

**UNIVERSIDADE FEDERAL DE MINAS GERAIS
ESCOLA DE CIÊNCIA DA INFORMAÇÃO**

Magali Rezende Gouvêa Meireles

**CATEGORIZAÇÃO DE DOCUMENTOS A PARTIR
DE SUAS CITAÇÕES: UM MÉTODO BASEADO
EM REDES NEURAS ARTIFICIAIS**

**Belo Horizonte
2012**

Magali Rezende Gouvêa Meireles

**CATEGORIZAÇÃO DE DOCUMENTOS A PARTIR
DE SUAS CITAÇÕES: UM MÉTODO BASEADO
EM REDES NEURAIS ARTIFICIAIS**

**Belo Horizonte
2012**

Magali Rezende Gouvêa Meireles

**CATEGORIZAÇÃO DE DOCUMENTOS A PARTIR
DE SUAS CITAÇÕES: UM MÉTODO BASEADO
EM REDES NEURAIS ARTIFICIAIS**

Tese apresentada ao programa de Pós-Graduação em
Ciência da Informação da Escola de Ciência da
Informação da Universidade Federal de Minas Gerais
para obtenção do grau de Doutor em Ciência da
Informação.

Linha de Pesquisa: Organização e Uso da Informação

Orientadora: Profa. Beatriz Valadares Cendón

Co-orientador: Prof. Paulo Eduardo Maciel de Almeida

**Belo Horizonte
2012**

Meiros, Magali Rezende Gouvêa.

M514c Categorização de documentos a partir de suas citações
[manuscrito] : um método baseado em redes neurais artificiais /
Magali Rezende Gouvêa Meiores. – 2012.
237 f. : il., enc.

Orientadora: Beatriz Valadares Cendón.

Co-orientador: Paulo Eduardo Maciel de Almeida.

Tese (doutorado) – Universidade Federal de Minas Gerais,
Escola de Ciência da Informação.

Referências: f. 171-179

Apêndices: f. 180-237

1. Ciência da informação – Teses. 2. Sistemas de
recuperação da informação – Teses. 3. Bibliometria – Teses. 4.
Inteligência artificial – Teses. 5. Redes neurais (Computação) –
Teses. 6. Classificação – Teses. 7. Categorização (Psicologia) –
Teses. I. Título. II. Cendón, Beatriz Valadares. III. Almeida, Paulo
Eduardo Maciel de. IV. Universidade Federal de Minas Gerais,
Escola de Ciência da Informação.

CDU: 025.4.03



UFMG

Universidade Federal de Minas Gerais
Escola de Ciência da Informação
Programa de Pós-Graduação em Ciência da Informação

FOLHA DE APROVAÇÃO

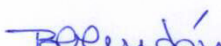
"CATEGORIZAÇÃO DE DOCUMENTOS A PARTIR DE SUAS CITAÇÕES: UM MÉTODO BASEADO EM REDES NEURAIS ARTIFICIAIS"

Magali Rezende Gouvêa Meireles

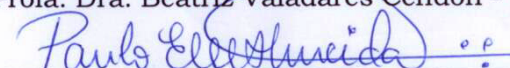
Tese submetida à Banca Examinadora, designada pelo Colegiado do Programa de Pós-Graduação em Ciência da Informação da Universidade Federal de Minas Gerais, como parte dos requisitos à obtenção do título de: "**Doutora em Ciência da Informação**", Linha de Pesquisa: "**Organização e Uso da Informação - OUI**".

Tese aprovada em: 08 de novembro de 2012.

Por:



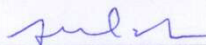
Prof. Dra. Beatriz Valadares Cendón - ECI/UFMG (Orientadora)



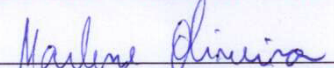
Prof. Dr. Paulo Eduardo Maciel de Almeida - CEFET/MG (Co-orientador)



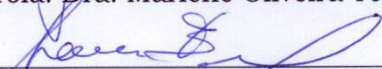
Prof. Dr. Renato Rocha Souza - FGV/RJ



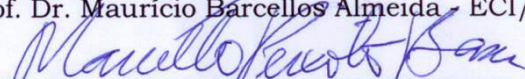
Prof. Dr. José Wilson da Costa - PUC/MG



Profa. Dra. Marlene Oliveira Teixeira de Melo - ECI/UFMG

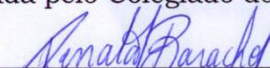


Prof. Dr. Maurício Barcellos Almeida - ECI/UFMG



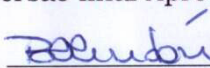
Prof. Dr. Marcello Peixoto Bax - ECI/UFMG

Aprovada pelo Colegiado do PPGCI



Prof. Renata Maria Abrantes Baracho Porto
Coordenadora Pró-Tempore

Versão final Aprovada por



Prof. Beatriz Valadares Cendón
Orientadora



UFMG

Universidade Federal de Minas Gerais
Escola de Ciência da Informação
Programa de Pós-Graduação em Ciência da Informação

ATA DA DEFESA DE TESE DE **MAGALI REZENDE GOUVÊA MEIRELES**, matrícula: 2009652759

Às 14:00 horas do dia 08 de novembro de 2012, reuniu-se na Escola de Ciência da Informação da UFMG a Comissão Examinadora aprovada pelo Colegiado do Programa de Pós-Graduação em Ciência da Informação em 04/10/2012, para julgar, em exame final, o trabalho intitulado **Categorização de documentos a partir de suas citações: um método baseado em redes neurais artificiais**, requisito final para obtenção do Grau de DOUTORA em CIÊNCIA DA INFORMAÇÃO, Área de Concentração: Produção, Organização e Utilização da Informação, Linha de Pesquisa: Organização e Uso da Informação - OUI. Abrindo a sessão, a Presidente da Comissão, Profa. Dra. Beatriz Valadares Cendón, após dar conhecimento aos presentes do teor das Normas Regulamentares do Trabalho Final, passou a palavra à candidata para apresentação de seu trabalho. Seguiu-se a arguição pelos examinadores com a respectiva defesa da candidata. Logo após, a Comissão se reuniu sem a presença da candidata e do público, para julgamento e expedição do resultado final. Foram atribuídas as seguintes indicações:

Profa. Dra. Beatriz Valadares Cendón - Orientadora	APROVADA
Prof. Dr. Paulo Eduardo Maciel de Almeida - Co-orientador	APROVADA
Prof. Dr. Renato Rocha Souza	APROVADA
Prof. Dr. José Wilson da Costa	APROVADA
Profa. Dra. Marlene Oliveira Teixeira de Melo	APROVADA
Prof. Dr. Maurício Barcellos Almeida	APROVADA
Prof. Dr. Marcello Peixoto Bax	APROVADA

Pelas indicações, a candidata foi considerada APROVADA.

O resultado final foi comunicado publicamente à candidata pela Presidente da Comissão. Nada mais havendo a tratar, a Presidente encerrou a sessão, da qual foi lavrada a presente ATA que será assinada por todos os membros participantes da Comissão Examinadora. A banca ressalta a qualidade e inovação da pesquisa e recomenda que a tese seja indicada para as premiações pertinentes.

Belo Horizonte, 08 de novembro de 2012

Profa. Dra. Beatriz Valadares Cendón
ECI/UFMG (Orientadora)

Prof. Dr. Paulo Eduardo Maciel de Almeida
CEFET/MG (Co-orientador)

Prof. Dr. Renato Rocha Souza
FGV/RJ

Prof. Dr. José Wilson da Costa
PUC/MG

Profa. Dra. Marlene Oliveira Teixeira de Melo
ECI/UFMG

Prof. Dr. Maurício Barcellos Almeida
ECI/UFMG

Prof. Dr. Marcello Peixoto Bax
ECI/UFMG

Profa. Renata Maria Abrantes Baracho
- coordenadora do Programa de
Pós-Graduação em Ciência da
Informação - ECI / UFMG

Obs: Este documento não terá validade sem a assinatura e carimbo da Coordenadora

Ao Paulo, à Cecília, ao Lucas e à Carol

AGRADECIMENTOS

Meus agradecimentos à minha orientadora, Profa. Beatriz Valadares Cendón, pelo acompanhamento atencioso e pelas valiosas e precisas sugestões que enriqueceram e valorizaram a proposta e o conteúdo deste trabalho.

Ao meu co-orientador, Prof. Paulo Eduardo Maciel de Almeida, do CEFET-MG, pelas contribuições técnicas e pelo grande incentivo para iniciar e desenvolver esta pesquisa.

À PUC Minas, pelo suporte financeiro destinado a este trabalho. Agradeço a todos que direta ou indiretamente contribuíram para a realização deste trabalho, em especial aos gestores do IEC durante o tempo de execução do trabalho, Profa. Carmen Luiza Rabelo Xavier, Prof. Sérgio de Moraes Hanriot e Prof. Alexandre Rezende Guimarães, ao Prof. Hugo Bastos de Paula, coordenador do curso Sistemas de Informação, e às funcionárias do IEC, Cláudia Maria Rodrigues de Almeida e Gláucia Andrade da Costa.

À Escola de Ciência da Informação da UFMG, pela infra-estrutura disponibilizada e pelo apoio financeiro concedido para participação em eventos. Aos professores das disciplinas que cursei, pelos ensinamentos, e aos professores da banca que se dispuseram a avaliar o meu trabalho.

Aos alunos do PIBIC-EM, Gabriel Miranda Pedrosa e Paulo Vyctor Gomes dos Santos Teixeira, pelo interesse e pela participação no desenvolvimento da base de dados e do programa, e à aluna da PUC Minas, Rita Diniz Viana, pelo apoio técnico no desenvolvimento do quarto experimento.

