

Ficha Catalográfica

Catálogo-na-Publicação (CIP). UFRGS. Escola de Engenharia. Biblioteca

E56a

Encontro Nacional de Engenharia de Produção (23.:2003: Ouro Preto, MG)
Anais / XXIII Encontro Nacional de Engenharia de Produção, IX International
Conference on Industrial Engineering and Operations Management - Ouro Preto:
UFOP, 2003.

ISBN 85-88478-09-9

1 CD-Rom: il.

1. Engenharia de Produção - Eventos. I. IX International Conference on
Industrial Engineering and Operations management. II. ENEGE. III. Universidade
Federal de Ouro Preto.

CDU 658.5(063)

ARTIGOS

ENEGE 2003

MENSAGEM

COMISSÃO ORG

COMITÊ CIENT

REFEREES

CONFERÊNCIA

SESSÕES DIRIGIDAS

OURO PRETO/MG

PRÊMIO TECMARAN

PREACTOR

REALIZAÇÃO

PATROCÍNIO

FICHA CATALOG

CRÉDITOS

AJUDA

Desenvolvido no:



LOPP
UFRGS

SEP
15
04
04

Aplicação de modelos de redes neurais na elaboração e análise de clusters macroeconômicos

Maurílio Benite (USP e IMESB-VC) mbenite@hotmail.com - Docente do Curso de Administração do Instituto Municipal de Ensino Superior de Bebedouro "Victorio Cardassi" - IMESB-VC

Marcelo Seido Nagano (USP) drnagano@usp.br

João Vitor Moccasin (USP) jvmoccel@prod.eesc.usp.br

B467a

Resumo

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 uma topologia neural auto-organizada na realização deste tipo de tarefa. Os 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; Geração de Clusters.

1. Introdução

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 resultariam destas decisões. Pensando nos diferentes resultados possíveis de um determinado evento a ser realizado como diferentes estados de natureza de um processo, sob uma situação ótima dever haver sempre um plano contingente elaborado através da especificação geral dos vários resultados possíveis deste processo em relação ao futuro (VARIAN, 1994).

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. 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.

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).

Existem diversos procedimentos paramétricos e não-paramétricos consagrados que são largamente utilizados para a análise de dados e suas estruturas subjacentes, dentre os quais pode-se citar a Análise Multivariada (JOHNSON & WICHERN, 1992), a Metodologia Box-Jenkins (BOX & JENKINS, 1976) e os Modelos Heterocedásticos ARCH-GARCH (ENGLE, 2001). Todavia, modelos de redes neurais artificiais auto-organizados possuem a vantagem de

1368990
160404

SYSNO	1368990
PROD	000778
ACERVO EESC	

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.

Deste modo, este estudo propõe a utilização de uma abordagem neural na elaboração e análise de cenários macroeconômicos e uma breve 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 e discutir sua razoabilidade.

A topologia neural utilizada no estudo é o modelo ART-2, proposto através da Teoria da Ressonância Adaptativa (*Adaptive Resonance Theory*) descrita por Carpenter & Grossberg em 1976, que apresentam como principal característica a estabilidade do armazenamento do conhecimento adquirido pela rede. Isto se torna mais importante à medida que, em uma base de dados relativamente vasta e inter-relacionada, a complexidade inerente ao sistema em estudo gera problemas relativos à perda paulatina de identidade do conhecimento adquirido por uma rede neural, gerando a criação de falsos padrões (BRAGA, LUDERMIR & CARVALHO, 2000).

2. Clusters e complexidade sistêmica

A geração de *clusters* consiste em uma metodologia comum na identificação de sistemas diversos. Um *cluster* é um agrupamento de elementos que possuem características em comum, de modo a oferecer um conjunto coerente, sistemático, compreensível e plausível, com o objetivo de descrever um determinado sistema e oferecer instrução e suporte à tomada de decisões (LAUDON & LAUDON, 1996).

