que sua plasticidade inerente ao processamento realizado as tornam passíveis de uso em sistemas quaisquer.

Deste modo, realizada a escolha pelo processamento neural, deve-se em primeiro lugar decidir acerca do paradigma de aprendizagem a ser empregado, e depois se definir a topologia neural. No caso da escolha do operador recair sobre um paradigma de aprendizado não supervisionado, em vista principalmente da falta de conhecimento padronizado acerca do sistema a ser estudado, existe uma classe de redes neurais artificiais, bastante semelhantes às estruturas neurobiológicas conhecidas, que apresentam resultados expressivos no desempenho de tarefas cujo conteúdo de informação está exclusivamente contido nos dados de entrada do sistema. Estas redes neurais possuem como característica mais marcante a capacidade de auto-organização de seus neurônios, tanto no aspecto de classificação

neuronal como no aspecto visual da representação destas estruturas, e são conhecidas como redes neurais auto-organizadas.

Apresenta-se neste capítulo os modelos de redes neurais auto-organizados baseados na Teoria de Ressonância Adaptativa, mais pormenorizadamente a rede ART-2, utilizada neste estudo, e as redes neurais geradas a partir de modelos SOM. Além da descrição da topologia e do funcionamento destas redes, são detalhados seu algoritmo de funcionamento e o ciclo de processamento realizado por cada uma destas arquiteturas.

4.1.1 Teoria de Ressonância Adaptativa - Redes ART

Durante décadas, estatísticos aplicaram Análise Discriminante e Modelos de Regressão na modelagem de padrões nos quais os dados de treinamento disponíveis são rotulados (com entradas e saídas conhecidas) e técnicas de *clustering* quando estes dados não são rotulados. Estes métodos encontram analogias em redes neurais, onde topologias multicamadas com algoritmos de retropropagação do erro são usados quando os dados são rotulados, e modelos auto-organizados quando não são rotulados (SMITH & GUPTA, 2000). Estas técnicas de *clustering* têm sido usadas no agrupamento e categorização de dados baseados nas estruturas naturais contidas nestes. O objetivo de um algoritmo de *clustering* apropriado é maximizar o grau de similaridade entre os padrões de um mesmo *cluster*, ao mesmo tempo em que o grau de similaridade entre os diversos *clusters* é minimizado.

Para os problemas relacionados à classificação de padrões sob os quais as informações fornecidas residem apenas nos dados relativos a estes problemas, sem que exista um crítico externo que possa orientar os resultados obtidos, seria interessante que um modelo matemático, notadamente um modelo de Inteligência Artificial, elaborasse uma classificação

própria baseada na exploração das redundâncias contidas nos dados de entrada disponíveis à rede (TAURITZ, 2002).

Desta forma, é necessária a aplicação de técnicas que não se apoiem em supervisão de erro das saídas como forma de se obter classes agrupadas de acordo com um determinado estado em que se encontram os elementos, tornando possível detectar relacionamentos entre eles (BRAGA, LUDERMIR e CARVALHO, 2000). Assim, pode-se gerar matematicamente estruturas de relacionamentos entre vários estados que coexistem sob um mesmo cenário.

Uma arquitetura adequada a este tipo de tarefa deveria identificar padrões através da comparação dos mesmos, e posteriormente elaborar um critério para o agrupamento destes padrões de acordo com a similaridade ou disparidade das características apresentadas. Existem diversos modelos neurais que atendem a estes requisitos, conforme discutido no Capítulo 3. Contudo, neste trabalho é proposto o uso do modelo neural auto-associativo baseado na Teoria de Ressonância Adaptativa, ou ART, criada por Stephen Grossberg em 1976 (TAURITZ, 2002), mais especificamente a rede na qual são utilizados dados contínuos como informação de entrada da rede, topologia esta conhecida como ART-2 (CARPENTER & GROSSBERG, 1987b).

ART engloba uma ampla variedade de redes neurais artificiais baseadas explicitamente na neurofisiologia, e são definidas em relação ao seu algoritmo de treinamento em termos de equações diferenciais detalhadas e críveis como modelos plausíveis dos neurônios biológicos. Na prática, as redes ART são implementadas como soluções analíticas ou aproximações para estas equações diferenciais. A ressonância adaptativa sobre a qual a teoria se refere ocorre quando padrões de atividade nas camadas de entrada e saída se reforçam em sinergia.

Uma característica fundamental na Teoria de Ressonância Adaptativa que fundamenta o funcionamento das redes ART consiste em que se nenhuma classe ressoa com o padrão de entrada apresentado à rede, uma nova classe é criada, de acordo com um parâmetro de vigilância previamente escolhido e que pode ser calibrado. Tal característica foi concebida com o intuito de se solucionar o dilema plasticidade-estabilidade, denominação utilizada acerca do problema de *trade-off* presente em redes neurais artificiais em se manter capaz de adaptar ou agrupar padrões de entrada indefinidamente (plasticidade) e ao mesmo tempo preservar o conhecimento adquirido, impedindo que os novos padrões se superponham ao conhecimento prévio adquirido pela rede (estabilidade), conforme descrito em CARPENTER & GROSSBERG (1987a). Esta característica, inclusive, é bastante positiva se for lembrado o Problema da Dimensionalidade mencionado na Seção 3.4. Portanto, esta arquitetura é conduzida por um algoritmo que utiliza um critério racional na alocação de padrões, através de seus vetores de entrada, em direção à geração de agrupamentos baseados na similaridade entre os padrões apresentados.

Existem redes ART dos mais diversos tipos, utilizando paradigmas de aprendizado tanto supervisionado como não supervisionado. Os modelos mais conhecidos e utilizados são:

- ART-1: primeiros modelos desenvolvidos, sua principal peculiaridade é a utilização de dados binários como entradas da rede;
- ART-2: modelo desenvolvido para processar dados contínuos;
- ART-3: modelo que utiliza ação de neuro-transmissores na propagação dos dados pela rede;

- ARTMAP: composto por duas sub-redes, ART-a, que recebe e processa um determinado padrão de entradas apresentado, e ART-b, que constitui a resposta desejada para o padrão apresentado à rede;
- *Fuzzy* ART: rede ART que processa dados *fuzzy*;
- *Fuzzy* ARTMAP: rede ARTMAP que processa dados *fuzzy*.

No caso do presente trabalho, conforme disposto no início deste capítulo, é utilizado o modelo ART-2, o qual consiste de um modelo de paradigma de aprendizado não supervisionado capaz de realizar o processamento de entradas e saídas analógicas (CARPENTER & GROSSBERG, 1987b). Seu algoritmo de treinamento é basicamente um algoritmo iterativo, no qual cada caso é processado de modo a se encontrar a classe mais parecida possível com a informação apresentada, e em seguida esta classe tem sua informação atualizada para que apresente características mais parecidas com a de seus componentes, incluindo o último elemento incorporado, em um processo de prototipagem de categorias. A arquitetura básica de uma rede ART envolve três grupos de neurônios: uma camada de processamento dos vetores de entrada, chamada F1, os neurônios representativos de cada categoria, chamados de camada F2, e o mecanismo de controle do grau de similaridade dos padrões alocados em uma mesma categoria, composto por um neurônio único e chamado de mecanismo de *reset*.

Na Figura 4 disposta a seguir, é representada a arquitetura de uma rede ART-2, bem como as conexões e suas devidas direção e polaridade, para melhor compreensão do exposto. Setas largas mostram que todas as unidades da camada de origem são conectadas a todas as unidades da camada de destino, tanto na direção ascendente (a_{ij}) quanto na descendente (d_{ij}), e os sinais (+) e (-) indicam, respectivamente, sinal excitatório e inibitório.




FIGURA 4: Arquitetura de uma rede ART-2. Adaptado de CARPENTER & GROSSBERG (1987a).

A camada F1 de uma rede ART-2 pode ser considerada como consistindo de duas partes: uma parte destinada à leitura dos vetores de entrada (F1a) e outra destinada à interface entre estes vetores e a própria rede (F1b). Esta interface combina sinais recebidos tanto da leitura dos vetores quanto da camada F2, para efeito de comparação da similaridade entre o sinal de entrada com o vetor de pesos do neurônio selecionado como candidato ao aprendizado. Estes nodos podem ser considerados nodos auxiliares que pré-processam as entradas, através de uma combinação de operações de normalização dos dados. Isso torna o modelo ART-2 adequado ao processamento e classificação de dados analógicos (CARPENTER & GROSSBERG, 1987b), como os que são apresentados à rede neste trabalho, em categorias baseadas em suas similaridades. Esta é a primeira fase do processo de treinamento de uma rede ART qualquer, chamada etapa de reconhecimento.

Para efeito de controle da similaridade dos padrões de entrada alocados em uma mesma categoria existem dois grupos de conexões, cada um com suas próprias ponderações, entre cada neurônio de F1b e de F2. Cada neurônio da camada F1b se conecta a todos os neurônios da camada F2 através de conexões ascendentes: a ponderação relativa a cada conexão ascendente relacionada ao i -ésimo neurônio F1b ligada ao j -ésimo neurônio F2 será chamado a_{ij} . Por sua vez, cada neurônio da camada F2 se conecta a todos os neurônios da camada F1b através de conexões descendentes: a ponderação relativa a cada conexão descendente relacionada ao j -ésimo neurônio F2 ligada ao i -ésimo neurônio F1b será chamada d_{ij} .

A camada F2 é uma camada competitiva, na medida em que o neurônio representativo de cada categoria que retorne a maior entrada ponderada de acordo com as conexões ascendentes se torna o candidato ao aprendizado daquele padrão de entrada, e a ativação de todos os outros neurônios de F2 são zeradas. A seguir, os neurônios de F1b combinam informações oriundas do processamento ocorrido em F1a e F2. Esta é a segunda fase do treinamento de uma rede ART, chamada etapa de comparação.

A efetivação do aprendizado e conseqüente incorporação do vetor de entrada ao neurônio candidato escolhido em F2 depende da similaridade entre o vetor descendente D e o vetor de entrada. Esta decisão é tomada pela unidade de *reset*, baseado nos sinais recebidos pelas camadas F1b e F2. Se o neurônio candidato não é efetivamente escolhido como representativo da categoria do vetor de entrada, é inibido e um novo neurônio de F2 é selecionado como novo candidato ao aprendizado. Esta é a terceira fase do treinamento de uma rede ART, chamada etapa de busca.

Finalmente, nota-se que para cada fase do treinamento é requerida uma resposta distinta de cada um dos neurônios das camadas F1b e F2. Para que os mesmos consigam distinguir como desempenhar a tarefa adequadamente, existem duas unidades suplementares dotadas de pesos binários (0 para sinal inibitório e 1 para sinal excitatório) e não atualizáveis que atuam como mecanismos de controle para estas repostas, chamadas C1 e C2. A unidade C1 determina o fluxo de dados para a camada F1b, e a unidade C2 determina o fluxo de dados e habilita os neurônios da camada F2. Assim, cada neurônio de F1b e F2 nas redes ART possui três fontes pelas quais pode ser recebido um sinal:

- F1b pode receber sinais de F1a (sinal de entrada), F2 (sinal descendente) e da unidade de controle C1;
- F2 pode receber sinais de F1b (sinal ascendente), da unidade de *reset* e da unidade de controle C2;

Desta forma, a ativação adequada dos neurônios é efetivada quando se recebem dois sinais excitatórios dos três possíveis, caso contrário não ocorre ativação. Este mecanismo é conhecido como Regra dos Dois Terços.

A despeito das topologias ART apresentarem uma maior complexidade do que outras topologias neurais de uso mais geral, e seu treinamento necessitar de um número de ciclos dependente do processo de treinamento utilizado, salienta-se que a introdução de neurônios que atuam como controladores do processo de treinamento possibilitam às redes ART se mostrarem mais capazes de armazenar informações sem incorrer na criação de falsos padrões através de generalização espúria (FAUSETT, 1994; BRAGA, LUDERMIR & CARVALHO, 2000).

As redes neurais baseadas na topologia ART são utilizadas nas mais diversas aplicações relacionadas à classificação, como reconhecimento de dados em questionários, reconhecimento de alvos militares, reconhecimento de caracteres e processamento de sinais (FAUSETT, 1994; BRAGA, LUDERMIR & CARVALHO, 2000).

4.1.2 Operação e parâmetros de uma rede ART-2

Antes da descrição dos passos de inicialização e do algoritmo de uma rede ART-2, abaixo é apresentada uma lista contendo os parâmetros utilizados no algoritmo de treinamento de uma rede ART-2, conforme descrito por CARPENTER & GROSSBERG (1987b), bem como seus respectivos papéis no modelo. São citados em alguns parâmetros abaixo valores obtidos de maneira empírica pelos autores do trabalho original que descreve o modelo como sendo os valores que minimizam o número de ciclos de treinamento, ou seja, valores que permitem que a rede obtenha uma classificação com apenas um ciclo de treinamento para cada padrão apresentado à rede.

- t : número de ciclos do treinamento, ou a quantidade de vezes que um padrão deve ser apresentado à rede até que seja obtida sua classificação;
- n : número de unidades de entrada (camadas F1a e F1b);
- z : número de unidades de *cluster* (camada F2);
- a, b : pesos fixos na camada F1, ambos empiricamente obtidos com valor 10;
- c : peso fixo utilizado no teste de *reset*, obtido empiricamente com valor igual a 0,1;
- d : ativação da unidade F2 vencedora, com valor obtido empiricamente igual a 0,9;
- e : parâmetro introduzido para prevenir divisão por zero quando a norma de um vetor de dados de entrada é nula, sendo que seu valor dever ser qualquer número inteiro positivo;

- α : taxa de aprendizagem, sendo que $0 < \alpha < 1$; seu valor indica o grau em que os novos padrões pertencentes a cada *cluster* terão na atualização de seus pesos no próximo ciclo de treinamento;
- ρ : parâmetro de vigilância, sendo que $0 < \rho < 1$; este parâmetro determina quantos *clusters* serão formados, em uma razão direta ao valor adotado, o que significa que este parâmetro define o grau de variação admitido entre os próprios componentes de cada *cluster*.