Agradeço o incentivo constante dos meus pais, Maury e Alda, meus exemplos e fontes de equilíbrio, dos meus irmãos Marylane e Maury Júnior, da minha cunhada Laura, da minha tia querida Conceição, presenças carinhosas na minha vida, e a cada um dos integrantes da minha família, que de algum modo esteve presente neste período, renovando a minha energia para trabalhar em cada uma destas páginas.

Aos meus filhos, Cecília, Lucas e Carolina, agradeço por estarem sempre por perto, aumentando minha motivação para desenvolver e finalizar o trabalho. Carol, obrigada por sempre me perguntar se eu já havia terminado e se precisava de ajuda, você me ajudou muito ditando os números das tabelas. Lucas, obrigada pelas traduções e pelas revisões de inglês. Cecília, obrigada pelas figuras que você editou e pelas revisões de inglês. Vocês são as minhas maiores inspirações!

O mais importante e bonito, do mundo, é isto: que as pessoas não estão sempre iguais, ainda não foram terminadas - mas que elas vão sempre mudando. Afinam ou desafinam. Verdade maior. É o que a vida me ensinou (GUIMARÃES ROSA, 1986).

RESUMO

A organização automática de grandes coleções torna-se atividade mais relevante à medida que aumenta o número de publicações disponíveis em meio digital. Esse trabalho pretende contribuir para essa área avaliando o uso de Redes Neurais Artificiais (RNA) para categorizar documentos automaticamente por meio da análise das referências bibliográficas neles citadas. O método desenvolvido gera categorias de documentos aplicando conceitos da bibliometria. As publicações foram categorizadas utilizando as citações como atributo principal, baseando-se na premissa de que as citações são uma importante fonte de informação sobre o relacionamento existente entre os documentos. As RNA são utilizadas, tipicamente, em problemas de aproximação de função, predição, classificação, categorização e otimização. Muitos dos experimentos relatados na literatura descrevem a utilização de redes *Self Organizing Maps* (SOM) para organização de documentos em um formato alternativo para a recuperação de informação. As redes SOM foram utilizadas, neste trabalho, com o objetivo de categorizar os documentos apresentados. As relações entre os textos foram definidas não pela identificação de termos em comum, mas, pela presença de referências bibliográficas comuns e respectivos anos de publicação. Após a validação do método, utilizando um protótipo, foi criado um banco de dados com 200 artigos, do periódico *IEEE Transactions on Neural Network*, publicados entre 2001 e 2010. As publicações foram categorizadas pela RNA e apresentadas em grupos organizados por suas citações em comum. Os resultados obtidos em três experimentos mostraram que a RNA identificou satisfatoriamente *clusters* de autores e textos a partir de suas referências. A análise dos textos das publicações pertencentes aos *clusters*, formados a partir da categorização automática dos documentos, evidenciou a forte relação semântica existente entre eles. Os *clusters* podem ser úteis na identificação de grupos de pesquisadores que trabalham em áreas afins, na identificação de tendências de pesquisa de um domínio específico de conhecimento e na formulação ou na reformulação de uma consulta no processo de recuperação de informação.

Palavras-chave: Agrupamento. Bibliometria. Categorização. Ciência da Informação. Redes Neurais Artificiais. Sistemas de Recuperação de Informação.

ABSTRACT

The automatic organization of large collections of documents becomes more important with the growth of the amount of information available in digital form. This study contributes to this issue evaluating the use of Artificial Neural Networks to automatically categorize documents through the analysis of the references cited in these documents. The method here developed generates clusters of documents based on bibliometric concepts. The publications were categorized using citations as the main input, grounded on the premise that the presence of common citations is an indicative of relationships among documents. Artificial Neural Networks are typically used to solve problems related to function approximation, prediction, classification, categorization and optimization. Many of the experiments reported in the literature describe the use of SOM networks, Self Organizing Maps, in the organization of documents for information retrieval. SOM networks were used in this work in order to categorize documents in a test database. In this categorization process, the semantic relationships among documents were defined not by the identification of terms in common, but by the presence of common references and their years of publication. After the validation of the method, through the use of a prototype, a database which contained the references cited in 200 articles published in the journal IEEE Transactions on Neural Networks between the years of 2001 and 2010 was created. The publications were categorized by the Artificial Neural Networks and presented in groups organized by their common citations. The results obtained in three experiments showed that the Artificial Neural Networks successfully identified clusters of authors and texts, through their cited references. The analysis of the texts from the cluster publications, formed by the automatic categorization of the documents, evidenced the existence of semantic relationships between the documents. They can be useful to identify groups of researchers working in related fields, for identifying research trends in specific domains of knowledge or in the development or reformulation of queries in the process of information retrieval.

Keywords: Clustering. Bibliometrics. Categorization. Information Science. Artificial Neural Networks. Information Retrieval Systems.

LISTA DE FIGURAS

Figura 1	- A formação interdisciplinar da Ciência da Informação	26
Figura 2	- Relações entre dado, informação e conhecimento	28
Figura 3	- Meios de transmissão de informação	32
Figura 4	- Diagrama de um processo de comunicação	33
Figura 5	- Diagrama da Teoria da Informação.....	34
Figura 6	- Representação de um neurônio biológico	47
Figura 7	- Diagrama de uma topologia MLP	51
Figura 8	- Diagrama topológico de uma rede SOM.....	51
Figura 9	- Diagrama topológico de uma rede Hopfield	52
Figura 10	- Exemplo de RNA utilizando a arquitetura de Mozer	55
Figura 11	- Representação de uma RNA aplicada à recuperação de informação	56
Figura 12	- O processo de categorização proposto por He e Hui (2001).....	60
Figura 13	- Representação das quatro etapas metodológicas.....	63
Figura 14	- Criação dos grupos representantes de todas as topologias	67
Figura 15	- Número de citações por referência: base de dados <i>JASIST</i>	74
Figura 16	- Número de citações por referência: base de dados <i>IEEE</i>	75
Figura 17	- Número de citações por referência: base de dados <i>IEEE</i> completa	76
Figura 18	- Repetição das referências de número 18 e 36	78
Figura 19	- Repetição das referências 5 e 35	79
Figura 20	- Interface inicial do programa	80
Figura 21	- Janela de interface com o usuário	81
Figura 22	- Geração da entrada da RNA.....	82
Figura 23	- Parte do arquivo utilizado pela RNA em suas entradas	84
Figura 24	- Grupos de artigos gerados pelas topologias de 10 e 12 categorias	86
Figura 25	- Grupos de artigos gerados pelas topologias de 16 e 25 categorias	87
Figura 26	- Grupos de artigos gerados pelas topologias de 4 e 9 categorias	87
Figura 27	- Grupos de artigos gerados pela topologia de 36 categorias	88
Figura 28	- Relação de referências comuns aos artigos do GrupoUm_E1	94
Figura 29	- Relação de referências comuns aos artigos do GrupoDois_E1	101
Figura 30	- Relação de referências comuns aos artigos do GrupoTrês_E1	107
Figura 31	- Relação de referências comuns aos artigos do GrupoQuatro_E1	113
Figura 32	- Relação de referências comuns aos artigos do GrupoCinco_E1	118

Figura 33	- Relação de referências comuns aos artigos do GrupoSeis_E1.....	123
Figura 34	- Relação de referências comuns aos artigos do GrupoSete_E1	128
Figura 35	- Fases do experimento 1	131
Figura 36	- Grupos de artigos gerados pelas topologias de 4 e 9 categorias	132
Figura 37	- Grupos de artigos gerados pelas topologias de 10 e 12 categorias	132
Figura 38	- Grupos de artigos gerados pelas topologias de 16 e 25 categorias	133
Figura 39	- Grupos de artigos gerados pela topologia de 36 categorias	133
Figura 40	- Relação de referências comuns aos artigos do GrupoA_E2	139
Figura 41	- Fases do experimento 2	153
Figura 42	- Relação de referências comuns aos artigos do GrupoB_E3.....	156
Figura 43	- Parte do arquivo de entrada da ferramenta Tanagra.....	160
Figura 44	- Método de categorização utilizando RNA	168

LISTA DE TABELAS

Tabela 1	- Relação de artigos e referências citadas	71
Tabela 2	- Relação entre os artigos e os códigos numéricos de suas referências	85
Tabela 3	- Número de artigos agrupados nos sete grupos	88
Tabela 4	- Identificação dos grupos em cada topologia	89
Tabela 5	- Número de artigos dos grupos em cada topologia	89
Tabela 6	- Categorização do GrupoUm_E1 nas 4 Topologias	92
Tabela 7	- Características dos artigos presentes no GrupoUm_E1	92
Tabela 8	- Referências comuns a cada dois artigos do GrupoUm_E1	94
Tabela 9	- Referências repetidas no GrupoUm_E1	95
Tabela 10	- Categorização do GrupoDois_E1 nas 4 topologias.....	96
Tabela 11	- Características dos artigos presentes no GrupoDois_E1	97
Tabela 12	- Referências comuns a cada dois artigos do GrupoDois_E1.....	100
Tabela 13	- Referências repetidas no GrupoDois_E1	101
Tabela 14	- Categorização do GrupoTrês_E1	102
Tabela 15	- Características dos artigos presentes no GrupoTrês_E1	103
Tabela 16	- Referências comuns a cada dois artigos do GrupoTrês_E1	106
Tabela 17	- Referências repetidas no GrupoTrês_E1	107
Tabela 18	- Categorização do GrupoQuatro_E1	108
Tabela 19	- Características dos artigos presentes no GrupoQuatro_E1	109
Tabela 20	- Referências comuns a cada dois artigos do GrupoQuatro_E1	112
Tabela 21	- Referências repetidas no GrupoQuatro_E1	114
Tabela 22	- Categorização do GrupoCinco_E1	115
Tabela 23	- Características dos artigos presentes no GrupoCinco_E1	115
Tabela 24	- Referências comuns a cada dois artigos do GrupoCinco_E1.....	118
Tabela 25	- Referências repetidas no GrupoCinco_E1	118
Tabela 26	- Categorização do GrupoSeis_E1	119
Tabela 27	- Características dos artigos presentes no GrupoSeis_E1	120
Tabela 28	- Referências comuns a cada dois artigos do GrupoSeis_E1.....	123
Tabela 29	- Referências repetidas no GrupoSeis_E1	124
Tabela 30	- Categorização do GrupoSete_E1	124
Tabela 31	- Características dos artigos presentes no GrupoSete_E1	125
Tabela 32	- Referências comuns a cada dois artigos do GrupoSete_E1	128