O trabalho resultante desta tarefa seria basicamente um estudo que possibilitaria ao seu usuário final a análise e a tomada de decisões fundamentado nas similaridades e diferenças das categorias obtidas, tanto sob o aspecto descritivo como o de planejamento, devido à inerente complexidade resultante da interação dos dados disponíveis. 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) com a necessidade final expressa na elaboração dos *clusters* em questão.

Porém, o grande complicador da 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 em complexidade à medida que se adicionam mais e mais dados na composição da análise (WILLIAMS, 1999). Entretanto, alternativas das mais diversas teriam sua efetividade observada pelos resultados obtidos independentemente da metodologia empregada.

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 (HAYKIN, 1994).

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). Nos modelos de redes neurais artificiais, estas características são simuladas através da adoção de estado, função e limiar de ativação (BRAGA, LUDERMIR & CARVALHO, 2000).

As funções de ativação realizam o processamento dos sinais recebidos por cada neurônio individualmente e o transformam em um estado de ativação neural. 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 (HAYKIN, 1994).

A mais distinta propriedade das redes neurais artificiais é sua habilidade em aprender com o ambiente, e melhorar sua performance através deste aprendizado através do uso de paradigmas de aprendizado, os quais consistem em métodos de gerenciamento do aprendizado neural. Existem dois tipos de paradigmas de aprendizado: supervisionado, o qual supõe a existência de um direcionador externo que orienta a rede para as saídas desejadas, e não supervisionado, no qual inexistente este direcionador, fazendo com que os resultados produzidos pela rede sejam considerados como sendo o melhor processamento possível obtido a partir dos dados disponíveis (HAYKIN, 1994). 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).

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. As estruturas genéricas são as conexões entre os neurônios e o arranjo entre as camadas de neurônios da rede, ilustrados na Figura 1 abaixo. 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).




FIGURA 1: Esquema de uma rede neural genérica. Adaptado de ZELL *et al.* (2001).

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). A partir desta retomada no interesse pelo emprego de redes neurais, várias outras topologias foram criadas, na tentativa de solucionar os mais diversos tipos de problemas. A seguir, é apresentada a topologia não supervisionada ART-2 utilizada neste estudo.

4. Redes neurais auto-organizadas

Os modelos neurais ART englobam 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. 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;
- 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*;

Na Figura 2 abaixo, apresentamos a arquitetura básica de uma rede ART, a qual 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*.

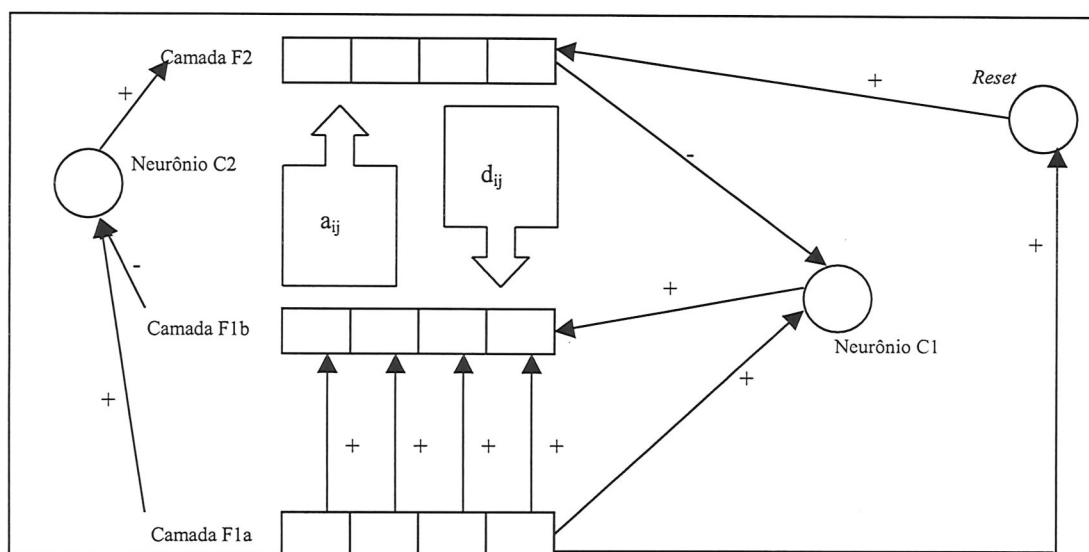


FIGURA 2: Arquitetura de uma rede ART-2. Adaptado de CARPENTER & GROSSBERG (1987).