Para uma rede ART-2 os pesos das conexões descendentes d_{ij} são inicializadas em zero de acordo com resultados empíricos e apresentados por CARPENTER & GROSSBERG (1987b). Já no caso das conexões ascendentes a_{ij} o valor de inicialização das mesmas é dado pela equação:

$$a_{ij}(0) \leq \frac{1}{(1-d)\sqrt{n}}, \quad (1.a)$$

com d conforme definido acima e n sendo igual ao número de conexões. Deste modo, empiricamente o valor de inicialização das conexões ascendentes a_{ij} é dado por

$$a_{ij}(0) \leq \frac{1}{0,1\sqrt{n}}, \quad (1.b)$$

Todos os valores obtidos empiricamente significam que se trata da obtenção via tentativa e erro de parâmetros de convergência interna da rede em um menor número de ciclos possível, ou seja, muito embora outros valores podem ser utilizados nos parâmetros a , b , c , d , estes números sugeridos acima são positivamente aqueles que produzem um custo

computacional menor em termos de tempo. Na prática operacional, os parâmetros obtidos empiricamente permitem que a rede classifique cada padrão com apenas um ciclo de treinamento (ZELL *et al.*, 2001), sendo assim, t acima definido como sendo igual a 1.

No procedimento de atualização dos pesos da rede, são possíveis duas abordagens operacionais: treinamento sincronizado e treinamento estável. No treinamento sincronizado, a rede efetua um passo de propagação a cada inicialização, e no treinamento estável a rede propaga o padrão até obter uma classificação para o mesmo. Assim, pode-se dizer que se for necessário traçar o caminho do padrão através da rede, lança-se mão do treinamento sincronizado, caso contrário utiliza-se o treinamento estável, o qual também requer menos tempo para executar a tarefa.

4.1.3 Algoritmo de treinamento de uma rede ART-2

Com o intuito de tornar mais claro o procedimento de classificação realizado pela rede ART-2, descreve-se a seguir a estrutura do seu algoritmo, conforme FAUSETT (1994):

Passo 1: Inicializar os parâmetros da rede:

$$a, b, c, d, e, \rho$$

Determinar t (número de ciclos do treinamento).

Passo 2: Para cada vetor de entrada \mathbf{I} , repetir passos 3, 4 e 5 z vezes até obter classificação do padrão apresentado; caso contrário, criar nova unidade em F2.

Passo 3: Buscar $Y_{j\text{-ésima}}$ unidade F2 com maior sinal. (Definir J para $y_j \geq y_j$ para $j = 1, \dots, m$).

Passo 4: Verificar *reset*, de acordo com valor de ρ ; se o valor de comparação for pelo menos igual a ρ , *reset* é verdadeiro, caso contrário é falso.

Passo 5: Se *reset* for verdadeiro, buscar a próxima $Y_{J\text{-ésima}}$ unidade F2 com maior sinal; se *reset* for falso, atualizar conexões da unidade F2 vencedora, de acordo com

$$d_{ij(\text{vencedor}, t+1)} = (1+\alpha)d_{ij(\text{vencedor}, t)} \quad (2)$$

4.2.1 Redes SOM

O estudo da neurofisiologia não serviu como base e inspiração apenas na criação de topologias neurais e seus respectivos algoritmos de treinamento, mas também foi o ponto de partida na proposição de arquiteturas que simulam o funcionamento do cérebro na armazenagem de conhecimento e no desempenho de tarefas cognitivas. Estas redes são conhecidas como modelos de Kohonen (KOHONEN, 1989), ou redes SOM, as quais são descritas a seguir.

Uma característica extremamente útil em uma análise classificatória para um conjunto de dados seria a possibilidade de se apresentar as estruturas contidas em uma determinada base de dados de uma forma que seja facilmente inteligível e ao mesmo tempo preserve a maior quantidade de informação presente nos dados originais possível. Alguns modelos neurais auto-organizados são métodos que apresentam as características essenciais de um grupo de dados, como a estrutura de suas categorias e os relacionamentos entre seus itens, em uma forma bidimensional.

Freqüentemente, padrões contidos em um conjunto de dados n -dimensional possuem uma estrutura bastante complexa, mas que pode se apresentar mais clara se for resumida em um espaço de características uni, bi ou tridimensional. KOHONEN (1989) desenvolveu os modelos SOM como uma forma de detectar automaticamente similaridades relevantes em grandes bases de dados, através da construção de um mapa facilmente caracterizável a partir de um espaço multidimensional, tornando assim os *clusters* mais prontamente visualizáveis.

Assim como os modelos multicamadas genéricos de redes neurais, os modelos SOM envolvem a adaptação das ponderações das conexões em reflexo ao aprendizado obtido, porém este aprendizado não é supervisionado na medida em que a saída desejada para a rede não é conhecida. Outra diferença significativa entre os modelos SOM e os modelos neurais genéricos reside na arquitetura e no papel desempenhado pela localização dos neurônios no processo de aprendizado. Na rede SOM os vetores de entrada são ligados a um arranjo de neurônios (D_n), normalmente unidimensional (uma linha) ou bidimensional (uma matriz). A Figura 5 mostra esta arquitetura para n entradas e uma matriz quadrada com nove neurônios.




FIGURA 5: Arquitetura de uma rede SOM. A seta larga indica que todas as entradas estão conectadas a todos os neurônios do mapa topológico. Adaptado de BRAGA, LUDERMIR & CARVALHO (2000).

Quando um padrão de entradas é apresentado à rede SOM, certas regiões da camada de neurônios se tornam ativas, e as ponderações entre as conexões da camada de entrada e estas regiões são reforçadas. Uma vez concluído o aprendizado, padrões de entrada similares causarão atividade semelhante nas mesmas regiões do mapa topológico. A idéia principal contida neste modelo é a obtenção de uma ordenação e um arranjo entre os neurônios. A ordenação obtida é importante na medida em que a mesma refere-se a regiões de neurônios ativadas simultaneamente, e o arranjo encontrado se refere à intensidade desta ativação. Se um determinado neurônio é ativado, provavelmente outros em sua região de vizinhança também serão ativados, e assim é gerado um arranjo físico dos neurônios baseado em sua localização (KOHONEN, 1989; DEBOECK & KOHONEN, 2000). Esta arquitetura apresenta uma justificativa biológica importante, já que o cérebro humano apresenta regiões

de neurônios operando de forma centralizada e localizada em relação à execução de determinadas tarefas (córtex auditivo, córtex visual, etc).

4.2.2 Conceito de vizinhança em redes SOM

A maior característica dos resultados produzidos por uma rede SOM consiste na emulação dos mesmos em uma estrutura que procura simular o sistema nervoso central humano. Assim, sabe-se que no cérebro humano em atividade normal há claramente a existência de um “neurônio vencedor”, definido como sendo o neurônio cujas ponderações são mais semelhantes ao padrão apresentado, e que é ativado nas situações em que ocorre a recepção de um determinado estímulo. De maneira a simular esta resposta do cérebro humano nos modelos SOM, o processo de aprendizado é modificado e o “neurônio vencedor” captura a maior parte do conhecimento adquirido acerca de determinados padrões, mas as ponderações dos neurônios da região de vizinhança do “neurônio vencedor” também aprendem com a entrada apresentada em menor grau.

Deste modo, deve-se definir o conceito de região de vizinhança $V_m(t)$ em relação à arquitetura SOM. Em um arranjo linear de neurônios, a vizinhança é simplesmente composta pelos neurônios à direita e à esquerda do vencedor. Entretanto, para se compreender o efeito de uma região de neurônios ativa, deve-se considerar vizinhanças maiores, como mostrados na Figura 6, para um arranjo bidimensional de neurônios com uma estrutura de vizinhança retangular.

Inicialmente, o tamanho da região de vizinhança ao redor do neurônio vencedor deve ser suficientemente grande para que ocorra uma especialização regional dos neurônios de acordo com cada padrão, mas à medida que o procedimento do aprendizado se consolida, a

região de vizinhança deve diminuir gradativamente para que a resposta da rede se torne mais localizada. Esta resposta localizada, necessária para a distinção entre os diferentes padrões, é reforçada pela variação da quantidade de aprendizado percebida por cada neurônio contido na região de vizinhança do neurônio vencedor. O neurônio vencedor recebe a maior parte do aprendizado, e seus vizinhos aprendem cada vez menos à medida que se encontram mais afastados do vencedor.

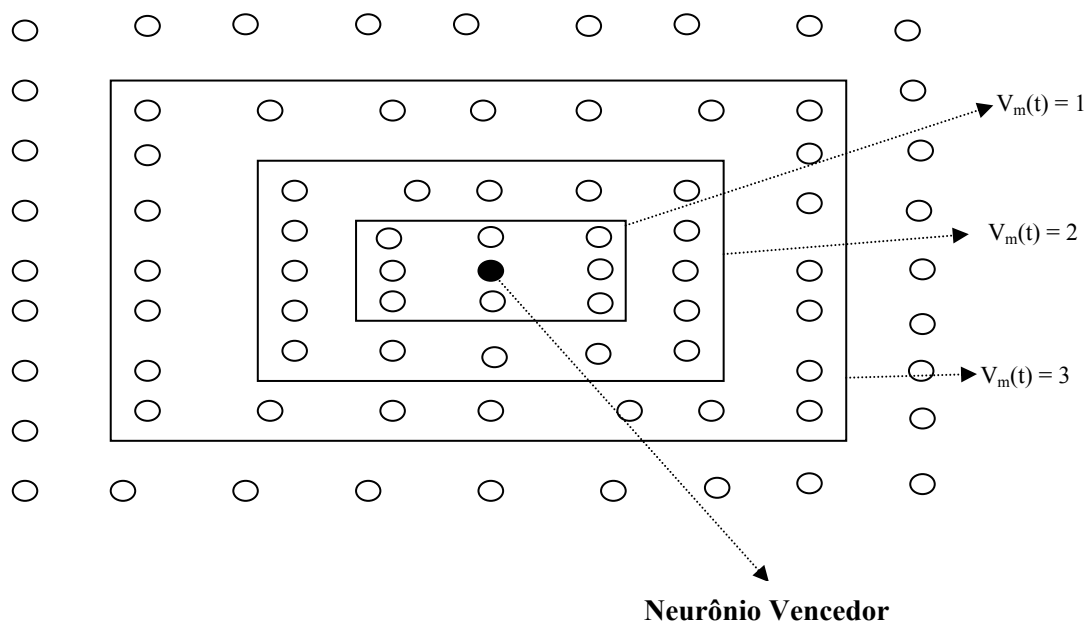


FIGURA 6: Conceito de região de vizinhança em um arranjo retangular de neurônios.

Adaptado de (FAUSETT, 1994).

Os mapas topológicos obtidos pelos modelos SOM desempenham um método de exibição adaptativa particularmente útil na representação de dados estatísticos estruturados. As características presentes nesta estrutura que se mostram relevantes em uma análise exploratória de dados são basicamente as seguintes:

- O mapeamento obtido representa uma base de dados de maneira ordenada, por meio do qual similaridades entre as amostras dos dados são visualizadas como relações geométricas das imagens das amostras contidas no mapa;
- A ordem obtida no mapeamento torna o mesmo plausível de ser utilizado como base na qual os indicadores estatísticos individuais podem ser visualizados, o que também os torna facilmente compreensíveis, bem como o grau de *clustering* de cada elemento pode ser representado por escalas de cinza ou colorida.

Assim como outros modelos de redes neurais, o algoritmo de aprendizado de uma rede SOM segue os procedimentos básicos contidos na apresentação de um padrão de entrada, no cálculo das saídas dos neurônios do mapa topológico, e na atualização das ponderações. As diferenças residem no método usado para o cálculo das saídas, baseado na similaridade entre as ponderações e as entradas, e o conceito de vizinhança na atualização das ponderações.

4.2.3 Operação e algoritmo de uma rede SOM

Conforme SMITH & GUPTA (2000), definindo o tamanho da vizinhança ao redor de um neurônio vencedor m em um período t como sendo $V_m(t)$, a parcela de aprendizado que cada neurônio i em conjunto com sua vizinhança m recebe é determinada por:

$$L = a(t) \exp(-|r_i - r_m|/\sigma^2(t)) \quad (3)$$

onde $r_i - r_m$ é a distância física (expressa em quantidade de neurônios) entre o neurônio i e o neurônio vencedor m .

As funções $a(t)$ e $\sigma^2(t)$ são usadas no controle do montante de conhecimento que cada neurônio aprende em relação ao neurônio vencedor, e devem ser funções decrescentes ao longo do tempo. O montante de conhecimento deve ser maior no neurônio vencedor (onde $i = m$ e $r_i = r_m$) e deve diminuir em uma proporção exponencial do inverso da distância entre o neurônio vizinho e o neurônio vencedor. Neurônios externos à região de vizinhança não capturam nenhum aprendizado a respeito do padrão apresentado.

Assim como outros modelos de redes neurais, o algoritmo de aprendizado de uma rede SOM segue os procedimentos básicos contidos na apresentação de um padrão de entrada, cálculo das saídas dos neurônios do mapa topológico, e atualização das ponderações. As diferenças residem no método usado para o cálculo das saídas, baseado na similaridade entre as ponderações e as entradas, e o conceito de vizinhança na atualização das ponderações. Este procedimento algorítmico é basicamente o seguinte (FAUSETT, 1994):

Passo 1: Inicializar

- ponderações em pequenos valores randômicos;
- tamanho da vizinhança $V_m(0)$ grande (mas menor do que o número de neurônios em uma dimensão do arranjo);
- parâmetros das funções $a(t)$ e $\sigma^2(t)$ entre 0 e 1.

Passo 2: Apresentar um padrão de entradas x à camada de entrada e calcular sua distância em relação às ponderações de cada neurônio j :

$$D_j = \|x - w_j\| = \sqrt{\sum_{i=1}^n (x_i - w_{ij})^2} \quad (4)$$

Passo 3: Selecionar o neurônio com a menor distância em relação ao vencedor m .

Passo 4: Atualizar as ponderações das conexões entre o padrão de entrada e o neurônio vencedor e sua região de vizinhança de acordo com a regra de aprendizagem:

$$w_{ij}(t+1) = w_{ij}(t) + L[x_i - w_{ij}(t)], \quad (5)$$

onde

$$L = a(t) \exp(-|r_i - r_m|/\sigma^2(t)) \quad (6)$$

para qualquer neurônio j em $V_m(t)$.

Passo 5: Continue a partir do *Passo 2* por Ω ciclos; então diminuir tamanho da vizinhança, $a(t)$ e $\sigma^2(t)$;

Repetir até ponderações estabilizarem.