Tabela 33	- Referências repetidas no GrupoSete_E1	129
Tabela 34	- Características dos Grupos do Experimento 1	129
Tabela 35	- Características do GrupoA_E2 em cada uma das topologias.....	134
Tabela 36	- Características dos artigos do GrupoA_E2	134
Tabela 37	- Referências comuns a cada dois artigos do GrupoA_E2	137
Tabela 38	- Referências repetidas no GrupoA_E2	139
Tabela 39	- Características das cinco referências mais citadas no GrupoA_E2.....	141
Tabela 40	- Relação entre os autores e os artigos do GrupoA_E2	142
Tabela 41	- Artigos do grande grupo da topologia de 16 categorias.....	147
Tabela 42	- Características do GrupoB_E3 em cada uma das topologias.....	154
Tabela 43	- Características dos artigos A142 e A177	154
Tabela 44	- Referências comuns aos artigos A142, A177 e ao GrupoB_E3.....	155
Tabela 45	- Referências repetidas no GrupoB_E3	156
Tabela 46	- Características das referências mais citadas no GrupoB_E3	158
Tabela 47	- Relação entre os autores e os artigos do GrupoB_E3	158

LISTA DE QUADROS

Quadro 1	- Relação entre as categorias aristotélicas e as categorias gramaticais.....	37
Quadro 2	- Razões que levam um autor a citar.....	42
Quadro 3	- Dificuldades encontradas na implementação da análise de citações.....	43
Quadro 4	- Aplicações das técnicas bibliométricas	44
Quadro 5	- Classificação de variáveis	64
Quadro 6	- Categorias geradas pela RNA	72
Quadro 7	- Informações relativas às entradas da RNA	83
Quadro 8	- Características dos autores dos artigos do GrupoA_E2	144
Quadro 9	- Comparação de autores do GrupoA_E2 e do GrupoB_E3.....	159
Quadro 10	- Palavras-chave dos artigos 4 e 19	161
Quadro 11	- Características dos quatro grupos gerados na topologia de 13 categorias	161

SUMÁRIO

CAPÍTULO 1: INTRODUÇÃO	17
1.1. Descrição do problema	17
1.2. Objetivos.....	19
1.3. Justificativa	20
1.4. Estrutura da tese	21
CAPÍTULO 2: CIÊNCIA DA INFORMAÇÃO E INTELIGÊNCIA COMPUTACIONAL – CONCEITOS E ESTADO DA ARTE	23
2.1. A Ciência da Informação	24
2.1.1. Interdisciplinaridade.....	25
2.1.2. A informação	27
2.1.3. A recuperação da informação	34
2.1.4. Os sistemas de recuperação de informação.....	35
2.1.5. Categorização e classificação.....	36
2.1.6. Técnicas bibliométricas	40
2.2. Inteligência Artificial.....	45
2.2.1. O sistema nervoso e a consciência	46
2.2.2. Histórico de redes neurais artificiais	48
2.2.3. Características das redes neurais artificiais.....	49
2.2.4. Principais arquiteturas de redes neurais artificiais.....	50
2.2.5. Tipos de aprendizado	52
2.3. Redes neurais artificiais na recuperação de informação	53
2.4. Redes neurais artificiais em processos de categorização e classificação	57
CAPÍTULO 3: METODOLOGIA	61
3.1. Classificação da pesquisa	61
3.2. Etapas metodológicas.....	61
3.2.1. Desenvolvimento da base de testes e do protótipo.....	63
3.2.2. Criação das categorias	65
3.2.3. Identificação das características comuns aos grupos.....	66
3.2.4. Utilização de um software de categorização baseado em palavras-chave	68
CAPÍTULO 4: DESENVOLVIMENTO DA BASE DE TESTES	69
4.1. Validação da proposta por meio de um protótipo.....	69
4.2. Criação da base de dados <i>JASIST</i>	73
4.3. Criação da base de dados <i>IEEE</i>	75
4.4. Pré-processamento da base de dados	76
4.4.1. Eliminação das inconsistências dos dados.....	76
4.4.2. Preparação do arquivo de entrada da RNA	79
CAPÍTULO 5: ANÁLISE DAS CARACTERÍSTICAS COMUNS ÀS CATEGORIAS	86
5.1. Apresentação e análise dos resultados do experimento 1	86
5.2. Apresentação e análise dos resultados do experimento 2	131
5.3. Apresentação e análise dos resultados do experimento 3	153
5.4. Apresentação e análise dos resultados do experimento 4	160

5.5. Comparação entre os experimentos.....	163
CAPÍTULO 6: CONCLUSÃO	166
6.1. Propostas de trabalhos futuros	168
6.2. Considerações Finais.....	169
REFERÊNCIAS.....	171
APÊNDICE A - PROGRAMAÇÃO DO MATLAB E RESULTADOS OBTIDOS PARA O PROTÓTIPO	180
APÊNDICE B - PROGRAMAÇÃO DO MATLAB PARA A CRIAÇÃO DE 10 CATEGORIAS NO EXPERIMENTO 2	182
APÊNDICE C - TABELA DE ARTIGOS.....	187
APÊNDICE D - SAÍDA DA RNA PARA A TOPOLOGIA DE 4 CATEGORIAS NO EXPERIMENTO 1	221
APÊNDICE E - DISTRIBUIÇÃO DOS ARTIGOS NA SAÍDA DA RNA NO EXPERIMENTO 3.....	223
APÊNDICE F - LISTA DE PALAVRAS-CHAVE EM ORDEM ALFABÉTICA	225

CAPÍTULO 1: INTRODUÇÃO

O cérebro está permanentemente à procura de padrões e semelhanças no mundo que o cerca, em um esforço contínuo de ordenar tudo com que interage. Há uma tendência natural para agrupar os objetos, selecionando-os por suas propriedades comuns e, deste modo, entender com mais clareza o ambiente que o rodeia. Os processos de categorização e de classificação são naturalmente executados pelo ser humano na busca de uma ordenação que o faça interpretar e entender melhor o mundo.

Grupos de documentos, por exemplo, podem ser separados de acordo com características que têm em comum, possibilitando a identificação de um atributo comum que reúne e organiza uma determinada coleção. Esta pesquisa versa sobre a categorização automática de documentos e utiliza, neste processo, Redes Neurais Artificiais (RNA).

Este capítulo apresenta o problema abordado, os objetivos propostos, a justificativa para o desenvolvimento deste trabalho e a estrutura utilizada para a sua apresentação.

1.1. Descrição do problema

Com a participação crescente da *Web* na vida dos usuários dos sistemas computacionais, o interesse pelo desenvolvimento de ferramentas de categorização que pudessem organizar uma coleção de documentos disponível em meio digital tornou-se cada vez maior. Uma possibilidade de organização consiste em separar os documentos de acordo com as características que têm em comum, criando categorias caracterizadas por um atributo comum aos integrantes dos grupos.

O cérebro humano é capaz de localizar propriedades comuns de uma pequena amostra de textos e criar grupos a partir de uma coleção de documentos. À medida que a coleção se torna significativamente maior, tanto a separação de documentos por características comuns quanto a indexação de textos utilizando descritores torna-se inviável. Para os computadores, localizar palavras comuns é um procedimento simples e algumas palavras especiais são, em alguns casos, suficientes para distinguir certo documento de outro, ignorando os contextos em que estas palavras estão inseridas (LENSU; KOIKKALAINEN, 1999). Refinando ainda mais este processo, na tentativa de capturar o contexto, a categorização de documentos pode ser realizada extraindo-se as principais ideias de tais

documentos (PHUC; HUNG, 2008) ou, ainda, extraindo frases que possam substituir um conjunto de palavras (BAKUS; HUSSIN; KAMEL, 2002).

Muitos dos sistemas tradicionais de recuperação de informação possuem interfaces que apresentam regras rígidas de utilização e exigem dos usuários o domínio do vocabulário da área de pesquisa (KURAMOTO, 1996). Além desta necessidade de se estabelecer uma palavra que permita o acesso à informação, segundo Kuramoto (2002), a utilização das palavras como representação temática dos documentos pode apresentar problemas relacionados às propriedades linguísticas destas palavras. Algumas das dificuldades encontradas são enumeradas a seguir:

- Polissêmia: palavras que têm diferentes significados. Exemplo: chave (solução de um problema ou ferramenta para abertura de portas);
- Sinonímia: duas palavras designando o mesmo significado. Exemplo: abóbora e jerimum;
- Combinação de palavras em ordem diferente: a ordem pode alterar o sentido da expressão. Exemplo: crimes, juvenis e vítimas podem gerar a expressão vítimas de crimes juvenis ou vítimas juvenis de crimes.