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, 1987). 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 chamada 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 (CARPENTER & GROSSBERG, 1987). 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 um vetor descendente D e o vetor de entrada. Esta decisão é tomada pela unidade de *reset*, baseado nos sinais recebidos pelas camadas F1a e F1b. 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 a regra dos dois terços.

A despeito das topologias ART apresentarem uma maior complexidade do que outras topologias neurais de uso mais geral 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 (BRAGA, LUDERMIR & CARVALHO, 2000).

Abaixo apresenta-se uma lista contendo os parâmetros utilizados no algoritmo de treinamento de uma rede ART-2, conforme descrito por CARPENTER & GROSSBERG (1987), 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);
- m : 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 deve 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 entre 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 (1987). 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.

5. Abordagem neural não supervisionada na elaboração de *clusters* macroeconômicos

É apresentada abaixo a aplicação de uma abordagem neural baseada em uma topologia auto organizadas, através da utilização de uma base de dados contida no “THE 1999 WORLD

BANK DEVELOPMENT INDICATORS CD-ROM”, versão 4.2, para o ano de 1997, constando 154 países e respectivos 27 dados macroeconômicos: razões do Investimento Doméstico Bruto, Exportações de Bens e Serviços, Poupança Doméstica Bruta, Poupança Nacional Bruta, Pagamentos de Juros, Dívida Total e Valor Presente da Dívida em função do Produto Interno Bruto; Percentual de Crescimento do Produto Interno Bruto; Exportação e Importação Agrícola, Industrial e de Serviços; Consumo Privado e Governamental; Variação de Preços ao Consumidor; Deflator Implícito do Produto Interno Bruto; Superávit (Déficit) Primário e Receitas Correntes do Governo; Renda Líquida Investida no Exterior, Transferências Correntes Líquidas, Saldo do Balanço em Conta Corrente, Variação nas Reservas Monetárias, Reservas Monetárias Totais; e Serviço Total da Dívida.

Os software usado foi 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 método de classificação neural e análise dos resultados empregado consiste em duas fases distintas. A classificação e geração dos *clusters* é obtida com o emprego de uma rede neural ART-2 com ρ igual a 0,9, conforme (ZELL *et. Al.*, 2000), e a análise da composição dos *clusters* será baseada na observação da similaridade entre seus componentes em relação aos dados empregados no estudo.

Os *clusters* obtidos pelo processamento neural proposto constam na Tabela 1 abaixo:

Cluster	Países
1	Estados Unidos
2	Austrália, Nova Zelândia, Hong Kong, Holanda
3	África do Sul, Cabo Verde, Chile, Comoros, Dinamarca, Espanha, Fiji, Geórgia, Grécia, Ilhas Maurícios, Ilhas Salomão, Ilhas Virgens, Indonésia, Maldivas, Malta, Moldova, Noruega, Papua Nova Guiné, Portugal, Rep. Coréia, Samoa, São Tomé e Príncipe, Singapura, Suécia, Suíça, Tanzânia, Tonga, Trinidad e Tobago, Vanuatu
4	Japão, França, Canadá, Alemanha, Reino Unido, Áustria, Bélgica, Finlândia, Itália
5	Cuba
6	China
7	Albânia, Bielorrússia, 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, Níger, Nigéria, Quênia, Rep. Congo, Rep. Dem., Congo, República Centro-Africana, Rwanda, Senegal, Serra Leoa, Seychelles, Suazilândia, Sudão, Tchad, Togo, Uganda, Zâmbia, Zimbábue
11	África do Sul, Argentina, Espanha, Irlanda, Islândia, Israel, Portugal, Rep. Coréia, Singapura
12	Arábia Saudita, Bahrein, Benin, Iêmen, Irã, Kuwait