As redes SOM têm sido predominantemente usadas em procedimentos de *clustering* e extração de características, como uma técnica de *data mining* (ZHANG, PATUWO & HU,

1998; VELLIDO, LISBOA & VAUGHAN, 2000). Também existem pesquisas relacionadas ao uso de redes SOM na obtenção de soluções de problemas de otimização e controle, bem como em diagnósticos financeiros (DEBOECK & KOHONEN, 2000).

4.3 Redes neurais auto-organizadas e a proposta deste estudo

Este Capítulo procurou, através da descrição de duas topologias neurais auto-organizadas, apresentar suas características mais relevantes, que as tornariam úteis em análises de dados complexos e inter-relacionados: a geração de respostas não direcionadas por crítica externa, sendo possível encontrar relacionamentos não percebidos pelo operador, tanto no caso das redes ART como nas redes SOM; a solução do Problema da Dimensionalidade e a conseqüente eliminação da geração de falsos padrões, no caso específico das redes ART; e a obtenção de mapas visuais a partir de *clusters* e seus respectivos neurônios vencedores no caso das redes SOM. Deste modo, um sistema seqüencial de análise de dados macroeconômicos através do emprego destas topologias acima descritas é apresentado a seguir, bem como os resultados obtidos são apresentados e discutidos.

5. ABORDAGEM NEURAL NÃO SUPERVISIONADA NA ELABORAÇÃO E ANÁLISE DE CENÁRIOS MACROECONÔMICOS

Nesta etapa do estudo realizado, efetua-se uma análise da viabilidade da aplicação de um método computacional totalmente baseado em topologias neurais auto-organizadas e não supervisionadas, através da utilização de uma base de dados relativas ao estudo da Macroeconomia. O método utilizado baseia-se em um processamento efetuado em quatro fases, feito seqüencialmente. Cada uma das fases se torna geradora de entradas para a fase seguinte; contudo, o tempo necessário no desempenho de cada uma das tarefas é relativamente baixo, especialmente quando comparado às metodologias mais tradicionais citadas no Capítulo introdutório deste trabalho.

O estudo foi inteiramente realizado com o emprego de apenas um computador pessoal, equipado com um processador AMD *Athlon* com velocidade de processamento de 1,2 *Gigahertz*, 20 *Megabites* de espaço em disco rígido e 256 *Megabites* de memória virtual. Os softwares usados foram o *Statistica Neural Networks*, versão 4.0 F, e o *freeware* disponibilizado em conjunto pelo *Institute for Parallel and Distributed High Performance Systems* (IPVR) da *University of Stuttgart* e pelo *Wilhelm-Schickard-Institute for Computer Science* da *University of Tübingen*, ambos na Alemanha, chamado SNNS – *Stuttgart Neural Network Simulator*, na sua versão 4.2, obtido em:


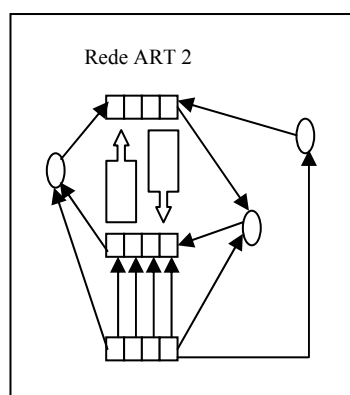
<http://www-ra.informatik.uni-tuebingen.de/downloads/SNNS/Windows/>

O *software* acima foi desenvolvido em plataforma Unix, e para que seja possível sua utilização no sistema operacional *Windows* foi necessário o emprego do simulador *X-Win32*, versão *Demo 3.4.1*, obtido gratuitamente no *link*:

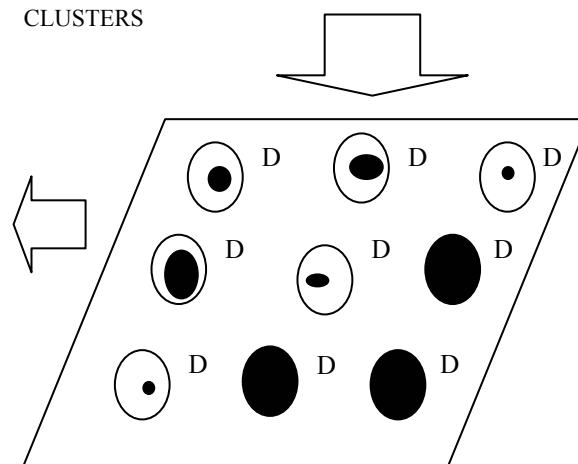
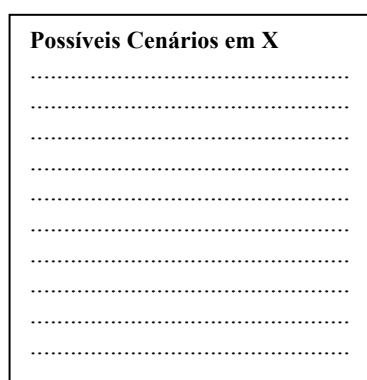

<http://www-ra.informatik.uni-tuebingen.de/downloads/SNNS/Windows/Sources/X11-Lib/>

O modelo neural híbrido empregado consiste, conforme mencionado, em quatro fases distintas, esquematizado na Figura 7:



- Fase 1: Uso de um modelo neural ART-2, com o propósito específico de se gerar *clusters* a partir dos países, através de seleção efetuada pelo algoritmo próprio, baseada nos dados macroeconômicos de cada um dos mesmos;
- Fase 2: Identificação dos componentes das categorias obtidas nas redes ART-2 empregadas;
- Fase 3: Elaboração de mapas topológicos para cada um dos *clusters* obtidos, através do uso do algoritmo SOM;
- Fase 4: Elaboração de cenário macroeconômico para cada *cluster*, através de análise econômica, com a apresentação e discussão dos resultados obtidos via classificação neural, com base na identificação do grau de conformidade ou aderência ao cluster para cada país individualmente, através da análise visual do mapa topológico.

FASE 1

CLUSTERS

FASE 2

CLUSTER X



CLUSTER Z

FASE 4**FASE 3**

FIGURA 7: Sistema neural híbrido usado na elaboração e estudo de cenários macroeconômicos.

Como variáveis empregadas na obtenção dos *clusters* na Fase 1, são utilizados os dados contidos no “*THE 1999 WORLD BANK DEVELOPMENT INDICATORS CD-ROM*”, versão 4.2, que consiste em uma base de 503 dados dispostos em uma série de tempo anual para um total de 210 países, entre os anos de 1960 e 1997, renovada anualmente pelo *World Bank* com a incorporação de estatísticas dos anos mais recentes. Destes, foram escolhidos os 154 países os quais existem 27 dados macroeconômicos disponíveis para o ano de 1997, devido ao mesmo ser o mais recente dentre os que constam na publicação. Países nos quais mais de um quarto dos dados utilizados não estão disponibilizados no trabalho foram excluídos deste estudo. O Apêndice B apresenta várias tabelas nas quais constam, por região do Globo, os países classificados em *clusters* pelo sistema neural usado.

Os dados de Produto Interno Bruto, Produto Nacional Bruto e Renda *per capita* foram excluídos do estudo, devido à sua importância relativamente maior na implicação dos outros dados utilizados. Justifica-se esta exclusão, entretanto, por não se poder afirmar o quanto mais importantes tais informações seriam, e na ausência de uma ponderação relativamente razoável fundamentada empiricamente, os mesmos não foram utilizados, adotando-se uma metodologia semelhante àquela adotada em KASKI & KOHONEN (1996), nas quais a não utilização da renda *per capita* se justificou devido ao interesse em demonstrar relacionamentos menos evidentes entre os dados com o uso de uma única rede SOM.

Abaixo se encontram identificados e descritos em oito áreas de concentração os dados macroeconômicos utilizados na entrada da rede ART-2 que compõe a Fase 1, na sua exata ordem de apresentação à rede neural:

1. Razões econômicas primárias em função do Produto Interno Bruto (PIB), definido pelo *World Bank* como o conjunto da produção final de bens e serviços realizada em um determinado país, independentemente da nacionalidade dos agentes econômicos, em um período de um ano:

- Investimento doméstico bruto/PIB: razão entre despesas com o aumento dos ativos fixos da economia mais mudanças líquidas nos níveis de estoques e o Produto Interno Bruto, expressa em porcentagem;
- Exportações de bens e serviços/PIB: razão entre o valor das exportações de bens e serviços e o Produto Interno Bruto, expressa em porcentagem;
- Poupança doméstica bruta/PIB: razão entre o montante poupado no país por residentes e não residentes e o Produto Interno Bruto, expressa em porcentagem;
- Poupança nacional bruta/PIB: razão entre o montante poupado por residentes no país e no exterior e o Produto Interno Bruto, expressa em porcentagem;
- Pagamento de juros/PIB: razão entre o total financeiro relacionado ao pagamento de juros sobre passivos contraídos pelo país no exterior e o Produto Interno Bruto, expressa em porcentagem;
- Dívida total/PIB: razão entre o valor global da dívida externa (se existir) do país e o Produto Interno Bruto, expressa em porcentagem;
- Valor presente da dívida/PNB: razão entre a atualização monetária do valor da dívida externa (se houver) do país em 1997, calculada pelo método do Valor Presente Líquido, e o Produto Interno Bruto, expressa em porcentagem;
- Crescimento do PIB: percentual de crescimento ou queda do Produto Interno Bruto.

2. Comércio internacional:

- Exportação agrícola: montante total da exportação de produtos agrícolas, expresso em bilhões de dólares americanos em 1997;
- Exportação industrial: montante total da exportação de produtos manufaturados, expresso em bilhões de dólares americanos em 1997;
- Exportação de serviços: montante total da exportação de produtos financeiros e outros serviços, expresso em bilhões de dólares americanos em 1997;
- Importação de bens e serviços: montante total da entrada de produtos financeiros e outros serviços, expresso em bilhões de dólares americanos em 1997;
- Importação agrícola: montante total da importação de produtos agrícolas, expresso em bilhões de dólares americanos em 1997;
- Importação industrial: montante total da importação de produtos industrializados, expresso em bilhões de dólares americanos em 1997;
- Importação de serviços: montante total da entrada de serviços prestados por não-residentes, expresso em bilhões de dólares americanos em 1997.

3. Dados de consumo agregado:

- Consumo privado: valor de mercado de todos os bens e serviços adquiridos ou recebidos como renda pelas famílias e por instituições sem fins lucrativos, expresso em bilhões de dólares americanos em 1997;
- Consumo governamental: inclui todas as despesas correntes com compras de bens e serviços, inclusive salários e pensões, por todos os níveis de governo, exceto autarquias, expresso em bilhões de dólares americanos em 1997.

4. Preços domésticos:

- Variação de preços ao consumidor: calculado de acordo com as estatísticas oficiais do país, expresso em porcentagem relacionada à variação do índice de preços oficial.

5. Indicadores monetários:

- Deflator implícito do PIB: mede a taxa média anual da variação dos preços em uma economia, calculado pelo método dos mínimos quadrados e expresso em porcentagem.

6. Finanças governamentais:

- Receitas correntes: total de impostos e outras rendas do governo em um determinado exercício, expresso em bilhões de dólares americanos em 1997;
- Superávit ou déficit primário: excesso ou falta de recursos por parte do governo, descontados os gastos com consumo e investimento governamentais, para o exercício de 1997.

7. Balanço de pagamentos:

- Renda líquida investida no exterior: receita de investimentos diretos e em ativos financeiros efetuados no exterior, expressa em bilhões de dólares americanos em 1997;
- Transferências correntes líquidas: transferências ao exterior de ativos financeiros sem contrapartida (como doações, por exemplo), expressa em bilhões de dólares americanos em 1997;
- Balanço da conta corrente: somatório líquido de exportações de bens e serviços, rendas, e transferências correntes, expressa em bilhões de dólares americanos em 1997;

- Mudança nas reservas: variação observada no saldo dos ativos financeiros mantidos pelo Banco Central de um determinado país na comparação de um exercício fiscal com o exercício imediatamente anterior, expresso em porcentagem;
- Reservas, incluindo ouro: total dos ativos financeiros mantidos pelo Banco Central de um determinado país ao final de um dado exercício, expresso em bilhões de dólares americanos em 1997.

8. Dívida externa e fluxo de capitais:

- Serviço total da dívida: somatório dos pagamentos relativos a principal e juros sobre o total da dívida externa de curto e longo prazo, efetuados geralmente em moeda estrangeira, mais recompra de títulos públicos e novos empréstimos obtidos junto ao Fundo Monetário Internacional, expresso em bilhões de dólares americanos em 1997.

Os resultados foram analisados de acordo com *benchmark* realizado através de comparação com os grupos de países classificados de acordo com a renda *per capita* - item tradicionalmente utilizado na classificação de países sob o aspecto de contas nacionais - contidos no CD-ROM utilizado como base de dados para o estudo. Encontram-se referidos na Tabela 1 abaixo os países, segundo sua renda *per capita* em 1997, de acordo com os dados e a classificação do *World Bank*:

TABELA 1: Países de renda *per capita* baixa, de acordo com WORLD BANK (1995)

Baixa Renda <i>Per Capita</i> – até US\$ 2000 (1997)					
Angola	820	Guiné Equatorial	1.790	Paquistão	1.580
Azerbaijão	1.520	Guiné-Bissau	230	Quênia	1.160
Bangladesh	1.090	Haiti	1.260	Rep. Centro- Africana	1.310
Benin	1.260	Iêmen	720	Rep. Congo	1.290
Burkina Faso	1.000	Ilhas Salomão	623	Rep. Dem. Congo	760
Burundi	620	Índia	1.660	Rwanda	650
Butão	430	Laos	1.300	São Tomé e Príncipe	290
Cabo Verde	1.090	Madagascar	900	Senegal	1.690
Camarões	1.770	Malawi	700	Serra Leoa	410
Camboja	1.290	Maldivas	1.130	Suazilândia	1.520
Comoros	400	Mali	720	Sudão	1.370
Costa do Marfim	1.690	Mauritânia	1.650	Tanzânia	620
Cuba	364	Mianmar	668	Tchad	950
Djibouti	510	Moçambique	690	Togo	1.460
Eritrêa	1.040	Moldova	1.450	Tonga	1.810
Etiópia	500	Mongólia	1.490	Uganda	1.160
Gâmbia	1.440	Nepal	1.090	Uzbequistão	1.020
Gana	1.610	Niger	830	Vanuatu	1.340
Geórgia	1.980	Nigéria	860	Vietnã	1.590
Guiana	800	Papua Nova Guiné	930	Zâmbia	910

Percebe-se nesta Tabela que os países considerados de baixa renda pelo *World Bank* são países pertencentes, respectivamente, à África Sub-Saariana, à Ásia Central e do Sul, e mais Cuba, o Iêmen e a Mongólia.