Kuramoto discute, ainda, o processo de representação do documento, reportando-se às antigas bases de dados bibliográficas:

Antes do surgimento das novas tecnologias da informação e da comunicação, o processo de elaboração da representação de um documento nas antigas bases de dados bibliográficas era realizado por técnicos de informação especializados em indexação. Esses indexadores trabalhavam com o auxílio de vocabulários controlados, tesouros, outras tabelas ou listas que forneciam os descritores adequados à elaboração da representação de cada documento. Com o alto incremento do registro da informação, em meio magnético, tornou-se inviável a utilização de indexadores para a construção da representação de documentos em uma base de dados. A solução foi criar mecanismos de indexação automática, os quais se baseiam na extração de palavras (KURAMOTO, 2002).

Kuramoto (2002) concluiu que as palavras substituem inadequadamente os descritores porque ao serem extraídas de um texto deixam de ter o valor atribuído pelo autor ao redigir o documento. O descritor torna-se uma unidade da língua, um vocabulário de designação genérica e deixa de ser, como desejado, uma unidade do discurso, relacionada à

realidade do autor. Todas estas dificuldades discutidas influenciam o resultado de uma busca em um Sistema de Recuperação de Informação (SRI) que utilize a indexação dos documentos por meio de palavras-chave.

Com o crescimento das coleções de documentos digitais, o interesse em organizar automaticamente as informações disponíveis tem aumentado. O gigantismo das coleções de documentos eletrônicos motivou o desenvolvimento de ferramentas e técnicas que auxiliam o usuário na organização destas coleções (HUSSIN; KAMEL, 2003).

A proposta deste trabalho foi categorizar documentos sem utilizar palavras como unidades de representação de documentos. Este trabalho propôs um método de categorização de documentos, que pode se tornar uma alternativa ao processo de organização e recuperação da informação que utiliza descritores de assunto. Como as citações bibliográficas são, reconhecidamente, uma fonte importante para a indicação de grupos que se relacionam e que definem o crescimento da pesquisa em uma determinada área de conhecimento, avaliou-se a utilização das citações listadas nos documentos como atributo no método de categorização. Segundo Alvarenga (1998), os artigos relacionados por suas citações podem estabelecer relações semânticas entre si, mesmo não utilizando palavras como representação temática destes documentos. Para categorizar os artigos foram utilizadas RNA. A principal RNA utilizada na categorização de documentos foi a rede *Self-Organizing Map* (SOM), que é uma rede neural não supervisionada, que produz mapas em sua saída a partir dos dados alimentados em sua entrada.

1.2. Objetivos

Esta pesquisa propôs a criação de um método para a categorização de documentos de acordo com as referências que têm em comum. Como as citações são uma importante fonte de informação sobre o relacionamento existente entre os documentos, os artigos foram categorizados utilizando-as como atributo.

O objetivo geral do trabalho foi verificar a viabilidade do uso de RNA para categorizar documentos, utilizando as referências bibliográficas citadas.

Foram definidos os seguintes objetivos específicos:

- Desenvolver um protótipo para testar o método;
- Comparar o desempenho do método de categorização proposto, baseado em citações, com outro baseado em descritores.

Entende-se por método um conjunto de passos determinados e organizados dentro de um procedimento pré-estabelecido para se atingir um objetivo.

1.3. Justificativa

As citações são, reconhecidamente, uma fonte importante para a indicação de grupos de trabalhos que se relacionam. Partindo-se do pressuposto de que os artigos poderiam ser agrupados, utilizando-se como atributos as referências indicadas em sua produção e que as categorias geradas poderiam gerar grupos de documentos fortemente relacionados por suas referências, foi proposto um método de categorização de artigos que utilizava RNA. A principal questão a ser discutida neste projeto foi “as RNA são uma ferramenta viável no processo de categorização de documentos que utiliza como atributo as referências citadas na produção destes documentos?”.

A proposta deste trabalho foi gerar uma alternativa à utilização de palavras como unidades de representação de documentos e aperfeiçoar, aplicando RNA e utilizando conceitos desenvolvidos em bibliometria, os métodos de categorização de documentos. Os atributos utilizados para a categorização dos documentos foram as referências bibliográficas citadas nos documentos.

Na bibliometria, muitas pesquisas se dedicam ao estudo estatístico da biblioteconomia e utilizam indicadores de uso de publicações. São propostas que desenvolvem avaliações quantitativas do fluxo da informação. Sob o ponto de vista de uma publicação, a análise de sua citação ao longo do tempo pode identificar as tendências e o desenvolvimento de uma área específica do conhecimento ou, ainda, constatar a dispersão e o desuso de uma linha de pesquisa.

O Acoplamento Bibliográfico, definido como a união de artigos que citam os mesmos documentos, e a Co-citação, caracterizada pela união de artigos citados pelos mesmos documentos, são exemplos de estudos que evidenciam a importância das citações comuns na identificação de grupos de artigos que apresentam uma ligação forte entre si.

Os resultados quantitativos e as análises qualitativas de algumas pesquisas confirmam o fato de que as citações podem ser utilizadas na categorização de documentos, agrupando documentos com características específicas de uma área de conhecimento.

As citações das referências, presentes no corpo dos documentos, permitem avaliar a rede de influência existente entre os autores que contribuem, efetivamente, para o curso evolutivo de uma determinada disciplina (LEAL, 2005). Ziman, citado por Leal (2005),

chama de “árvores de citação” o modelo que relaciona os trabalhos uns aos outros, como se fossem nós de uma rede, de onde partem ramificações que os conectam a vários trabalhos anteriores e posteriores. Segundo Alvarenga (1998), os artigos relacionados por suas citações podem estabelecer relações semânticas entre si. Neste caso, se for realizada a categorização dos artigos, basicamente, por análises quantitativas, as classes obtidas podem ser, também, avaliadas sob o ponto de vista semântico. Agrupar artigos utilizando as referências bibliográficas citadas pode levar à identificação de grupos de autores que se dedicam ao estudo de áreas de conhecimento relacionadas e de tendências de pesquisa em específicos domínios de conhecimento.

Na literatura, podem ser encontradas algumas ferramentas de Inteligência Artificial utilizadas em processos de categorização. A capacidade do cérebro de armazenar conhecimento e reorganizar as conexões já estabelecidas vem inspirando pesquisadores a aprimorar o desenvolvimento de uma delas, as RNA. A neuroplasticidade, que é a capacidade do sistema nervoso de organizar-se frente ao aprendizado e à lesão, está ligada ao processo de categorização discutido neste trabalho. Associar o conceito de neuroplasticidade às RNA na busca de um método de categorização de documentos foi a principal motivação na definição da ferramenta utilizada na pesquisa.

1.4. Estrutura da tese

O Capítulo 2 apresenta a fundamentação teórica deste trabalho, que se baseou em técnicas bibliométricas, categorização e Inteligência Artificial, ressaltando a utilização de RNA em processos de recuperação de informação e de categorização de documentos.

O Capítulo 3 mostra a metodologia utilizada. A primeira etapa metodológica descreve o desenvolvimento do protótipo e da base de testes. A segunda etapa apresenta os passos utilizados na criação das categorias. A terceira etapa mostra como foram identificadas as características comuns a cada um dos grupos gerados nos três experimentos realizados com a RNA. A quarta etapa compara os resultados obtidos com os gerados por um *software* de categorização baseado em palavras-chave.

O Capítulo 4 discute os passos de desenvolvimento da base de testes, destacando a validação da metodologia por meio do protótipo, a criação das bases utilizadas e o pré-processamento da base de testes final, eliminando-se as inconsistências dos dados e preparando o arquivo para a entrada da RNA.

O Capítulo 5 analisa as características comuns às categorias geradas, descrevendo e analisando os resultados obtidos nos quatro testes realizados, três destes com a RNA e o último baseado em descritores.

O Capítulo 6 apresenta a conclusão do trabalho. Os apêndices mostram os códigos de processamento utilizados para a categorização do protótipo e da base de testes final, a tabela contendo as informações dos artigos utilizados, um exemplo do arquivo de saída da RNA, os resultados gerados no experimento 3 e a lista de palavras-chave dos artigos, em ordem alfabética, utilizada no último teste.

CAPÍTULO 2: CIÊNCIA DA INFORMAÇÃO E INTELIGÊNCIA COMPUTACIONAL – CONCEITOS E ESTADO DA ARTE

Segundo Searle (1984), a descontinuidade entre as ciências sociais e as ciências naturais não procede do fato de que existe uma conexão disjuntiva dos fenômenos sociais e físicos, nem tampouco do fato de que as disciplinas sociais não têm conceitos constitutivos que provenham da física ou, ainda, de que há uma grande complexidade na vida social. A descontinuidade deriva do caráter mental dos fenômenos sociais e psicológicos e estaria, neste fato, a fonte de sua fraqueza e, também, a fonte de sua força como ciências sociais.

Em disciplinas de áreas como a Filosofia, a Psicologia e a Inteligência Artificial encontram-se identificadas algumas analogias entre o funcionamento do cérebro humano e o funcionamento dos computadores digitais. Na busca de resultados que simulem o funcionamento do cérebro, é importante destacar que a natureza das operações realizadas é puramente sintática e desconsidera aspectos relacionados à consciência, aos pensamentos, aos sentimentos e às emoções. A mente possui mais do que uma estrutura formal, que reproduz a relação lógica das frases ou de comandos e instruções de um programa de computador. O que desafia os cientistas que se dedicam às pesquisas da área é a capacidade semântica do cérebro, que, além das relações sintáticas, associa significado aos símbolos.

Nenhum programa de computador pode representar um modelo completo da mente. Os neurônios presentes no cérebro humano e sua rede de conexão formada por axônios e sinapses podem ser descritos em nível neurofisiológico, mas, nesta descrição, não são consideradas a disposição psíquica e a emoção de uma pessoa geradas por sua capacidade pessoal e por sua percepção do mundo.