Tabela 1 – Quantidade de *clusters* obtidos e respectivo número de países para cada *cluster*

Percebe-se que alguns *clusters*, notadamente 1, 5 e 6, apresentam apenas um país. Isto significa que a rede ART-2 empregada considerou que estes países são bastante distintos de todos os outros, sob uma análise macroeconômica. Assim, destacamos o caso altamente específico dos Estados Unidos, e depois os casos de Cuba e China. O primeiro é classificado distintamente dos outros países em razão da magnitude para quaisquer dos dados macroeconômicos empregados: os módulos são elevados em comparação com todos os outros. O caso cubano é exatamente o oposto: os módulos dos dados cubanos são extremamente baixos, provavelmente por não serem fornecidos. 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.

Outros *clusters* deixam bastante evidente que a classificação neural obtida corresponde a aspectos geopolíticos, os quais não são representados diretamente pela base de dados empregada. Assim, o *cluster* 4 corresponde, de uma forma geral, a países que apresentaram alto índice de crescimento e desenvolvimento econômico nas últimas décadas, devido especialmente ao papel do setor exportador e os efeitos concomitantes na balança comercial e de serviços; o *cluster* 7 agrupa a maioria dos países do Leste Europeu; o *cluster* 8 consiste nos países da América Latina, com a notável inclusão do Líbano; o *cluster* 9 agrega os países da Ásia de menor renda e desenvolvimento humano; o *cluster* 10 engloba toda a África Sub-Saariana; o *cluster* 11 mostra os países que apresentavam no período taxas de crescimento econômico que os aproximava dos ricos, contudo possuindo indicadores relacionados a Finanças Governamentais que os diferenciam do *cluster* 4; e por fim, o *cluster* 12 apresenta países exportadores de petróleo cujos dados de Comércio Internacional os aproxima dos países do *cluster* 4. O *cluster* 3 se mostra como uma categoria bastante dispersada em relação aos seus componentes, não sendo possível inferir informações que justifique a diversidade observada, podendo ser assim considerado como um *cluster default*.

6. Considerações finais

Os *clusters* obtidos neste estudo se revelaram uma alternativa razoável aos 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. Contribuem nestes pontos positivos, no caso das redes ART, a sua arquitetura imune ao problema de geração de falsos padrões em bases de dados complexas e correlacionadas.

Referências

- 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). ART-2: self-organization of a stable category recognition codes for analog input patterns. *Applied Optics*, v.26, n.23, p.4919-4930, Dec.
- ENGLE, R. (2001). The use of ARCH/GARCH models in applied econometrics. *Journal of Economic Perspectives*, v.15, n.4, p.157-168.
- HAYKIN, S. (1994). *Neural networks: a comprehensive foundation*. Hamilton, Prentice-Hall.
- JOHNSON, R.A.; WICHERN, D.W. (1992). *Applied multivariate statistical analysis*. Upper Saddle River, Prentice-Hall.
- LAUDON, K.C.; LAUDON, J.P. (1996). *Management information systems: organization and technology*. 4.ed. Upper Saddle River, Prentice-Hall.
- SARLE, W.S. (2001). *Neural network FAQ*. ftp.sas.com/pub/neural/FAQ.txt.zip. (18 Sept).
- THE 1999 WORLD BANK DEVELOPMENT INDICATORS - Win*STARS version 4.2. (CD-ROM). Washington, 1999.
- VARIAN, H.R. (1994). *Microeconomia: princípios básicos*. Trad. por Luciane Melo. Rio de Janeiro, Campus.
- WILLIAMS, T.M. (1999). The need for new paradigms for complex projects. *International Journal of Project Management*, v.17, n.5, p.269-273.
- 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).