TABELA 2: Países de renda *per capita* média-baixa, de acordo com WORLD BANK (1995).

Renda <i>Per Capita</i> Média-Baixa – de US\$ 2000 a US\$ 4000 (1997)					
Albânia	2.170	El Salvador	2.860	Letônia	3.970
Armênia	2.540	Equador	4.700	Macedônia	3.180
Bahreïn	2.070	Fiji	2.460	Marrocos	3.210
Belize	2.670	Filipinas	3.670	Paraguai	3.860
Bolívia	2.810	Honduras	2.260	Samoa	3.915
Bulgária	3.870	Jamaica	3.330	Síria	3.000
Cazaquistão	3.530	Jordânia	3.350	Sri Lanka	2.460
China	3.070	Kirjistão	2.180	Ucrânia	2.170
Dominica	3.040	Lesoto	2.490	Zimbabwe	2.240
Egito	3.080				

Nesta faixa de renda *per capita* encontra-se, de acordo com o *World Bank*, países dos cinco continentes, sendo portanto geograficamente mais bem distribuída pelo mundo.

TABELA 3: Países de renda *per capita* média, de acordo com WORLD BANK (1995).

Renda <i>Per Capita</i> Média – de US\$ 4000 a US\$ 7000 (1997)					
Argélia	4.250	Hungria	6.970	Romênia	4.270
Bielo-Rússia	4.820	Irã	5.690	Rússia	4.280
Estônia	5.090	Líbano	6.090	Seychelles	6.910
Brasil	6.350	Lituânia	4.140	Tailândia	6.490
Colômbia	6.570	Namíbia	5.100	Trinidad e Tobago	6.460
Costa Rica	6.510	Peru	4.580	Tunísia	5.050

Gabão	6.560	Polônia	6.510	Turquia	6.470
Guatemala	4.060	Rep. Dominicana	4.690		

Também nesta faixa de renda nota-se a presença de países dos cinco continentes, com uma notável participação da América Latina.

TABELA 4: Países de renda *per capita* média-alta, de acordo com WORLD BANK (1995).

<u>Renda Per Capita Média – Alta - de US\$ 7000 a US\$ 15000 (1997)</u>					
África do Sul	7.190	Eslovênia	11.880	México	8.110
Arábia Saudita	10.540	Grécia	12.540	Rep. Coréia	13.430
Argentina	10.100	Ilhas Maurícios	9.230	Rep. Tcheca	10.380
Botswana	7.430	Malásia	7.730	Uruguai	9.110
Chile	12.240	Malta	9.330	Venezuela	8.660
Eslováquia	7.860				

Nesta categoria vê-se países dos cinco continentes, caracterizados por economias com forte setor exportador; contudo, disparidades cambiais podem influenciar esta classificação em alguns casos (Botswana, Rep. Coréia).

TABELA 5: Países de renda *per capita* alta, de acordo com WORLD BANK (1995).

Renda Per Capita Alta – a partir de US\$ 15000 (1997)					
Alemanha	21.170	França	22.210	Kuwait	23.519
Austrália	19.510	Holanda	21.300	Noruega	24.260
Áustria	22.010	Hong Kong	24.350	Nova Zelândia	15.780
Bélgica	23.090	Ilhas Virgens	22.890	Portugal	14.180
Canadá	21.750	Irlanda	17.420	Reino Unido	20.710
Dinamarca	23.450	Islândia	24.001	Singapura	29.230
Espanha	15.690	Israel	17.680	Suécia	19.010
Estados Unidos	29.080	Itália	20.100	Suíça	26.580
Finlândia	19.660	Japão	24.400		

Na classe que engloba os países de alta renda, nota-se a presença dos países tradicionalmente considerados desenvolvidos do mundo, com a inclusão de alguns paraísos fiscais (Hong Kong, Ilhas Virgens), um país exportador de petróleo (Kuwait) e outros de desenvolvimento mais recente (Irlanda, Islândia, Israel, Nova Zelândia, Singapura).

5.1. Fase 1

Foi nesta etapa empregada uma rede neural baseada na topologia conhecida como ART-2, com os seguintes parâmetros de inicialização da rede adotados, de acordo com CARPENTER & GROSSBERG (1987 b) e ZELL *et. al.*, (2000):

- Treinamento estável;
- $t = 1$ ciclo;

- Conexões $d_{ij} = 0$;
- Conexões $a_{ij} = 1,92$ (valor máximo obtido na Equação 1.b);
- $n = 27$;
- $z = 25$;
- $a = 10$;
- $b = 10$;
- $c = 0,1$;
- $d = 0,9$;
- $e = 1$;
- $\alpha = 0,7$.

O parâmetro ρ foi testado com três valores diferentes, respectivamente 0,4, 0,7 e 0,9, no intuito de se verificar possível diferenças quanto às classificações neurais obtidas face à variação do parâmetro de vigilância da rede, o que acabou se mostrando de fundamental importância nas classificações obtidas na rede ART-2. A quantidade de *clusters* obtida em cada uma das redes – considerando cada ρ como compondo uma rede neural ART-2 distinta das demais - está contida na Tabela 6 abaixo:

TABELA 6: Quantidade de *clusters* obtidos para cada valor de ρ empregado no estudo

<u>Valor de ρ</u>	<u>Número de clusters obtidos</u>
0,4	4
0,7	5
0,9	12

A razão da variação na quantidade de *clusters* retornados pela rede ART-2, conforme CARPENTER & GROSSBERG (1987 b) é clara: valores altos de ρ permitem uma miscigenação menor entre os componentes de cada categoria, fazendo com que seja admitida uma diversificação menor nas mesmas. À medida que se diminui ρ , esta diferenciação se torna menos relevante na fase de busca das redes ART, o que leva à obtenção de uma menor quantidade de *clusters*. Para cada valor de ρ , são apresentados nas Tabelas abaixo a quantidade de países em cada um dos *clusters* gerados.

TABELA 7: Quantidade de países em cada um dos *clusters* obtidos para $\rho = 0,4$.

$\rho = 0,4$	<u>Quantidade de Países</u>
1	1
2	4
3	9
4	140

Percebe-se nesta primeira rede ART-2, com um valor de ρ baixo, que poucos países foram qualificados como sendo suficientemente distintos dos demais para que se justificasse a geração de um *cluster* correspondente. Como resultado, nota-se que existem apenas quatro categorias, sendo uma delas bastante genérica, contendo 140 países.

TABELA 8: Quantidade de países em cada um dos *clusters* obtidos para $\rho = 0,7$.

<u>$\rho = 0,7$</u>	<u>Quantidade de Países</u>
1	1
2	4
3	9
4	1
5	139

Nesta segunda rede ART-2, vemos que a antiga categoria genérica encontrada na rede anterior classificou apenas mais uma classe de países, e ainda assim com apenas um componente. Assim, o incremento no valor de ρ de 0,4 para 0,7 produziu pouco efeito na obtenção de categorias de países mais definidas.

TABELA 9: Quantidade de países em cada um dos *clusters* obtidos para $\rho = 0,9$.

<u>$\rho = 0,9$</u>	<u>Quantidade de Países</u>
1	1
2	4
3	9
4	1
5	1
6	15

7	24
8	21
9	39
10	9
11	6
12	24

Nesta última rede ART-2 percebemos a geração de diversas classes de países, as quais discutiremos na Fase 3, com a apresentação dos mapas topológicos. Contudo, a categoria genérica ainda não desapareceu por completo, indicando duas prováveis hipóteses: a primeira seria relativa a uma insuficiência dos dados macroeconômicos disponíveis para a obtenção de uma classificação perfeitamente uniforme, e a segunda seria de que existem relacionamentos entre as variáveis macroeconômicas que não são suficientemente evidentes para que se possa compreender sua interação, remetendo-nos ao problema da complexidade discutido no Capítulo 2 deste trabalho.

5.2. Fase 2

Os componentes de cada mapa topológico para cada um dos *clusters* obtidos, através do uso de redes ART-2, estão apresentados nas Tabelas 10, 11 e 12 dispostas no seguimento do texto.

TABELA 10: Países contidos em cada cluster, para $\rho = 0,4$.

<u>Cluster</u>	<u>Países</u>
1	Estados Unidos
2	Austrália, Nova Zelândia, Hong Kong, Holanda
3	Alemanha, Áustria, Bélgica, Canadá, Finlândia, França, Itália, Japão, Reino Unido
4	Demais países restantes

A primeira rede ART-2, com parâmetro de vigilância igual a 0,4 destacou países de renda relativamente elevada, conforme se pode ver na Tabela acima. Os demais permaneceram em uma categoria genérica, não sendo diferenciados pela rede neural.

TABELA 11: Países contidos em cada cluster, para $\rho = 0,7$.

<u>Cluster</u>	<u>Países</u>
1	Estados Unidos
2	Austrália, Nova Zelândia, Hong Kong, Holanda
3	Alemanha, Áustria, Bélgica, Canadá, Finlândia, França, Itália, Japão, Reino Unido
4	Cuba
5	Demais países restantes

Na segunda rede ART-2 vê-se que apenas Cuba foi destacada da categoria genérica obtida na rede anterior.

TABELA 12: Países contidos em cada cluster, para $\rho = 0,9$.

<u>Cluster</u>	<u>Países</u>
1	Estados Unidos
2	Austrália, Holanda, Hong Kong, Nova Zelândia
3	Alemanha, Áustria, Bélgica, Canadá, Finlândia, França, Itália, Japão, Reino Unido
4	Cuba
5	China
6	Cabo Verde, Chile, Comoros, Dinamarca, Fiji, Geórgia, Grécia, Ilhas Maurícios, Ilhas Salomão, Ilhas Virgens, Indonésia, Maldivas, Malta, Moldova, Noruega, Papua Nova Guiné, Samoa, São Tomé e Príncipe, Suécia, Suíça, Tanzânia, Tonga, Trinidad e Tobago, Vanuatu
7	Albânia, Bielo-Rússia, Bulgária, Eslováquia, Eslovênia, Estônia, Hungria, Letônia, Lituânia, Macedônia, Polônia, República Tcheca, Romênia, Rússia, Ucrânia
8	Belize, Bolívia, Brasil, Colômbia, Costa Rica, Dominica, El Salvador, Equador, Filipinas, Guatemala, Guiana, Honduras, Jamaica, Líbano, Malásia, México, Mianmar, Paraguai, Peru, República Dominicana, Sri Lanka, Tailândia, Uruguai, Venezuela
9	Argélia, Armênia, Azerbaijão, Bangladesh, Butão, Camboja, Cazaquistão,

	Egito, Índia, Jordânia, Kirjistão, Laos, Marrocos, Mongólia, Nepal, Paquistão, Síria, Tunísia, Turquia, Uzbequistão, Vietnã
10	Angola, Botswana, Burkina Faso, Burundi, Camarões, Costa do Marfim, Djibouti, Eritreia, Etiópia, Gabão, Gâmbia, Gana, Guiné Equatorial, Guiné-Bissau, Haiti, Lesoto, Madagascar, Malawi, Mali, Mauritânia, Moçambique, Namíbia, Niger, Nigéria, Quênia, Rep. Congo, Rep. Dem. Congo, República Centro-Africana, Rwanda, Senegal, Serra Leoa, Seychelles, Suazilândia, Sudão, Tchad, Togo, Uganda, Zâmbia, Zimbabwe
11	África do Sul, Argentina, Espanha, Irlanda, Islândia, Israel, Portugal, Rep. Coreia, Singapura
12	Arábia Saudita, Bahrein, Benin, Iêmen, Irã, Kuwait

Nesta última rede ART-2 encontra-se uma divisão das categorias maior e mais detalhada dos países que compõem o estudo. Mais à frente serão discutidas as composições de cada *cluster* obtido, bem como a aderência de cada componente do *cluster* ao mesmo face à análise visual dos mapas topológicos das redes SOM. Salienta-se que, muito embora a visualização obtida nas redes SOM é um excelente meio de se comparar categorias e detectar relacionamentos obscuros entre seus componentes, o próprio desconhecimento *a priori* do significado de determinado relacionamento entre as variáveis torna a análise dos *clusters* relativamente complexa e realizada parcialmente de forma intuitiva. A pesquisa por similaridades entre os dados de entrada utilizados na Fase 1 deste estudo foi uma alternativa empregada na tentativa de se descobrir o que é considerado relevante no emparelhamento dos *clusters* pela rede neural, contudo esta limitação analítica deve ser ressaltada.

5.3. Fase 3

Nesta etapa apresenta-se uma exploração das estruturas visuais obtidas com o emprego de uma rede SOM, realizada para cada componente individualmente. Foi empregado um tamanho padrão referente ao mapa topológico, consistindo de um arranjo bidimensional de 50 neurônios de largura por 50 neurônios de comprimento, totalizando 2.500 neurônios. Foi escolhido tal tamanho relativamente avantajado em face da quantidade de dados contidos no estudo (27 características para 154 países). Os parâmetros de inicialização do algoritmo da rede SOM foram os seguintes:

- $V_m(0) = 1$ (limitação do *software* empregado)
- $L = 0,1$
- $\Omega = 1000$ ciclos (limite máximo de iterações da rede)

Na Figura 8 a seguir ilustramos um mapa topológico reduzido com as dimensões dos mapas apresentados a seguir. A numeração dos neurônios segue a ordem da esquerda para a direita e de cima para baixo, com 50 neurônios em cada linha. Assim, o primeiro neurônio do alto à esquerda é o neurônio de número 1, o último neurônio da primeira linha o de número 50, o primeiro à esquerda da segunda linha o neurônio 51, e assim sucessivamente, até o último neurônio à direita da última linha sendo identificado como o neurônio 2.500.