Esta busca pela compreensão do ser, comparável à compreensão que as ciências naturais apresentam para o resto da natureza, inspirou o trabalho realizado para se construir as chamadas máquinas inteligentes. Neste contexto, que associa as práticas da Ciência da Informação (CI) às técnicas da Inteligência Artificial é que são discutidos, nas próximas seções, os processos de categorização e classificação como fundamento dos sistemas de organização do conhecimento. A fundamentação teórica do trabalho é apresentada, então, em quatro grandes seções, quais sejam, “A Ciência da Informação”, “Inteligência Artificial”, “Redes Neurais Artificiais na Recuperação de Informação” e “Redes Neurais Artificiais em processos de categorização e classificação”.

Na primeira seção, “A Ciência da Informação”, são abordadas grandes áreas de estudo da CI, quais sejam, “Interdisciplinaridade”, “A Informação”, “A Recuperação da Informação”, “Os Sistemas de Recuperação de Informação”, “Categorização e Classificação” e “Técnicas Bibliométricas”.

A seção “Inteligência Artificial” apresenta o “O sistema nervoso e a consciência”, “Histórico das Redes Neurais Artificiais”, “Características das Redes Neurais Artificiais”, “Principais Arquiteturas de Redes Neurais Artificiais” e “Tipos de Aprendizado”.

2.1. A Ciência da Informação

Um campo, segundo Saracevic (1996), é definido pelos problemas discutidos e pelos métodos que utiliza para solucioná-los. Desta maneira, três são as características que constituem a razão da existência e da evolução da CI. A primeira delas é a sua natureza interdisciplinar. As relações com a Ciência da Computação, com a Inteligência Artificial e com a Ciência Cognitiva estão se tornando mais visíveis em aplicações. A segunda característica refere-se à sua ligação com a tecnologia da informação. E a terceira característica ressalta o fato da CI, por ser descrita por uma forte dimensão social e humana, ser uma participante ativa na evolução da sociedade da informação (SARACEVIC, 1996).

Segundo Le Coadic (1996), são quatro as disciplinas atuantes no campo da informação, quais sejam a biblioteconomia, a museologia¹, a documentação e o jornalismo, que dedicaram seu maior interesse aos suportes da informação. A documentação surgiu a partir da necessidade, identificada no final do século XIX, da utilização de novas técnicas para organizar, analisar e descrever os documentos. Os meios disponíveis, nas bibliotecas, já se tornavam pouco eficazes para acessar os variados tipos de documentos armazenados.

A CI é, reconhecidamente, uma ciência voltada para a demanda social de informação e insere-se no campo das ciências sociais aplicadas. Os estudos científicos, inicialmente realizados por pesquisadores de áreas como psicologia, sociologia, economia, informática e telecomunicações, em muito contribuíram para a sua cientifização (LE COADIC, 1996).

¹ A tradução da obra de Le Coadic (1996) menciona o termo “museoconomia”.

Borko foi o responsável pela definição clássica da CI:

Ciência da Informação é uma disciplina que investiga as propriedades e o comportamento da informação, as forças que regem o fluxo de informações, e os meios de processamento de informação para otimizar sua acessibilidade e sua usabilidade. Ela está ligada ao corpo de conhecimentos relacionados com a origem, coleta, organização, armazenamento, recuperação, interpretação, transmissão, transformação e uso da informação. Isto inclui a investigação de representações de informação em ambos os sistemas natural e artificial, o uso de códigos para a transmissão da mensagem eficiente, e o estudo de dispositivos de processamento de informações e técnicas, tais como computadores e seus sistemas de programação (BORKO, 1968, p.3).

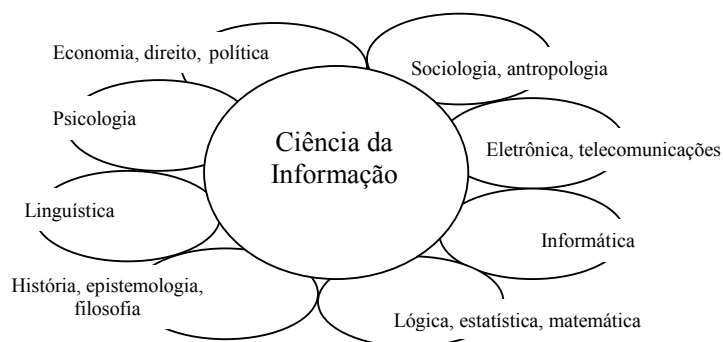
A CI vem dedicando grande interesse, em seus trabalhos de pesquisa, à solução ou melhoria de aspectos relacionados ao problema de organização e recuperação de informação.

2.1.1. Interdisciplinaridade

Borko (1968), ao definir a CI, ressalta seu caráter interdisciplinar, relacionando-a a áreas como matemática, lógica, linguística, psicologia, informática, pesquisa operacional, artes gráficas, comunicação, biblioteconomia e administração. Destaca, também, a sua capacidade de investigar tanto conteúdos teóricos como aplicativos derivados de assuntos discutidos por seus profissionais.

Le Coadic (1996) define a interdisciplinaridade como sendo uma colaboração entre disciplinas, que permite interações e enriquecimento entre os campos de conhecimento envolvidos. Ressalta que a CI é uma interdisciplina, onde colaboram entre si, principalmente, a psicologia, a linguística, a sociologia, a informática, a matemática, a lógica, a estatística, a eletrônica, a economia, o direito, a filosofia, a política e as telecomunicações como é ilustrado pela Figura 1.

Figura 1 - A formação interdisciplinar da Ciência da Informação



Fonte: adaptado de LE COADIC, 1996

Segundo Pinheiro e Loureiro (1995), a CI possui, em sua configuração estrutural, um caráter eminentemente interdisciplinar, e, ainda que hoje coexistam múltiplas reflexões, não se pode negligenciar que o espectro dos conhecimentos envolvidos em CI se estende por todos os campos científicos.

Pinheiro (2006) apresenta duas afirmações para justificar a interdisciplinaridade da CI. A primeira é que seus problemas não podem ser resolvidos por abordagens de uma única disciplina. E a segunda afirmação é que a interdisciplinaridade foi introduzida na área pelas diferenças de formação e áreas de origem das pessoas que discutem os temas da CI.

Alguns autores descrevem conceitos próximos ao de interdisciplinaridade para estabelecer conexões entre as disciplinas. As abordagens multi, inter e transdisciplinar, segundo Bicalho e Oliveira (2011), parecem indicar novos caminhos empenhados em fortalecer os fundamentos disciplinares da CI. Segundo estas autoras, a multidisciplinaridade é um conceito associado à integração de conhecimentos de várias disciplinas no estudo de um objeto de uma única disciplina. A interdisciplinaridade ocupa posição intermediária entre a multi e a transdisciplinaridade. Este último conceito refere-se às situações de conhecimento que vão além das disciplinas, superando-se as fronteiras, trabalhando-se nas interfaces e envolvendo a migração de um conceito de um campo de saber para outro. Em seu trabalho, as autoras esclarecem que estas diferentes abordagens do conhecimento científico não são excludentes, mas, muitas vezes, complementares em diferentes etapas do processo investigativo.

Na história da ciência, de acordo com Gomes (2001), as rupturas das fronteiras disciplinares ocorrem quando a discussão de um tema conduz ao desenvolvimento de um projeto interdisciplinar, por meio do qual as disciplinas envolvidas trocam teorias e conceitos, alcançando uma cooperação, a partir da qual não apenas os sujeitos envolvidos tornam-se

especialistas com múltiplas competências, mas, as próprias gramáticas dessas disciplinas são alteradas, interferindo na formação de futuros especialistas dessas áreas.

Segundo Pombo (2004), assim como passamos de uma ciência predominantemente analítica para uma ciência que se comporta de modo transversal, vive-se a necessidade de ampliar o conceito de interdisciplinaridade e discutir as questões sob a perspectiva interdisciplinar. O mundo atual é cada vez mais um mundo sem fronteiras e, a cada dia, se distancia de um modelo cartesiano e se aproxima de uma rede altamente conectada e complexa.

A natureza deste trabalho veio ao encontro desta discussão por ser este um projeto interdisciplinar que utilizou os conceitos da CI, as ferramentas e conceitos da Inteligência Artificial bem como o campo da Ciência Cognitiva abordado no processo de categorização.

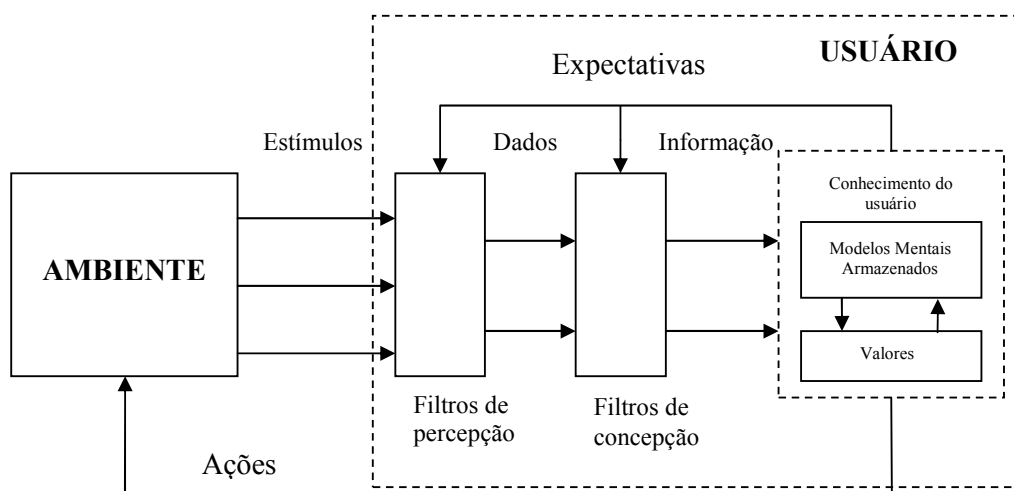
2.1.2. A informação

O conceito de informação é central dentro da abordagem da CI e, exatamente porque é discutido dentro de um contexto interdisciplinar, é comum ser definido por profissionais de diferentes formações.

Segundo Le Coadic (1996, p.5), “a informação é um significado transmitido a um ser consciente por meio de uma mensagem inscrita em um suporte espacial temporal.” Essa inscrição é realizada utilizando-se signos, que podem ser caracterizados como elementos da linguagem cuja função é associar um significado a um significante.

Para introduzir esta discussão, é importante definir, também, outros dois termos intimamente relacionados, quais sejam, dado e conhecimento. Segundo Boisot e Canais (2004), as principais relações existentes entre dados, informações e conhecimento podem ser resumidas no diagrama apresentado a seguir na Figura 2.

Figura 2 - Relações entre dado, informação e conhecimento



Fonte: BOISOT; CANAIS, 2004

O diagrama mostra que o usuário controla dois tipos de filtros para converter os estímulos recebidos do meio externo em informação. Os filtros de percepção recebem os estímulos externos e orientam os sentidos dentro de uma faixa física característica de cada usuário. Apenas os estímulos que passam por este filtro são registrados como dados. Os filtros de concepção extraem informação do que foi registrado como dado na saída do filtro de percepção. Segundo os autores, os filtros são acionados pelas expectativas cognitivas e afetivas do usuário, que são geradas por seu conhecimento anterior. Este conhecimento é baseado em modelos mentais armazenados e valores adquiridos e construídos em sua vida e é responsável, em uma instância superior, pela seleção tanto dos estímulos que serão transformados em dados como dos dados que serão transformados em informação. Este mesmo conhecimento permite que o usuário interfira, por meio de ações, no ambiente a sua volta. Em linhas gerais, os dados carregam informação codificada do mundo físico. A informação pode modificar o estado de conhecimento do usuário, provendo-lhe de elementos e condições para agir sobre o mundo físico.

Para Turban, Rainer Jr. e Potter (2007), dentro de uma organização, dados, informações e conhecimento podem ser assim definidos:

Dados se referem a uma descrição elementar de coisas, eventos, atividades e transações que são registrados, classificados e armazenados, mas não são organizados para transmitir qualquer significado específico.

A informação se refere a dados que foram organizados de modo a terem significado e valor para o receptor.

O conhecimento consiste em dados e/ou informações que foram organizados e processados para transmitir entendimento, experiência, aprendizagem acumulada e prática aplicados a um problema ou atividade atual. (TURBAN; RAINER JR.; POTTER, 2007, p.3)

Estes autores ilustram estas definições, utilizando o exemplo das notas de um aluno em uma disciplina. Neste caso, as notas do aluno são dados. O nome do aluno associado à sua nota é uma informação. Se for identificado que os alunos com média acima de um determinado percentual são mais bem sucedidos em algum programa específico de gerenciamento, este é um conhecimento adquirido pela experiência de pessoas envolvidas neste processo.

Segundo Setzer (2001), dado é uma sequência de símbolos quantificados, caracterizando-se, assim, como uma entidade matemática e puramente sintática. A informação é uma abstração informal e semântica, que associa significado ao dado. Já o conhecimento é uma abstração pessoal de algo que foi vivenciado por alguém, estando em um âmbito subjetivo. Como o conhecimento não é sujeito a representações formais ou estruturais, não pode ser armazenado em um computador. A informação pode ser armazenada no computador se sua representação for feita por meio de dados. Setzer associou o conhecimento à pragmática, que é o ramo da linguística que estuda a linguagem no contexto do seu uso na comunicação, indo além da construção da frase, na sintaxe, ou do seu significado, na semântica.

Le Coadic (1996), ao relacionar conhecimento e informação, afirma que nosso estado de conhecimento sobre determinado assunto é representado por uma estrutura de conceitos relacionados, formada pela imagem que cada indivíduo tem do mundo. Ao constatar uma deficiência, uma imperfeição ou uma anomalia desse estado de conhecimento, o indivíduo encontra-se em um estado anômalo de conhecimento. A premissa básica provém da consideração de que o usuário busca a informação por reconhecer uma anomalia em seu estado de conhecimento, sendo, no entanto, incapaz de identificar o que é necessário para resolver esta anomalia (BELKIN; ODDY; BROOKS, 1982). Esta é uma situação de desconforto e instabilidade que motiva o indivíduo a buscar novas informações e, ao ter acesso a elas, o indivíduo altera o seu estado de conhecimento.

Brookes (1980) define a informação como uma pequena parte da estrutura representada pelo conhecimento e representa a relação entre informação e conhecimento pela equação que denominou Equação Fundamental:

$$K[S]+\Delta I = K[S+\Delta S]$$

onde:

$K[S]$: estrutura de conhecimento;

$K[S+\Delta S]$: estrutura modificada de conhecimento;

ΔI : informação;

ΔS : efeito da modificação.

Segundo Brookes (1980), a equação é uma forma pseudo-matemática de representar esta relação e o modo mais compacto de expressar esta ideia, revelando o pouco que se conhece sobre o crescimento do conhecimento. Brookes ressalta que, se as variáveis são mensuráveis e se estão relacionadas por uma equação, devem ser medidas pelas mesmas unidades. Se a informação é, portanto, medida como o conhecimento, a variação da informação pode ser substituída pela variação de conhecimento. Brookes, no entanto, sugere que se mantenha a equação em seu formato original por entender que a mesma informação pode ter diferentes efeitos em diferentes estruturas do conhecimento. Assim como Boisot e Canais (2004), que sugerem que existem filtros de concepção, acionados pelo conhecimento, para extrair informação do que foi registrado como dado, esta equação também enfatiza que o dado deve ser subjetivamente interpretado por uma estrutura de conhecimento para se tornar informação.

A equação mostra, ainda, que o efeito gerado pela absorção da informação em uma estrutura de conhecimento não é simplesmente uma operação de adição. O que se observa é que a estrutura é reajustada, alterando-se as relações que ligam dois ou mais conceitos. Pereira (2008) interpreta a equação como sendo a expressão da passagem de um estado de conhecimento anômalo para um novo estado de conhecimento, devido à contribuição de um novo conhecimento, extraído de uma informação.


Na teoria matemática da comunicação (SHANNON, 1948), a informação é a medida da liberdade para o usuário escolher quando está diante do processo de selecionar uma mensagem. Boisot e Canais (2004) também discutem esta possibilidade de seleção, propondo, como apresentado anteriormente, a existência de dois filtros. Estes filtros são acionados por

expectativas geradas pelo usuário, contribuindo para a formação do que será para ele, dado e, posteriormente, informação.

Brookes (1980) comenta, ao descrever os Fundamentos da CI, que Shannon, modelando a transmissão de sinais codificados, incute dinamismo ao que, até então, havia sido relatado como uma teoria puramente estática. Shannon mede a informação em termos logarítmicos e sua teoria é aplicada a sistemas de telecomunicações, a computadores ou a qualquer sistema que transmita ou processe informação objetiva. Segundo Brookes (1980), a teoria de Shannon é capaz de relatar as transações entre os mundos II e III, definidos por Popper. Os três mundos de Popper, mesmo definidos distintamente e caracterizados de modo independente, se relacionam. O mundo I é o físico e, segundo Brookes, a teoria de Shannon é capaz de medir as transações entre o mundo II, o mundo do conhecimento humano subjetivo, e o mundo III, o mundo do conhecimento objetivo, produto da mente humana e armazenado em linguagens, artes, ciências e tecnologias. Brookes enfatiza que sua Equação Fundamental se aplica tanto às estruturas de conhecimento objetivo quanto às de conhecimento subjetivo e que o desafio dos pesquisadores é aprender como estruturar informação objetiva em conhecimento objetivo.

Para que possa ser percebida, compreendida e utilizada, a informação deve ser, previamente, ordenada, estruturada ou formatada. Deve haver um meio de transmissão cujas características possam identificá-lo como meio de transmissão de informação, diferenciando-o dos fenômenos que cercam o receptor. McGarry (1999) identificou três classes de meios de transmissão de informação, quais sejam, os sinais, os signos e os símbolos. Os sinais podem ser descritos como signos seguidos por algum tipo de ação que desencadeiam alguma reação do receptor. Os signos são um indício físico de que um evento vai ser realizado imediatamente depois. Os símbolos representam um evento e se caracterizam por causar, no receptor, a mesma reação que o evento causaria. No trânsito, por exemplo, os motoristas utilizam sinais ao dirigir o carro, comunicando que alguma ação será realizada. O medidor de temperatura é um signo que pode indicar que existem problemas de aquecimento no veículo. O triângulo no código de trânsito é um símbolo que indica que o motorista deve dar a preferência ao veículo que circula na outra via. São representações, culturalmente construídas e aceitas, que dependem do grupo social que as utiliza. A Figura 3 relaciona os meios de transmissão de informação.