Nos mapas obtidos neste estudo pelas redes SOM, os neurônios vencedores que correspondem à região de ativação de cada país em seu respectivo *cluster* serão representados por neurônios pintados de preto. Contudo, deve-se salientar que a interpretação dos resultados obtidos em cada mapa topológico é muitas vezes dificultosa, e

esta ressalva é válida a partir do momento em que o aspecto relevante nesta etapa é a visualização obtida em cada *cluster* obtido por ART-2.

FIGURA 8: Exemplo de mapa topológico utilizado no estudo.

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47	48	49	50
51	52	53	54	55	56	57	58	59	60	61	62	63	64	65	66	67	68	69	70	71	72	73	74	75	76	77	78	79	80	81	82	83	84	85	86	87	88	89	90	91	92	93	94	95	96	97	98	99	100
101	102	103	104	105	106	107	108	109	110	111	112	113	114	115	116	117	118	119	120	121	122	123	124	125	126	127	128	129	130	131	132	133	134	135	136	137	138	139	140	141	142	143	144	145	146	147	148	149	150
151	152	153	154	155	156	157	158	159	160	161	162	163	164	165	166	167	168	169	170	171	172	173	174	175	176	177	178	179	180	181	182	183	184	185	186	187	188	189	190	191	192	193	194	195	196	197	198	199	200
201	202	203	204	205	206	207	208	209	210	211	212	213	214	215	216	217	218	219	220	221	222	223	224	225	226	227	228	229	230	231	232	233	234	235	236	237	238	239	240	241	242	243	244	245	246	247	248	249	250
251	252	253	254	255	256	257	258	259	260	261	262	263	264	265	266	267	268	269	270	271	272	273	274	275	276	277	278	279	280	281	282	283	284	285	286	287	288	289	290	291	292	293	294	295	296	297	298	299	300
301	302	303	304	305	306	307	308	309	310	311	312	313	314	315	316	317	318	319	320	321	322	323	324	325	326	327	328	329	330	331	332	333	334	335	336	337	338	339	340	341	342	343	344	345	346	347	348	349	350
351	352	353	354	355	356	357	358	359	360	361	362	363	364	365	366	367	368	369	370	371	372	373	374	375	376	377	378	379	380	381	382	383	384	385	386	387	388	389	390	391	392	393	394	395	396	397	398	399	400
401	402	403	404	405	406	407	408	409	410	411	412	413	414	415	416	417	418	419	420	421	422	423	424	425	426	427	428	429	430	431	432	433	434	435	436	437	438	439	440	441	442	443	444	445	446	447	448	449	450
451	452	453	454	455	456	457	458	459	460	461	462	463	464	465	466	467	468	469	470	471	472	473	474	475	476	477	478	479	480	481	482	483	484	485	486	487	488	489	490	491	492	493	494	495	496	497	498	499	500
501	502	503	504	505	506	507	508	509	510	511	512	513	514	515	516	517	518	519	520	521	522	523	524	525	526	527	528	529	530	531	532	533	534	535	536	537	538	539	540	541	542	543	544	545	546	547	548	549	550
551	552	553	554	555	556	557	558	559	560	561	562	563	564	565	566	567	568	569	570	571	572	573	574	575	576	577	578	579	580	581	582	583	584	585	586	587	588	589	590	591	592	593	594	595	596	597	598	599	600
601	602	603	604	605	606	607	608	609	610	611	612	613	614	615	616	617	618	619	620	621	622	623	624	625	626	627	628	629	630	631	632	633	634	635	636	637	638	639	640	641	642	643	644	645	646	647	648	649	650
651	652	653	654	655	656	657	658	659	660	661	662	663	664	665	666	667	668	669	670	671	672	673	674	675	676	677	678	679	680	681	682	683	684	685	686	687	688	689	690	691	692	693	694	695	696	697	698	699	700
701	702	703	704	705	706	707	708	709	710	711	712	713	714	715	716	717	718	719	720	721	722	723	724	725	726	727	728	729	730	731	732	733	734	735	736	737	738	739	740	741	742	743	744	745	746	747	748	749	750
751	752	753	754	755	756	757	758	759	760	761	762	763	764	765	766	767	768	769	770	771	772	773	774	775	776	777	778	779	780	781	782	783	784	785	786	787	788	789	790	791	792	793	794	795	796	797	798	799	800
801	802	803	804	805	806	807	808	809	810	811	812	813	814	815	816	817	818	819	820	821	822	823	824	825	826	827	828	829	830	831	832	833	834	835	836	837	838	839	840	841	842	843	844	845	846	847	848	849	850
851	852	853	854	855	856	857	858	859	860	861	862	863	864	865	866	867	868	869	870	871	872	873	874	875	876	877	878	879	880	881	882	883	884	885	886	887	888	889	890	891	892	893	894	895	896	897	898	899	900
901	902	903	904	905	906	907	908	909	910	911	912	913	914	915	916	917	918	919	920	921	922	923	924	925	926	927	928	929	930	931	932	933	934	935	936	937	938	939	940	941	942	943	944	945	946	947	948	949	950
951	952	953	954	955	956	957	958	959	960	961	962	963	964	965	966	967	968	969	970	971	972	973	974	975	976	977	978	979	980	981	982	983	984	985	986	987	988	989	990	991	992	993	994	995	996	997	998	999	1000

São mostradas abaixo as redes SOM nas quais os *clusters* compostos por mais de um elemento são apresentados. A nomenclatura adotada a partir deste ponto para cada mapa se resume em quatro ou cinco caracteres, sendo os dois primeiros indicando o parâmetro de vigilância e seu algoritmo significativo, e os dois ou três últimos indicando a numeração do *cluster*.

TABELA 13: Neurônios vencedores para cada país nos *clusters* ρ_{4c2} , ρ_{7c2} e ρ_{9c2} .

País	Neurônio Vencedor
Austrália	2319
Holanda	1219
Hong Kong	1951
Nova Zelândia	1965

Nota-se que neste *cluster* se encontram países que apresentam desempenho do balanço da conta corrente e das transferências correntes líquidas relativamente similares, mas não ao ponto de apresentarem uma grande proximidade na ativação neuronal. Assim, mesmo sendo classificados em uma mesma categoria, suas diferenças dentro do *cluster* são evidenciadas devido à pouca proximidade entre os neurônios vencedores representativos de cada país. Nota-se inclusive que nos casos específicos de Hong Kong (neurônio vencedor 1951) e da Holanda (neurônio vencedor 1219) os mesmos se encontram relativamente distantes visualmente de Austrália e Nova Zelândia, indicando maior grau de semelhança entre os si.

TABELA 14: Neurônios vencedores para cada país nos *clusters* p4c3, p7c3 e p9c3.

País	Neurônio Vencedor
Alemanha	944
Áustria	86
Bélgica	33
Canadá	334
Finlândia	282
França	466
Itália	214
Japão	312
Reino Unido	81

Este cluster apresenta países que indicam taxas bastante próximas para a variação de preços ao consumidor para o ano estudado, bem como similaridades importantes nas reservas incluindo ouro. Contudo, na análise dos neurônios vencedores notamos três áreas de ativação distintas: uma composta apenas pela Alemanha, outra composta por Reino Unido, Bélgica, Finlândia, Áustria e Canadá, e uma terceira, reunindo Japão, Itália e França. Assim, nota-se que dentro desta mesma categoria existem três grupos de países devido à análise dos neurônios vencedores.

TABELA 15: Neurônios vencedores para cada país no *cluster* ρ_4c_4 .

País	Neurônio Vencedor
África do Sul	1682
Albânia	2474
Angola	1921
Arábia Saudita	2074
Argélia	2170
Argentina	1739
Armênia	2185
Azerbaijão	2085
Bahrein	1770
Bangladesh	2038
Belize	2077
Benin	2182
Bielo-Rússia	2076
Bolívia	1783
Botswana	2125
Brasil	1589
Bulgária	1728
Burkina Faso	2333
Burundi	2379
Butão	2225
Cabo Verde	1980
Camarões	2279
Camboja	2281
Casaquistão	1986
Chile	1581
China	1684
Colômbia	1887
Comoros	2183
Costa do Marfim	2129
Costa Rica	2028
Cuba	2241
Dinamarca	1990
Djibouti	1982
Dominica	1984
Egito	1988
El Salvador	1937
Equador	1884
Eritréia	1981
Eslováquia	1977
Eslovênia	2026
Espanha	1891
Estônia	1780
Etiópia	2331

Fiji	1983
Filipinas	1882
Gabão	2122
Gâmbia	2083
Gana	2181
Geórgia	2284
Grécia	2091
Guatemala	2085
Guiana	1974
Guiné Equatorial	2038
Guiné-Bissau	2381
Haiti	2135
Honduras	2079
Hungria	1433
Iêmen	1680
Ilhas Maurícios	1882
Ilhas Salomão	2490
Ilhas Virgens	2177
Índia	1692
Indonésia	1686
Irã	2341
Irlanda	1889
Islândia	2193
Israel	1525
Jamaica	1928
Jordânia	1928
Kirjistão	2279
Kuwait	1775
Laos	2281
Lesoto	1828
Letônia	1780
Líbano	1980
Lituânia	1781
Macedônia	1979
Madagascar	2181
Malásia	1880
Malawi	2183
Maldivas	2286
Mali	2279
Malta	1874
Marrocos	1785
Mauritânia	2130
México	1586
Mianmar	2485
Moçambique	2179
Moldova	2325
Mongólia	2277
Namíbia	1976
Nepal	2377

Niger	2183
Nigéria	2177
Noruega	1990
Papua Nova Guiné	2223
Paquistão	1783
Paraguai	2037
Peru	1531
Polônia	1675
Portugal	2139
Quênia	2083
Rep. Congo	2019
Rep. Coréia	1628
Rep. Dem. Congo	2481
República Centro-Africana	2476
República Dominicana	1985
República Tcheca	1623
Romênia	2372
Rússia	1686
Rwanda	2284
Samoa	2388
São Tomé e Príncipe	2081
Senegal	1985
Serra Leoa	2479
Seychelles	1976
Singapura	1485
Síria	2137
Sri Lanka	1782
Suazilândia	1876
Sudão	2238
Suécia	2386
Suíça	1992
Tailândia	1529
Tanzânia	2486
Tchad	2233
Togo	2231
Tonga	2488
Trinidad e Tobago	1885
Tunísia	2028
Turquia	1787
Ucrânia	2320
Uganda	2282
Uruguai	1583
Uzbequistão	2384
Vanuatu	2483
Venezuela	1430
Vietnã	2177
Zâmbia	1885
Zimbabwe	1934

Neste *cluster* se encontram praticamente todos os países que se diferenciam pelos mais diversos motivos, daqueles que foram classificados como distintos pela Fase 1, ou seja, este *cluster* seria um *default* em que a Fase 1 agrupa todos os países que não apresentam discrepâncias importantes, dado um padrão de vigilância. Porém, é evidente na análise dos neurônios vencedores que trata-se de uma classificação relativamente regular. Todos os neurônios ativados no mapa topológico acima estão concentrados em uma mesma área, o que demonstra que, considerando-se um grau de diferenciação relativamente baixo, este cluster é bastante equilibrado em relação à sua constituição visual.

FIGURA 12: Regiões de ativação neural do *cluster p7c5*.




TABELA 16: Neurônios vencedores para cada país no *cluster* $\rho7c5$.

País	Neurônio Vencedor
África do Sul	1682
Albânia	2474
Angola	1921
Arábia Saudita	2074
Argélia	2170
Argentina	1739
Armênia	2185
Azerbaijão	2085
Bahrein	1770
Bangladesh	2038
Belize	2077
Benin	2182
Bielo-Rússia	2076
Bolívia	1783
Botswana	2125
Brasil	1589
Bulgária	1728
Burkina Faso	2333
Burundi	2379
Butão	2225
Cabo Verde	1980
Camarões	2279
Camboja	2281
Casaquistão	1986
Chile	1581
China	1684
Colômbia	1887
Comoros	2183
Costa do Marfim	2129
Costa Rica	2028
Dinamarca	1990
Djibouti	1982
Dominica	1984
Egito	1988
El Salvador	1937
Equador	1884
Eritrêia	1981
Eslováquia	1977
Eslovênia	2026
Espanha	1891
Estônia	1780
Etiópia	2331
Fiji	1983
Filipinas	1882

Gabão	2122
Gâmbia	2083
Gana	2181
Geórgia	2284
Grécia	2091
Guatemala	2085
Guiana	1974
Guiné Equatorial	2038
Guiné-Bissau	2381
Haiti	2135
Honduras	2079
Hungria	1433
Iêmen	1680
Ilhas Maurícios	1882
Ilhas Salomão	2490
Ilhas Virgens	2177
Índia	1692
Indonésia	1686
Irã	2341
Irlanda	1889
Islândia	2193
Israel	1525
Jamaica	1928
Jordânia	1928
Kirjistão	2279
Kuwait	1775
Laos	2281
Lesoto	1828
Letônia	1780
Líbano	1980
Lituânia	1781
Macedônia	1979
Madagascar	2181
Malásia	1880
Malawi	2183
Maldivas	2286
Mali	2279
Malta	1874
Marrocos	1785
Mauritânia	2130
México	1586
Mianmar	2485
Moçambique	2179
Moldova	2325
Mongólia	2277
Namíbia	1976
Nepal	2377
Niger	2183
Nigéria	2177

Noruega	1990
Papua Nova Guiné	2223
Paquistão	1783
Paraguai	2037
Peru	1531
Polônia	1675
Portugal	2139
Quênia	2083
Rep. Congo	2019
Rep. Coréia	1628
Rep. Dem. Congo	2481
República Centro-Africana	2476
República Dominicana	1985
República Tcheca	1623
Romênia	2372
Rússia	1686
Rwanda	2284
Samoa	2388
São Tomé e Príncipe	2081
Senegal	1985
Serra Leoa	2479
Seychelles	1976
Singapura	1485
Síria	2137
Sri Lanka	1782
Suazilândia	1876
Sudão	2238
Suécia	2386
Suíça	1992
Tailândia	1529
Tanzânia	2486
Tchad	2233
Togo	2231
Tonga	2488
Trinidad e Tobago	1885
Tunísia	2028
Turquia	1787
Ucrânia	2320
Uganda	2282
Uruguai	1583
Uzbequistão	2384
Vanuatu	2483
Venezuela	1430
Vietnã	2177
Zâmbia	1885
Zimbabwe	1934

Esta Tabela se diferencia da Tabela 11 apenas pela exclusão de Cuba dentre seus elementos, sendo assim a classificação *default* da Fase 1 para $\rho = 0,7$. Contudo, a uniformização também é bastante grande dentre os neurônios vencedores. Este resultado aponta para uma detecção relativamente intuitiva de que a grande parte dos países do mundo, considerada sob um grau de exigência de diferenciação médio, possui a maior parte de suas características macroeconômicas relativamente parecidas, ou pelo menos suas diferenças neste aspecto não são particularmente relevantes. Porém, retornando à análise visual do mapa, também pode ser notado que o grau de conformidade não é tão grande quanto no *cluster* ρ_{4c4} , assegurando que a rede SOM considera relevante o valor adotado pelo parâmetro ρ na rede ART-2 da Fase 1.

TABELA 17: Neurônios vencedores para cada país no *cluster* ρ_9c6 .

País	Neurônio Vencedor
Cabo Verde	1610
Chile	1666
Comoros	1608
Dinamarca	672
Fiji	1360
Geórgia	1711
Grécia	581
Ilhas Maurícios	1564
Ilhas Salomão	834
Ilhas Virgens	1612
Indonésia	1518
Maldivas	874
Malta	1509
Moldova	1464
Noruega	675
Papua Nova Guiné	1363
Samoa	830
São Tomé e Príncipe	1466
Suécia	977
Suíça	525
Tanzânia	778
Tonga	930
Trinidad e Tobago	1512
Vanuatu	877

Esta é a Tabela *default* para $\rho = 0,9$. A diversidade ainda é grande, com países das mais diversas regiões do mundo. Contudo, de uma maneira geral, são países que apresentam bom desempenho global nos dados referentes especialmente às exportações, quando se analisa individualmente as semelhanças entre seus dados. Também, notamos a polarização das regiões de ativação, sendo a mais personalizada a região mais à esquerda, onde há uma predominância dos países do Pacífico Sul. Os demais países deste *cluster* se situam na região mais à direita na qual ocorrem diversos neurônios vencedores.

TABELA 18: Neurônios vencedores para cada país no *cluster* ρ_{9c7} .

País	Neurônio Vencedor
Albânia	2246
Bielo-Rússia	2298
Bulgária	2146
Eslováquia	2400
Eslovênia	2398
Estônia	2500
Hungria	2200
Letônia	2497
Lituânia	2497
Macedônia	2198
Polônia	2049
República Tcheca	2300
Romênia	2493
Rússia	2495
Ucrânia	2345

Este *cluster* agrupa de maneira bem interessante os países da antiga “Cortina de Ferro”, que também apresentam similaridades visíveis de seus dados relacionados a consumo privado e governamental, quando suas entradas são revisitadas pelo analista. Visualmente, no mapa topológico, os neurônios vencedores também se encontram bastante próximos, o que indica uma boa uniformização do *cluster*, sendo particularmente este resultado bastante interessante, especialmente lembrando-se que trata-se de um resultado recorrente mas obtido de maneira experimental.

FIGURA 15: Regiões de ativação neural do cluster ρ_9c8 .

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47	48	49	50
51	52	53	54	55	56	57	58	59	60	61	62	63	64	65	66	67	68	69	70	71	72	73	74	75	76	77	78	79	80	81	82	83	84	85	86	87	88	89	90	91	92	93	94	95	96	97	98	99	100

TABELA 19: Neurônios vencedores para cada país no *cluster* $\rho 9c8$.

País	Neurônio Vencedor
Belize	396
Bolívia	192
Brasil	50
Colômbia	398
Costa Rica	493
Dominica	296
El Salvador	594
Equador	398
Filipinas	498
Guatemala	590
Guiana	196
Honduras	298
Jamaica	47
Líbano	344
Malásia	600
México	150
Mianmar	596
Paraguai	342
Peru	496
República Dominicana	598
Sri Lanka	500
Tailândia	148
Uruguai	400
Venezuela	300

Este cluster agrupa principalmente os países em desenvolvimento da América Latina e Ásia, com a notável inclusão do Líbano. São, deste modo, países que apresentam similaridades em praticamente todos os dados apresentados, como pode ser verificado na análise do mapa topológico obtido, o qual lembra bastante o resultado apresentado em $\rho 9c7$, diferindo-se apenas na região ativada do mapa topológico.

TABELA 20: Neurônios vencedores para cada país no *cluster* ρ_9c9 .

País	Neurônio Vencedor
Argélia	1521
Armênia	1473
Azerbaijão	1373
Bangladesh	1273
Butão	1275
Camboja	1019
Cazaquistão	1372
Egito	1172
Índia	1126
Jordânia	1368
Kirjistão	1120
Laos	973
Marrocos	1468
Mongólia	1168
Nepal	1377
Paquistão	1278
Síria	1269
Tunísia	1420
Turquia	1124
Uzbequistão	1425
Vietnã	1271

Este *cluster* inclui antigos países que compunham a extinta União Soviética, países mais pobres da Ásia e da África Mediterrânea, e também os europeus Turquia e Armênia. Uma grande característica comum a todos é o nível alto das importações no período estudado. O mapa topológico também retorna uma região de ativação regular, licalizada na região central da estrutura.

TABELA 21: Neurônios vencedores para cada país no *cluster* ρ_9c10 .

País	Neurônio Vencedor
Angola	2257
Botswana	2460
Burkina Faso	2402
Burundi	2201
Camarões	2203
Costa do Marfim	2205
Djibouti	2454
Eritréia	2454
Etiópia	2301
Gabão	2305
Gâmbia	2303
Gana	2103
Guiné Equatorial	2203
Guiné-Bissau	1906
Haiti	2451
Lesoto	2406
Madagascar	2005
Malawi	2353
Mali	2301
Mauritânia	1852
Moçambique	2007
Namíbia	2359
Niger	2402
Nigéria	2159
Quênia	2103
Rep. Congo	2259
Rep. Dem. Congo	2101
República Centro-Africana	2201
Rwanda	2401
Senegal	1904
Serra Leoa	2001
Seychelles	2362
Suazilândia	2458
Sudão	2105
Tchad	2451
Togo	2353
Uganda	2351
Zâmbia	1804
Zimbabwe	2003

Este padrão obtido no sistema se refere a uma classe exclusivamente africana, sem uma diferenciação clara entre a África do Norte e a África Sub-Saariana. O mapa visual apresenta uma padronização extremamente uniforme, com vários países apresentando o mesmo neurônio vencedor, indicando grandes semelhanças entre os dados macroeconômicos dos mesmos de acordo com a rede SOM. Realizando-se uma comparação entre esta classe e as Tabelas de Renda *Per Capita* constantes mais acima neste Capítulo, podemos perceber que os fatores geográfico e geoposicional parecem ser mais influentes na constituição desta categoria do que a própria renda *per capita*, tendo em vista que alguns países da África Mediterrânea que constam como possuidores de renda *per capita* maiores que os países mais ao sul foram classificados juntos.

TABELA 22: Neurônios vencedores para cada país no *cluster* ρ_9c11 .

País	Neurônio Vencedor
África do Sul	1015
Argentina	1217
Espanha	1143
Irlanda	1146
Islândia	1445
Israel	916
Portugal	1294
Rep. Coréia	1019
Singapura	1862

O *cluster* acima junta países emergentes em estágio avançado, de uma maneira geral, muito embora sua padronização visual seja fragmentada, com Singapura apresentando um distanciamento relativamente grande dos outros dois grupos, compostos respectivamente por Israel, África do Sul, República da Coréia e Argentina mais à esquerda, e Portugal, Espanha, Irlanda e Islândia mais à direita. Contudo, para o ano de 1997 (data-base dos dados utilizados), os países desta classe gozavam de situação macroeconômica relativamente estável, com vários indicadores em situação de equilíbrio, como por exemplo os seus dados econômicos estruturais (área de concentração 3), indicadores monetários (área de concentração 5) e finanças governamentais (área de concentração 6).

TABELA 23: Neurônios vencedores para cada país no *cluster* ρ_9c12 .

País	Neurônio Vencedor
Arábia Saudita	443
Bahrein	1058
Benin	2119
Iêmen	1969
Irã	1536
Kuwait	290

Esta classe é composta por países do Oriente Médio grandes produtores de petróleo mais a República do Benin, localizada na África Ocidental e com economia voltada para a agricultura. À exceção do país africano, cujo neurônio vencedor se encontra próximo ao do Iêmen, não se pode afirmar, devido a uma relativa disparidade entre as variáveis, que este *cluster* forma uma categoria relativamente uniforme, à exceção dos dados de exportação relativamente similares em relação ao Produto Interno Bruto. Ainda no tocante à análise visual do mapa, o Bahrein tem seu neurônio vencedor relativamente isolado, assim como o Irã, e a região mais acima e à direita apresenta atividade nos neurônios correspondentes à Arábia Saudita e ao Kuwait.

5.4. Fase 4

Nesta fase procura-se interpretar cada *cluster* obtido, através de uma análise qualitativa baseada na análise dos mesmos, bem como de seus mapas topológicos, procurando em certas convergências de acordo com a classificação baseada na renda *per capita* sugerida pelo *World Bank*.

Em primeiro lugar, destacamos o caso altamente específico dos Estados Unidos, e depois os casos de Cuba e China. O primeiro, mesmo sob uma relativamente pequena taxa de vigilância dos padrões, que admite maior diversidade em cada categoria, sempre foi classificado separadamente dos outros países. A principal razão notada quando analisamos os dados é a magnitude dos seus dados reais: para qualquer das oito áreas de concentração dos dados macroeconômicos empregados, o módulo dos mesmos é sempre bastante elevado em comparação com todos os outros. O caso cubano é exatamente o oposto: muito embora tenha sido necessário o emprego de uma maior diferenciação entre os *clusters* para que Cuba fosse considerado distinto dos demais, o módulo dos dados reais cubanos é extremamente baixo. Finalmente, a China parece compor um caso à parte quando analisamos algumas das suas razões primárias em função do PIB, especialmente relacionadas a investimento e exportações, os quais apresentam um percentual elevado, indicando uma forte orientação política no sentido da expansão.

A categoria 3 obtida em quaisquer dos parâmetros de vigilância das redes ART mostra um grupo de países que, mesmo sem uma grande proximidade entre os seus neurônios vencedores, mostram desempenho de suas contas relativas ao comércio internacional e ao balanço de pagamentos com desempenhos relativamente semelhantes em magnitude.

A categoria 4 apresenta países de renda elevada, mesmo não havendo a disponibilidade destes dados às redes treinadas. Assim, supõe-se que os outros dados incluídos como entradas às redes ART indicam um padrão macroeconômico que responde de maneira semelhante, mesmo na ausência da variável mais importante.

Nas classes 6, 7, 8, 9 e 10, compostas respectivamente por países da antiga Europa comunista, da América Latina e Caribe, do Norte da África e Sul da Ásia, África Sub-Saariana, e por países de alto volume percentual de exportações, notamos também a clara convergência geopolítica em relação à sua própria composição, sendo que não existem dados relacionados a tal característica que possam sugerir esta classificação às redes ART-2. Esta é uma constatação que indica que os dados macroeconômicos apontam, no caso do estudo *cross-sectional* realizado, uma situação histórica momentânea que pode ter sido determinada por fatos ocorridos no passado, que exercem grande influência nas contas nacionais dos países no tocante ao estudo do período em que os dados foram empregados, ou mesmo por razões outras que não podem ser detectadas apenas com a análise destes dados fornecidos à rede. Podemos ressaltar, neste sentido, a existência do *cluster* 11, composto por países recentemente considerados de renda média ou média-alta pelo World Bank, e do *cluster* 12, que não aparenta nesta análise nenhuma semelhança à luz da análise dos dados fornecidos à rede, o que pode indicar a existência de relacionamentos não compreendidos.

5.5. Análise dos resultados obtidos

A viabilidade de uso das redes neurais em classificação de dados é uma realidade comprovada pelos mais diversos empregos que a técnica se prestou, especialmente na última década. Especificamente no caso de dados macroeconômicos, as redes neurais auto-organizadas se mostraram ferramentas que proporcionam ao usuário uma comparação intuitiva bastante interessante, notadamente na obtenção de estruturas visuais, que indicam tanto uma categorização

relativa aos grupos distintos que compõem cada *cluster* quanto um posicionamento dos elementos dentro de um mesmo grupo. Porém, mostra-se necessário, face à conformidade relativamente difusa que caracteriza alguns *clusters*, a adição de dados que permitam uma melhor definição dos critérios adotados pelo próprio sistema, notadamente na Fase 1 do sistema proposto.

Contudo, o resultado mais importante deste estudo não é plenamente visualizável em seus mapas topológicos: as classificações obtidas aparentam na maior parte dos casos um padrão que se relaciona a dados de renda *per capita* e geopolíticos, os quais não constam de forma alguma em nenhuma entrada disponível em quaisquer das Fases que compuseram o sistema. Tal resultado é bastante similar ao obtido no estudo realizado por KASKI & KOHONEN, em 1996, utilizando-se os dados contidos no *World Bank Development Report* do ano de 1992, incluindo também indicadores sócio-econômicos.

6 CONSIDERAÇÕES FINAIS

O uso de técnicas de classificação neural auto-organizadas em uma base de dados macroeconômica confiável se mostrou uma alternativa plausível, com tempo de execução relativamente baixo e com perspectivas promissoras. Os *clusters* obtidos neste estudo se revelaram razoáveis em comparação com estudos realizados com o emprego de técnicas tradicionais, baseadas na análise da renda *per capita* e do produto agregado, utilizadas pelo *World Bank*, tendo em vista que a composição dos mesmos apresenta coerência compatível com os resultados apresentados por estas técnicas. A visualização destes *clusters* proporcionada pela Fase 3 se mostrou interessante do ponto de vista da disponibilidade da ilustração de suas estruturas, o que torna seu exame uma tarefa mais objetiva. Contribuem nestes pontos positivos, especialmente no caso das redes SOM, a especificação matemática da aproximação vetorial contida em seu algoritmo de treinamento, e especialmente no caso das redes ART, a sua arquitetura adequada a um bom manejo do Problema da Dimensionalidade e da impossibilidade da geração de falsos padrões, casos estes iminentes em bases de dados complexas e correlacionadas.