Figura 3 - Meios de transmissão de informação



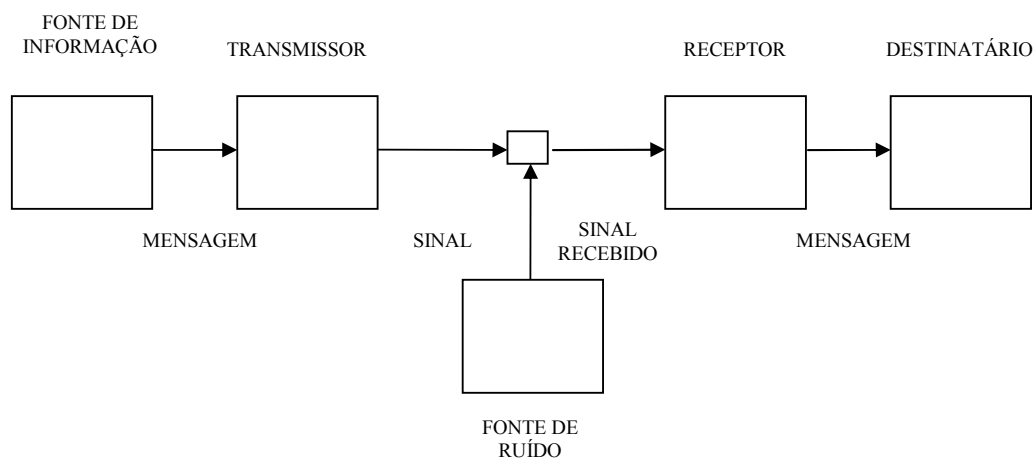
Os símbolos, como meio de transmissão da informação, devem representar o evento, causando no receptor a reação que o evento causaria.

A mensagem e o sinal podem ser uma sequência de símbolos discretos ou contínuos. Um exemplo de símbolos discretos é utilizado quando o usuário se depara com uma situação na qual se tem duas mensagens alternativas para escolher. O transmissor poderá, então, codificar duas mensagens de modo que “zero” seja o sinal para a primeira e “um”, o sinal para a segunda mensagem. Neste caso, as variáveis são qualitativas e assumem apenas valores 0 ou 1, indicando a ocorrência ou não de um evento ou a presença ou a ausência de uma condição. Estas variáveis são, também, conhecidas como variáveis *dummy*. Esta unidade de informação é denominada *bit*, que é uma abreviação de *binary digit* ou dígito binário. Quando os números são expressos no sistema binário há somente dois dígitos, 0 ou 1, cada um deles responsável pela transmissão de mensagens distintas.

2.1.2.1. Os Processos de Comunicação

Para Araujo (1995), sistemas de informação são aqueles que, de maneira genérica, objetivam a realização de processos de comunicação. Um diagrama de um processo de comunicação, denominado por Shannon (1948), um sistema de comunicação, pode ser visto na Figura 4.

Figura 4 - Diagrama de um processo de comunicação




Fonte: SHANNON, 1948

O diagrama descrito na Figura 4 é constituído de cinco partes. A fonte de informação produz a mensagem ou a sequência de mensagens para ser comunicada ao terminal de recepção. Um transmissor opera a mensagem para produzir um sinal adequado para transmissão através do canal. O canal é o meio utilizado para transmitir o sinal do transmissor para o receptor. O receptor realiza a operação inversa do transmissor, reconstruindo a mensagem a partir do sinal. A mensagem é direcionada ao destinatário.

Não se pode desprezar a fonte de ruído presente no canal de transmissão da mensagem. Segundo Nicolelis (2011), “o ruído de fundo numa enxurrada de dados, não importa quão insignificante ele possa soar a princípio, às vezes, contém a mais essencial de todas as mensagens”.

Ao simplificar, na apresentação da Figura 5, a teoria da informação proposta por Shannon (1948), Le Coadic (1996) expõe sua crítica ao modelo gerado e à utilização de analogias presentes em contextos interdisciplinares. Ao avaliar que a inserção de itens como canal, código, ruído e realimentação aprimorou a relação antes apresentada linearmente entre informador e informado, ressalta que a relação proposta não caracterizou um modelo de comunicação social inserido em um processo de comunicação humana. A teoria considerou a comunicação entre máquinas e não destacou o fato de que a comunicação é um processo intermediário que permite a troca de informações entre pessoas.

Figura 5 - Diagrama da Teoria da Informação



Fonte: LE COADIC, 1996

Le Coadic (1996) afirma que, da prática de organização, presente em disciplinas como a documentação, a CI tornou-se uma ciência social rigorosa apoiada em uma tecnologia rigorosa. Além de ter como objetivo o estudo dos processos de construção, comunicação e uso da informação, concebe, avalia e controla os sistemas de informação compostos por coleções de documentos.

2.1.3. A recuperação da informação

Vannevar Bush, durante a segunda guerra mundial, definiu as incipientes tecnologias de informação da época como a solução para o problema da explosão informacional, particularmente vivenciada pelos registros documentais científicos e tecnológicos (SARACEVIC, 1996). Das questões relacionadas à recuperação destas informações, segundo Saracevic, “surgiram conceitos e construtos teóricos, empíricos e pragmáticos, bem como numerosas realizações práticas”. Sistemas, técnicas e máquinas foram utilizados na recuperação da informação, transformando-a em um processo interativo partindo de “bases documentais para bases de conhecimento, de textos escritos à multimídia, da recuperação de citações à recuperação de textos completos, alcançando os sistemas inteligentes”.

A recuperação da informação é definida por Abadal e Codina (2005) como a disciplina que estuda a representação, a organização e o acesso eficiente à informação registrada em documentos. As operações associadas à recuperação de informação têm como objetivo solucionar os problemas que requerem informação científica, técnica e cultural e que surgem em, pelo menos, alguma etapa da vida de todos os seres humanos, na tentativa de descobrir, estudar, aprender ou investigar um tema.

As principais demandas dos usuários por serviços de informação, na busca pela solução dos seus problemas, recaem em duas grandes necessidades (LANCASTER; WARNER, 1993). A primeira é a necessidade de localizar e obter uma cópia de um

documento específico em que o autor ou o título são conhecidos. A segunda é a necessidade de localizar documentos que contenham um assunto particular ou que sejam capazes de responder a uma pergunta definida pelo usuário.

Com o crescimento do volume de publicações disponível em meio digital, muitas técnicas de recuperação de informação foram desenvolvidas para atender às necessidades dos usuários e muitos estudos estão sendo realizados com o objetivo de organizar as coleções de documentos. As possibilidades de acesso às bases de dados disponíveis eletronicamente permitiram aumentar a qualidade das buscas bibliográficas, mas, também, a quantidade de documentos recuperados. Selecionar os documentos que atendem à necessidade da busca vem se tornando um processo desafiador para o usuário. Organizar as publicações para, posteriormente, recuperá-las é uma tentativa de manter a qualidade da informação recuperada sem que possa ser comprometida pela quantidade cada vez maior de documentos disponíveis.

Como campo de estudo, segundo Abadal e Codina (2005), a teoria da recuperação de informação é interdisciplinar e especialistas procedentes de diversas áreas contribuem para o seu desenvolvimento.

2.1.4. Os sistemas de recuperação de informação

Segundo Turban, Rainer Jr. e Potter (2007), um sistema de informação coleta, processa, armazena, analisa e dissemina informações para um fim específico. Os SRI lidam, especificamente, com a informação que está potencialmente contida em documentos, que devem ser formalmente organizados, processados e recuperados com a finalidade de maximizar o uso da informação.

Segundo Souza (2006), um dos problemas centrais da recuperação de informações em SRI é a seleção dos documentos relevantes e a exclusão dos que não atendem a necessidade do usuário. Nos sistemas automatizados, existem inúmeras estratégias para indexar os documentos e definir pesos associados à necessidade da informação do usuário.

Os modelos de recuperação de informações podem ser divididos em três grupos, quais sejam, o modelo booleano, o modelo vetorial e o modelo probabilístico. O modelo booleano é baseado na teoria dos conjuntos. Para cada *query*, são recuperados todos os documentos que possuem os termos nas condições definidas pelo usuário. Sua maior desvantagem reside no fato de analisar o documento sob o ponto de vista binário, ou seja, o documento é considerado relevante ou não relevante para a consulta realizada. Há uma proposta estendida deste modelo que utiliza a lógica difusa ou lógica *fuzzy*. Nesta proposta,

são associados aos documentos valores intermediários entre zero e um, permitindo ao documento um grau de relevância intermediário, caracterizado pelo grau de associação do documento à busca.

A grande maioria dos SRI é baseada no modelo vetorial. Neste modelo, os documentos são representados como sacos de palavras, *bags of words*, e são representados como vetores no espaço n-dimensional, onde n é o total de termos índices de todos os documentos do sistema (SOUZA, 2006). Existem propostas estendidas deste modelo que utilizam a indexação semântica latente e as RNA. A primeira é um método que estabelece um espaço vetorial reduzido, onde cada dimensão corresponde a um termo e cada documento é representado por um somatório dos seus componentes, diminuindo as dimensões do espaço vetorial. Já as RNA apresentam a vantagem de recuperar documentos que podem não compartilhar nenhum termo-índice com a *query*.

O modelo probabilístico considera a interação contínua com o usuário uma solução para refinar o resultado da busca. Neste modelo, supõe-se que exista um conjunto ideal de documentos que satisfaça a consulta do usuário.

2.1.5. Categorização e classificação

Os processos de categorização e de classificação são processos de ordenamento das informações disponíveis para que, associadas a grupos, possam ser mais facilmente identificadas, nomeadas e recuperadas.

2.1.5.1. A Categorização

Historicamente, a noção de categoria tem sido abordada de modos diversos. Segundo Xavier (2008), o conceito de categorias, como discutido nos dias de hoje, nasceu com Aristóteles, que viveu entre os anos de 384 e 322 a.C.. Categorias é o primeiro dos cinco tratados que compõem Organon, a obra que expõe a lógica aristotélica. Admite-se que este seja o tratado que introduz o conteúdo de todos os outros quatro, Sobre a Interpretação, Analíticos Anteriores, Analíticos Posteriores e Tópicos.