Seguramente o ponto de discussão mais intensa acerca dos resultados obtidos gira em torno da própria adoção de uma metodologia de processamento do tipo caixa-preta, em que não há uma modelagem que dê sustentação à classificação obtida: apenas confia-se nas saídas proporcionadas pela rede neural. Contudo, isso pode ser também apreciado sob uma ótica favorável, na qual o mais importante atributo da realização de uma tarefa qualquer seria a obtenção do melhor desempenho possível, independentemente de qual a metodologia adotada. Observa-se na prática,

com referência a uma vastíssima bibliografia na área computacional, que a utilização de modelos neurais no controle e monitoramento de sistemas complexos geralmente apresenta resultados mais positivos do que aqueles obtidos por técnicas matemáticas tradicionais, tanto em relação a uma maior eficácia na realização das tarefas, quanto no menor dispêndio computacional e na necessidade de grande especialização do operador, redundando em uma crescente utilização desta metodologia em problemas computacionais e de engenharia.

Outro ponto que deve ser destacado diz respeito à natureza das variáveis utilizadas: algumas variáveis são nominais (expressas em valor monetário corrente) e outras variáveis são reais (expressas levando-se em conta a variação de outras grandezas econômicas, como índices de preços). Todavia, este é um problema inerente à elaboração das Contas Nacionais, e a proposição de fórmulas para sua solução é uma tarefa que foge do escopo deste trabalho.

Uma terceira discussão em torno dos resultados obtidos seria originária da primeira limitação ressaltada acima: a dificuldade operacional em interpretar os resultados obtidos pela rede SOM mais positivamente. A análise realizada apresenta determinadas dificuldades à medida em que devem existir inter-relacionamentos não capturados face ao conhecimento econômico atual. Contudo, deve-se compreender os resultados obtidos como um indicador de que existe uma diferenciação entre as categorias obtidas, muitas delas inclusive de maneira bastante clara segundo os mapas topológicos obtidos.

Abaixo estão apresentadas algumas sugestões para a continuidade de pesquisas na área, tendo em vista que vários aspectos pertinentes não são abordados pelo presente trabalho:

- Comparar diretamente a utilização de sistemas de classificação neural com as técnicas mais comuns mencionadas no corpo do texto, através da apreciação de suas potencialidades e inadequações intrínsecas;
- Realizar estudos semelhantes baseados na evolução temporal destes dados em uma série de tempo, com a geração de vários *clusters* relativos aos diversos anos considerados e a consequente comparação das mudanças ocorridas *intracluster* e *intercluster*, como, por exemplo, a migração entre *clusters* e a consequente evolução de cada um dos *clusters* obtidos;
- Utilização de arquiteturas capazes de realizar processamento de dados difusos (lógica *fuzzy*), como por exemplo *Fuzzy ARTMAP*, o que permitiria a geração de categorias superpostas, e uma posterior comparação dos resultados com a metodologia aqui empregada;
- Analisar a sobreposição entre os *clusters* em relação às suas similaridades, considerando assim alguns componentes como não completamente aderentes a uma categoria específica;
- Outras aplicações de interesse nas áreas relativas à Economia e Finanças, especialmente relacionadas ao estudo de risco e composição de carteiras de ativos (*portfolio*), tendo em vista a capacidade de identificação de relacionamentos *a posteriori* observada no sistema proposto neste estudo.

Além destas possibilidades, sem dúvida o emprego de um sistema semelhante pode efetuar classificações de dados relativos aos estudos de Humanidades em uma vasta gama de aplicações, como planejamento urbano e regional, planejamento cooperativo, organização industrial e economia de empresas, análise de concorrência, estudos em Contabilidade Social e Desenvolvimento Econômico, pesquisas e análises sociais e demográficas, e muitas outras.

REFERÊNCIAS BIBLIOGRÁFICAS

BARTFAI, G. (1994). *Hierarchical Clustering with ART Neural Networks*. . In: THE IEEE INTERNATIONAL CONFERENCE ON NEURAL NETWORKS, Orlando, EUA, 1994. *Annals*. Orlando, v.II, p.940-944.

BEER, S. (1979). *Cibernética na administração: visão totalmente original de como organizar e administrar desde uma pequena empresa até um país*. São Paulo, Ibrasa.

BISHOP, C.M. (1995). *Neural networks for pattern recognition*. Birmingham, Oxford University Press.

BOX, G.E.P.; JENKINS, G.M. (1976). *Time series analysis, forecasting and control*. San Francisco, Holden Day.

BRAGA, A.P.; LUDERMIR, T.B.; CARVALHO, A.C.P.L.F. (2000). *Redes neurais artificiais: teoria e aplicações*. Rio de Janeiro, Livro Técnico e Científico.

CARPENTER, G.A.; GROSSBERG, S. (1987). A massively parallel architecture for a self-organizing neural pattern recognition machine. *Computer Vision, Graphics and Image Processing*, v.37, p.54-115.

CARPENTER, G.A.; GROSSBERG, S. (1987). ART-2: self-organization of a stable category recognition codes for analog input patterns. *Applied Optics*, v.26, n.23, p.4919-4930, Dec.

CHESTER, D.L. (1990). Why two hidden layers are better than one. *International Joint Conference on Neural Networks*, v.1, p.265-268.

COATES, J.F. (2000). Scenario planning. *Technological Forecasting and Social Change*, v.5, p.115-123.

CYBENKO, G. (1988). *Continuous valued neural networks with two hidden layers are sufficient*. Medford, Department of Computer Science/Tufts University (Technical Report).

DEBOECK, G.; KOHONEN, T. (2000). *Visual explorations in finance with self-organizing maps*. London, Springer-Verlag.

DURATEX S.A. (1985). *A abordagem sistêmica das organizações*. São Paulo./Relatório técnico Divisão de Treinamento/

ENGLE, R. (2001). The use of ARCH/GARCH models in applied econometrics. *Journal of Economic Perspectives*, v.15, n.4, p.157-168.

ENGLISCH, H.; HIEMSTRA, Y. (1994). The correlation as cost function in neural networks. In: THE IEEE INTERNATIONAL CONFERENCE ON NEURAL NETWORKS, Orlando, EUA, 1994. *Annals*. Orlando, v.V, p.3170-3172.

FAUSETT, L. (1994). *Fundamentals of neural networks: architectures, algorithms, and applications*. Englewood Cliffs, Prentice Hall.

GAUSEMEIER, J.; FINK, A.; SCHLAKE, O. (1998). Scenario management: an approach to develop future potentials. *Technological Forecasting and Social Change*, v.59, p.111-130.

GODET, M. (1987). *Scenarios and strategic planning*. London, Butterworth.

GODET, M.; ROUBELAT, F. (1996). Creating the future: the use and misuse of scenarios. *Long Range Planning*, v.29, n.2, p.164-171.

HAYKIN, S. (1994). *Neural networks: a comprehensive foundation*. Hamilton, Prentice-Hall.

HEILEMAN, G.L.; GEORGIPOULOS, M.; HWANG, J. (1994). A survey of learning results for ART1 networks. In: THE IEEE INTERNATIONAL CONFERENCE ON NEURAL NETWORKS, Orlando, EUA, 1994. *Annals*. Orlando, v.II, p.1222-1225.

JOHNSON, R.A.; WICHERN, D.W. (1992). *Applied multivariate statistical analysis*. Upper Saddle River, Prentice-Hall.

KANE, R.; MILGRAM, M. (1994). Financial forecasting and rules extraction from trained networks.:In: THE IEEE INTERNATIONAL CONFERENCE ON NEURAL NETWORKS, Orlando, EUA, 1994. *Annals*. Orlando, v.V, p.3190-3195.

KASKI, S.; KOHONEN, T. (1996). *Exploratory data analysis by the self-organizing map: structures of welfare and poverty in the world*. Helsinki, Neural Networks Research Centre/Helsinki University of Technology (Technical Report).

KIANG, M. (2001). Extending the Kohonen self-organizing map networks for clustering analysis. *Computational Statistics & Data Analysis*, v.38, p.161-180.

KOHONEN, T. (1989). *Self-organization and associative memory*. 3.ed. New York, Springer-Verlag.

LAUDON, K.C.; LAUDON, J.P. (1996). *Management information systems: organization and technology*. 4.ed. Upper Saddle River, Prentice-Hall.

MAHONEY, B. (1994). The limits of a computational model of human thinking. In: THE IEEE INTERNATIONAL CONFERENCE ON NEURAL NETWORKS, Orlando, EUA, 1994. *Annals*. Orlando, v.IV, p.2173.

MITRA, S. (1994). Fuzzy inferencing with ART networks. In: THE IEEE INTERNATIONAL CONFERENCE ON NEURAL NETWORKS, Orlando, EUA, 1994. *Annals*. Orlando, v.II, p.1230-1234.

PARK, Y. (1994). An ART2 trained by two-stage learning on circularly ordered data sequence. In: THE IEEE INTERNATIONAL CONFERENCE ON NEURAL NETWORKS, Orlando, EUA, 1994. *Annals*. Orlando, v.V, p.2928-2933.

RUMELHART, D.E.; HINTON, G.E.; WILLIAMS, R.J. (1986). Learning representations by back-propagation errors. *Nature*, v.323, p.533-536.

- SARLE, W.S. (2001). *Neural network FAQ*. <ftp.sas.com/pub/neural/FAQ.txt.zip>. (18 Sept).
- SERRANO-CINCA, C. (1996). Self organizing neural networks for financial diagnosis. *Decision Support Systems*, v.17, p.227-238.
- SMITH, K.A.; GUPTA, J.N.D. (2000). Neural networks in business: techniques and applications for the operations researcher. *Computers & Operations Research*, v.27, p.1023-1044.
- SPECHT, D.F.; ROMSDAHL, H. (1994). Experience with adaptive probabilistic neural networks and adaptive general regression neural networks. In: THE IEEE INTERNATIONAL CONFERENCE ON NEURAL NETWORKS, Orlando, EUA, 1994. *Annals*. Orlando, v.II, p.1203-1208.
- TAKAHASHI, H. et.al. (1994). The reliability of neural networks on pattern recognition. In: THE IEEE INTERNATIONAL CONFERENCE ON NEURAL NETWORKS, Orlando, EUA, 1994. *Annals*. Orlando, v.V, p.3067-3070.
- TAURITZ, D.R. (2001). *The adaptive resonance (ART) clearinghouse*.
<http://www.wi.leidenuniv.nl/art/> (06 Feb).
- THE 1999 WORLD BANK DEVELOPMENT INDICATORS - Win*STARS version 4.2. (CD-ROM). Washington, 1999.
- TSAI, W.Y.; TAI, H.M.; REYNOLDS, A.C. (1994). An ART2-BP neural net and its application to reservoir engineering. In: THE IEEE INTERNATIONAL CONFERENCE ON NEURAL NETWORKS, Orlando, EUA, 1994. *Annals*. Orlando, v.V, p.3289-3294.

TURBAN, E.; ARONSON, J.E. (2001). *Decision support systems and intelligent systems*. 6.ed. Upper Saddle River, Prentice-Hall.

VARIAN, H.R. (1994). *Microeconomia*: princípios básicos. Trad. por Luciane Melo. Rio de Janeiro, Campus.

VELLIDO, A.; LISBOA, P.J.G.; VAUGHAN, J. (1999). Neural networks in business: a survey of applications (1992-1998). *Expert Systems with Applications*, v.17, p.51-70.

VISHWAKARMA, K.P. (1994). A neural network to predict multiple economic time series. In: THE IEEE INTERNATIONAL CONFERENCE ON NEURAL NETWORKS, Orlando, EUA, 1994. *Annals*. Orlando, v.VI, p.3674-3679.

WEIERICH, P.; VON ROSENBERG, M. (1994). The use of formal measures for the training of hierarchical Kohonen maps. In: THE IEEE INTERNATIONAL CONFERENCE ON NEURAL NETWORKS, Orlando, EUA, 1994. *Annals*. Orlando, v.II, p.612-615.

WEST, D. (2000). Neural network credit scoring models. *Computers & Operations Research*, v.27, p.1131-1152.

WILLIAMS, T.M. (1999). The need for new paradigms for complex projects. *International Journal of Project Management*, v.17, n.5, p.269-273.

WOLLENBERG, E.; EDMUNDS, D.; BUCK, L. (2000). Using scenarios to make decisions about the future: anticipatory learning for the adaptive co-management of community forests. *Landscape and Urban Planning*, v.47, p.65-77.

WONG, B.K.; SELVI, Y. (1998). Neural network applications in finance: a review and analysis of literature (1990-1996). *Information & Management*, v.34, p.129-139.

WONG, B.K.; LAI, V.S.; LAM, J. (2000). A bibliography of neural network business applications research: 1994-1998. *Computers & Operations Research*, v.27, p.1045-1076.

ZHANG, G.; PATUWO, B.E.; HU, M.Y. (1998). Forecasting with artificial neural networks: the state of the art. *International Journal of Forecasting*, v.14, p.35-62.

ZELL, A. et al. (2001). *SNNS - Stuttgart Neural Networks Simulator user manual version 4.2*.
<http://www-ra.informatik.uni-tuebingen.de/downloads/SNNS/SNNSv4.2/Manual.pdf> (27 Aug).

OBRAS CONSULTADAS

ABELÉM, A.J.; PACHECO, M.A.; VELLASCO, M.M.B.R. (1995). Modelagem de redes neurais artificiais para previsão de séries temporais. In: II SIMPÓSIO BRASILEIRO DE REDES NEURAI, São Carlos, 1995. *Anais*. São Carlos, v.1, p.107-112.

AHN, B.S.; CHO, S.S.; KIM, C.Y. (2000). The integrated methodology of rough set theory and artificial neural network for business failure prediction. *Expert Systems With Applications*, v.18, p.65-74.

AMARI, S. (1990). Neural representation of information. In: I INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS, Washington, 1990. *Annals*. Washington, v.I, p.509-511.

BACK, B.; LAITINEN, T.; SERE, K. (1996). Neural networks and genetic algorithms for bankruptcy predictions. *Expert Systems With Applications*, v.11, n.4, p.407-413.

BALAKRISHNAN, S.N.; WEIL, R.D. (1996). Neurocontrol: a literature survey. *Mathematical and Computational Modelling*, v.23, n.1, p.101-117.

BALLINI, R.; VON ZUBEN, F.J. (2000). Application of neural networks to adaptive control of nonlinear systems. *Automatica*, v.36, p.1929-1933.

BALKIN, S.D.; ORD, J.K. (2000). Automatic neural network modeling for univariate time series. *International Journal of Forecasting*, v.16, p.509-515.

BARTFAI, G. (1995). *An ART-based modular architecture for learning hierarchical clusterings*. Wellington, Department of Computer Science/Victoria University of Wellington (Technical Report).

BARTFAI, G.; WHITE, R. (1996). *ART-based modular networks for incremental learning of hierarchical clusterings*. Wellington, Department of Computer Science/Victoria University of Wellington (Technical Report).

BARTFAI, G. (1998). *An adaptive resonance theory-based neural network capable of learning via representational redescription*. Budapest, Analogical and Neural Computing Systems Laboratory/Computer and Automation Research Institute/Hungarian Academy of Sciences (Technical Report).

BLANCO, A.; DELGADO, M.; PEGALAJAR, M.C. (2000). A genetic algorithm to obtain the optimal recurrent neural network. *International Journal of Approximate Reasoning*, v.23, p.67-83.

BJORNSON, C.; BARNEY, D.K. (1999). Identifying significant model inputs with neural networks – tax court determination of reasonable compensation. *Expert Systems With Applications*, v.17, p.13-19.

BODE, J. (1998). Decision support with neural networks in the management of research and development: concepts and application to cost estimation. *Information & Management*, v. 4, p.33-40.

CALLEN, J.L. et al. (1996). Neural network forecasting of quarterly accounting earnings. *International Journal of Forecasting*, v.12, p.475-482.

CHESTER, D.L. (1990). Why Two Hidden Layers Are Better Than One. In: I INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS, Washington, EUA, 1990. *Annals*. Washington, v.I, p.265-268.

CHIANG, W.C.; URBAN, T.L.; BALDRIDGE, G. W. (1996). A neural network approach to mutual fund net asset value forecasting. *Omega-The International Journal of Management Science*, v.24, n.2, p.205-215.

CHIEN, T.W. et al. (1999). A neural networks-based approach for strategic planning. *Information & Management*, v.35, p.357-364.

COTTIS, R.A. et al. (1999). Neural network methods for corrosion data reduction. *Materials and Design*, v.20, p.169-178.

COURRIEU, P. (2001). Two methods for encoding clusters. *Neural Networks*, v.14, p.175-183.

FANG, J.; XI, Y. (1997). Neural network design based on evolutionary programming. *Artificial Intelligence in Engineering*, v.11, p.155-161.

FUNAHASHI, K. (1998). Multilayer neural networks and Bayes decision theory. *Neural Networks*, v.11, p.209-213.

GRUCA, T.S.; KLEMZ, B.R. (1998). Using neural networks to identify competitive market structures from aggregate market response data. *Omega-The International Journal of Management Science*, v.26, n.1, p.49-62.

HEINEMANN, M. (2000). Adaptive learning of rational expectations using neural networks. *Journal of Economic Dynamics & Control*, v.24, p.1007-1026.

HORNE, B.G; HUSH, D.R. (1996). Bounds on the complexity of recurrent neural network implementations of finite state machines. *Neural Networks*, v.9, n.2, p.243-252.

HU, M.Y.; SHANKER, M.; HUNG, M.S. (1999). Estimation of posterior probabilities of consumer situational choices with neural network classifiers. *International Journal of Research in Marketing*, v.16, p.307-317.

INDRO, D. C. et al. (1999). Predicting mutual fund performance using artificial neural networks. *Omega-The International Journal of Management Science*, v.27, p.373-380.

ISHIBUCHI, H.; NII, M. (2000). Neural networks for soft decision making. *Fuzzy Sets and Systems*, v.115, p.121-140.

KAMGAR-PARSI, B.; GUALTIERI, J.A. (1990). Clustering taxonomic data with neural networks. In: I INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS, Washington, EUA, 1990. *Annals*. Washington, v.I, p.277-280.

KARAYANNIS, N.B.; VENETSANOPOULOS, A.N. (1995). On the training and performance of high-order neural networks. *Mathematical Biosciences*, v.68, p.129-143.

KASPARIAN, V.; BATUR, C. (1998). Model reference based neural network adaptive controller. *ISA Transactions*, v.37, p.21-39.

KLEIN, B.D.; ROSSIN, D.F. (1999). Data quality in neural network models: effect of error rate and magnitude of error on predictive accuracy. *Omega-The International Journal of Management Science*, v.27, p.569-582.

KUO, R. J.; XUE, K. C. (1999). Fuzzy neural networks with application to sales forecasting. *Fuzzy Sets and Systems*, v.108, p.123-143.

LANOUILLE, R.; THIBAUT, J.; VALADE, J.L. (1999). Process modeling with neural networks using small experimental datasets. *Computers & Chemical Engineering*, v.23, p.1167-1176.

LAXTON, R. (2000). The World Wide Web as a neural net – implications for market-driven web enabling. *Technological Forecasting and Social Change*, v.64, p.55-70.

LEE, K.C.; HAN, I.; KWON, Y. (1996). Hybrid neural network models for bankruptcy predictions. *Decision Support Systems*, v.18, p.63-72.

LI, H.X.; DA, X.L. (2000). A neural network representation of linear programming. *European Journal of Operational Research*, v.124, p.224-234.

LI, S. (2000). The development of a hybrid intelligent system for developing marketing strategy. *Decision Support Systems*, v.27, p.395-409.

LIN, T.; HORNE, B.G.; GILES, C.L. (1998). How embedded memory in recurrent neural network architectures helps learning long-term temporal dependencies. *Neural Networks*, v.11, p.861-868.

LIU, P. (2000). Max-min fuzzy Hopfield neural networks and an efficient learning algorithm. *Fuzzy Sets and Systems*, v.112, p.41-49.

MACLEAN, D. (2001). Analyzing the monetary aggregates. *Bank of Canada Review*, Summer 2001, p.31- 43.

MEERT, K. (1998). A real-time recurrent learning network structure for data reconciliation. *Artificial Intelligence in Engineering*, v.12, p.213-218.

MEKKAOUI, A.; JESPERS, P. (1990). An optimal self-organizing pattern classifier. In; INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS, Washington, EUA, 1990. *Annals*. Washington, v.I, p.447-450.

NIKOV, A.; STOEVA, S. (2001). Quick fuzzy backpropagation algorithm. *Neural Networks*, v.14, p.231-244.

PATTERSON, R.A.; PIRKUL, H. (2000). Heuristic procedure neural networks for the CMST problem. *Computers & Operations Research*, v.27, p.1171-1200.

PIERRE, S.; SAID, H.; PROBST, W.G. (2000). Routing in computer networks using artificial neural networks. *Artificial Intelligence in Engineering*, v.14, p.295-305.

PIRAMUTHU, S. (1999). Financial credit-risk evaluation with neural and neurofuzzy systems. *European Journal of Operational Research*, v.112, p.310-321.

POSEY, C.L.; HAWKES, L.W. (1996). Neural networks applied to knowledge acquisition in the student model. *Information Sciences*, v.88, p.275-298.

QUAH, T.S.; SRINIVASAN, B. (1999). Improving returns on stock investment through neural network selection. *Expert Systems With Applications*, v.17, p.295-301.

SCHYNS, P.G. (1990). Expertise acquisition through concepts refinement in a self-organizing architecture. In: INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS, Washington, EUA. *Annals*. Washington, v.I, p.236-239.

SETIONO, R.; THONG, J.Y.L.; YAP, C.S. (1998). Symbolic rule extraction from neural networks – an application to identifying organizations adopting IT. *Information & Management*, v.34, p.91-101.

SHARDA, R.; WANG, J. (1996). Neural networks and operations research/management science. *European Journal of Operational Research*, v.93, p.227-229.

SHMUELI, D.; SALOMON, I.; SHEFER, D. (1996). Neural network analysis of travel behavior: evaluating tools for prediction. *Transportation Research*, v.4, n.3, p.151-166.

SILVA, L.C.; CARVALHO FILHO, E.C.B. (1995). Métodos de rotulagem para as redes de Kohonen. In: II SIMPÓSIO BRASILEIRO DE REDES NEURAIS, São Carlos, 1995. *Anais*. São Carlos, v.1, p.199-204.

ST. JOHN, C.H.; BALAKRISHNAN, N.; FIET, J.O. (2000). Modeling the relationship between corporate strategy and wealth creation using neural networks. *Computers & Operations Research*, v.27, p.1077-1092.

SUNG, A.H. (1998). Ranking importance of input parameters of neural networks. *Expert Systems With Applications*, v.15, p.405-411.

TAURITZ, D.R.; HEINS, L.G. (1995). *Adaptive Resonance Theory (ART): an introduction*. Leiden, Department of Computer Sciences/Leiden University (Technical Report), 1995.

WALCZAK, S. (2001). Neural networks as a tool for developing and validating business heuristics. *Expert Systems With Applications*, v.21, p.31-36.

WANG, S. (1996). Nonparametric econometric modeling: a neural network approach. *European Journal of Operational Research*, v.89, p.581-592.

WANG, S. (1997). Neural networks in generalizing expert knowledge. *Computers and Industrial Engineering*, v.32, n.1, p.67-76.

WANG, S. (1998). An insight into the standard back-propagation neural network model for regression analysis. *Omega-The International Journal of Management Science*, v.26, n.1, p.133-140.

WANG, S. (1999). Nonlinear regression: a hybrid model. *Computers & Operations Research*, v.26, p.799-817.

WEI, Y. (2000). Recurrent neural networks for computing weighted Moore-Penrose inverse. *Applied Mathematics and Computation*, v.116, p.279-287.

WONG, B.K.; BODNOVICH, T.A.; SELVI, Y. (1997). Neural network applications in business: a review and analysis of the literature (1988-95). *Decision Support Systems*, v.19, p.301-320.

YAHIA, M. E. et al. (2000). Rough neural expert systems. *Expert Systems With Applications*, v.18, p.87-99.

YAO, J.; LI, Y.; TAN, C.L. (2000). Option price forecasting using neural networks. *Omega-The International Journal of Management Science*, v.28, p.455-466.

ZENGQI, S.; ZHIDONG, D. (1996). A fuzzy neural network and its application to controls. *Artificial Intelligence in Engineering*, v.10, p.311-315.

ZHANG, G. et al. (1999). Artificial neural networks in bankruptcy prediction: general framework and cross-validation analysis. *European Journal of Operational Research*, v.116, p.16-32.

ZHANG, G.; HU, M.Y. (1998). Neural network forecasting of the British Pound/US Dollar exchange rate. *Omega-The International Journal of Management Science*, v.26, n.4, p.495-506.

ZOPOUDINIS, C.; DOUMPOS, M.; MATSATSINIS, N.F. On the use of knowledge-based decision support systems in financial management: a survey. *Decision Support Systems*, v.20, p.259-277.


APÊNDICE A

Funções de Ativação

Estão a seguir apresentadas algumas funções de ativação utilizadas no treinamento de redes neurais artificiais. Para cada tipo de função há uma correspondência com o comportamento da base de dados utilizada ou com o tipo de problema a ser aprendido pela rede neural, portanto a escolha da função de ativação depende em boa medida da experiência prática do operador em manipular os diversos modelos de redes neurais existentes, bem como do seu conhecimento das aplicações bem-sucedidas de cada arquitetura. Constam também, juntamente com as expressões matemáticas das funções, seus respectivos gráficos que mostram o comportamento das mesmas.

Função Degrau:

$$\varphi(v) = \begin{cases} 1, v > Limite \\ 0, v \leq Limite \end{cases}$$




Função Linear:

$$\varphi(v) = k.v$$




Função Logística Sigmoidal ou Sigmóide:

$$\varphi(v) = \frac{1}{1 + e^{-v}}$$



Função Tangente Hiperbólica:

$$\varphi(v) = \operatorname{tgh}(v)$$



APÊNDICE B

Países Estudados Por Continente

África:

África do Sul	Eritreia	Mauritânia	Seychelles
Angola	Etiópia	Moçambique	Suazilândia
Argélia	Gabão	Namíbia	Sudão
Botswana	Gâmbia	Niger	Tanzânia
Burkina Faso	Gana	Nigéria	Tchad
Burundi	Guiné Equatorial	Quênia	Togo
Cabo Verde	Guiné-Bissau	Rep. Congo	Tunísia
Camarões	Lesoto	Rep. Dem. Congo	Uganda
Comoros	Madagascar	República Centro-Africana	Zâmbia
Costa do Marfim	Malawi	Rwanda	Zimbabwe
Djibouti	Mali	Senegal	
Egito	Marrocos	Serra Leoa	

América Central:

Belize	Dominica	Haiti	República Dominicana
Costa Rica	El Salvador	Honduras	Trinidad e Tobago
Cuba	Guatemala	Jamaica	

América do Norte

Canadá	Estados Unidos	México
--------	----------------	--------

América do Sul:

Argentina	Chile	Guiana	Uruguai
Bolívia	Colômbia	Paraguai	Venezuela
Brasil	Equador	Peru	

Ásia:

Arábia Saudita	Filipinas	Jordânia	Nepal
Azerbaijão	Geórgia	Kirjistão	Paquistão
Bahrein	Hong Kong	Kuwait	Rep. Coréia
Bangladesh	Iêmen	Laos	Singapura
Benin	Índia	Líbano	Síria
Butão	Indonésia	Malásia	Sri Lanka
Camboja	Irã	Maldivas	Tailândia
China	Israel	Mianmar	Usbequistão
Casaquistão	Japão	Mongólia	Vietnã

Europa:

Albânia	Eslovênia	Islândia	Portugal
Alemanha	Espanha	Itália	Reino Unido
Armênia	Estônia	Letônia	República Tcheca
Áustria	Finlândia	Lituânia	Romênia
Bélgica	França	Macedônia	Rússia
Bielo-Rússia	Grécia	Malta	Suécia
Bulgária	Holanda	Moldova	Suíça
Dinamarca	Hungria	Noruega	Turquia
Eslováquia	Irlanda	Polônia	Ucrânia

Oceania:

Austrália	Ilhas Maurícios	Papua Nova Guiné	Tonga
Fiji	Ilhas Salomão	Samoa	Vanuatu
Ilhas Virgens	Nova Zelândia	São Tomé e Príncipe	