De acordo com Xavier (2008), Aristóteles determinou dez gêneros supremos que constituem as Categorias: substância, quantidade, qualidade, relação, lugar, tempo, posição, posse, ação e paixão. Há quem afirme que Aristóteles não se limitou a esta tabela de categorias. Alguns dos seus discípulos defenderam a ideia de que o número de categorias

proposto pelo filósofo era indeterminado. Estas categorias, segundo Xavier (2008), possibilitavam a ordenação do pensamento, fornecendo elementos para a perfeita caracterização do objeto a ser estudado.

As categorias aristotélicas são, segundo Padre Leme e Lopes, citados por Piedade (1983), a base das categorias gramaticais. A associação entre algumas das categorias pode ser observada no Quadro 1.

Quadro 1 - Relação entre as categorias aristotélicas e as categorias gramaticais

CATEGORIAS ARISTOTÉLICAS	CATEGORIAS GRAMATICAIS	EXEMPLOS
Quantidade	Adjetivo quantitativo	O grande
Substância	Substantivo	Cavalo
Qualidade	Adjetivo qualitativo	Castanho
Relação	Pronome relativo, adjunto adnominal	do cavaleiro
Ação	Verbo na voz ativa	Está
Maneira de ser	Advérbio de modo	Arreiado
Duração (Tempo)	Advérbio de tempo	de manhã
Lugar	Advérbio de lugar	no pátio

Fonte: adaptado de PIEDADE, 1983

Como destaca Barite (2000), Shiyali Ramamrita Ranganathan levou o conceito da filosofia para a classificação do conhecimento e, para provar que as categorias são o fundamento de qualquer sistema de organização do conhecimento, ele construiu um sistema de classificação, a *Colon Cassification* (Sistema de Classificação de Dois Pontos), a partir de seus postulados teóricos. Ranganathan (1892-1972), matemático indiano que se tornou bibliotecário, foi um dos estudiosos, segundo Lima (2004), que mais contribuiu para a teoria da biblioteconomia no século XX. Apesar de o sistema de Classificação de Dois Pontos não ter sido aceito por unanimidade, o referencial teórico sobre a análise e síntese de facetas, que relacionava os termos, aplicando um princípio básico de divisão, transformou-se em uma base teórica importante para a análise de assunto. Seu sistema de Classificação de Dois Pontos, publicado em 1933 e republicado em 1957 e em 1967, surgiu de sua insatisfação com os sistemas de Classificação Decimal de Dewey (CDD) e Classificação Decimal Universal (CDU).

Piedade (1983) esclarece que Ranganathan estabeleceu cinco categorias fundamentais com as quais dividia todo e qualquer assunto: Personalidade, Matéria, Energia, Espaço e Tempo, conhecidas pela sigla PMEST, criando um referencial teórico importante no século XX. A categoria “Personalidade” é constituída dos objetos de estudo de uma determinada disciplina. A “Matéria” abrange os tipos de materiais e de substâncias de que são feitas as coisas. “Energia” está associada às ações, às reações, às atividades, aos processos e às técnicas. “Espaço” corresponde às divisões geográficas e o “Tempo”, às divisões cronológicas.

Segundo Lima (2010), foi Eleanor Rosch quem transformou a categorização em uma questão de pesquisa. Rosch desenvolveu seus trabalhos na década de 70 e criou o modelo de protótipo. Baseada na tese de que, no modelo clássico, as categorias são definidas somente pelas propriedades que todos os membros do grupo apresentam, Rosch concluiu que nenhum membro do grupo poderia exemplificar a categoria melhor do que o outro. O princípio fundamental do modelo de protótipo afirma, assim, que as categorias são organizadas em torno de protótipos centrais. De acordo com este modelo, conceitos são representados por um grupo de características e não por suas definições. O agrupamento de conceitos em uma dada categoria se daria pela semelhança com os protótipos, ou seja, aqueles membros da categoria que mais refletem a redundância da estrutura de uma categoria como um todo.

Rosch (1978) propôs dois princípios básicos para a geração de categorias. O primeiro princípio afirma que a função de um sistema de categorias é fornecer o máximo de informação com o menor esforço cognitivo possível. O segundo princípio caracteriza a estrutura da informação gerada e afirma que ela será tanto melhor e mais organizada quanto mais próxima estiver da estrutura que um observador percebe do mundo.

Outros pesquisadores discutiram os conceitos associados aos processos de categorização e classificação. Segundo Jacob (2004), categorização é o processo de dividir o mundo em grupos de entidades cujos membros têm similaridades entre eles dentro de um determinado contexto. Agregar as entidades em categorias leva o indivíduo a perceber ordem no mundo que o circunda. Segundo Barite (2000), as categorias são usadas como ferramentas para se descobrir certas regularidades do mundo material, concluindo-se que todos os objetos, pelo menos os que pertencem ao mundo material, possuem certas propriedades. Barite afirma, ainda, que as categorias são abstrações simplificadas usadas pelos classificacionistas para investigar regularidades de objetos do mundo físico e ideal e para representar noções.

2.1.5.2. A Classificação

A classificação é uma capacidade conceitual humana, que utiliza as categorias como ferramentas. Para Jacob (2004), o processo de classificação envolve a associação ordenada e sistemática de cada entidade a uma única classe dentro de um conjunto de classes mutuamente exclusivas e que não se sobrepõem. É um processo que estabelece ordem ao demonstrar relações entre entidades, tanto explicitamente por meio das definições utilizadas para associar os objetos às classes, quanto implicitamente ao se construir uma estrutura com um relacionamento hierárquico entre as classes.

O processo de classificar é realizado de acordo com um conjunto de princípios estabelecidos que governa a estrutura e o relacionamento das classes. Estes princípios são aplicados sistematicamente na busca de uma reprodução ordenada do mundo real. Segundo Jacob (2004), o processo é artificial, porque é criado com o propósito de estabelecer uma organização significativa, e é arbitrário, porque seleciona uma perspectiva única de domínio, excluindo as demais.

Segundo Alvarenga (2009), há similaridades entre o processo cognitivo de categorização e o processo formal da classificação lógica e, apesar de serem conceitos distintos, se confundem pelo fato de representarem mecanismos utilizados para se estabelecer ordem. A distinção fundamental entre os dois processos reside no modo pelo qual se utiliza o processo na busca do ordenamento.

Alvarenga (2009) ressalta que a classificação tradicional é rigorosa ao ordenar que uma entidade seja ou não membro de uma classe particular. O processo de categorização, no entanto, é flexível e criativo e cria associações não rígidas entre as entidades, baseadas em similaridades observadas dentro de um determinado contexto. A flexibilidade do processo se caracteriza pelo fato de que o contexto pode variar, alterando, assim, as percepções cognitivas do observador.

A classificação é, portanto, um processo posterior ao da categorização e caracteriza uma tentativa do ser humano de associar os objetos que o cercam a objetos já identificados como pertencentes a um grupo específico. Deste modo, os novos objetos são integrados às estruturas já definidas, para que estas estruturas sejam reorganizadas, facilitando a interação do ser humano com os objetos que o cercam e aperfeiçoando o entendimento das estruturas que compõem o mundo em que vive o observador.

2.1.6. Técnicas bibliométricas

A bibliometria se constitui de métodos matemáticos e estatísticos que estudam e analisam eventos relacionados a variáveis quantificáveis na produção escrita. Na produção escrita, existem elementos que se interconectam e podem ser avaliados do ponto de vista matemático. Com o crescimento da comunicação científica eletrônica, podem ser identificadas mudanças nos processos de comunicação, que devem ser consideradas na interpretação dos dados gerados pela avaliação quantitativa (BORGMAN; FURNER, 2002).

Sengupta (1992) definiu a bibliometria como a “organização, a classificação e a avaliação quantitativa dos padrões de publicação de toda a comunicação e autorias envolvendo cálculos matemáticos e estatísticos”. De uma maneira geral, Sengupta afirma que a bibliometria pode ser dividida em dois grandes grupos, a bibliometria descritiva e a bibliometria comportamental. O primeiro grupo descreve as características da literatura e o segundo grupo examina o relacionamento entre os componentes da literatura.

Borgman e Furner (2002) ressaltam que a análise de citações é a abordagem bibliométrica mais conhecida e identifica relacionamento de um documento com outro independentemente da presença de termos iguais nos documentos avaliados. As citações bibliográficas denotam relações particulares entre o artigo citante e o citado e, nesse sentido, Leal (2005) esclarece que a citação pode ser entendida como um processo social no momento em que considera toda a experiência anterior do autor, sua rede de conhecimento e suas próprias considerações.

Cronin (1984) afirma que o hábito de citar mostra conformidade e consistência no ato da produção intelectual, muitas vezes, governada por conhecimento tácito e normas internalizadas. Os fatos citados no texto ganham credibilidade quando se apresenta a literatura utilizada, interligando o leitor a outras fontes de informação sobre o assunto. De acordo com Alvarenga (2009), cria-se um fluxo de informação e de comunicação entre aquele que cita e aquele que lê, proporcionando uma dinâmica circulante, que mantém viva a criação de um autor, concedendo-lhe significativo reconhecimento. Todos os aspectos relacionados confirmam a importância das interpretações dos resultados obtidos pela aplicação da análise de citações como método de avaliação de produtividade e de tendências da literatura científica no tempo e no espaço físico.

A análise de citações é utilizada, ainda, segundo Guedes e Borschiver (2005) para estimar o fator de imediatismo ou de impacto de um artigo publicado. A hipótese é de que, em determinada área científica, artigos de periódicos citados mais frequentemente sejam mais

relevantes do que artigos menos citados. O fator de impacto de um periódico é calculado dividindo-se, o número total de citações dos artigos de um determinado periódico publicados nos dois anos anteriores, pelo número total dos artigos presentes no periódico no mesmo período.

O indicador fator de impacto foi concebido por Eugene Garfield, o fundador, em 1958, do *Institute for Scientific Information* (ISI), que, em 1992, foi adquirido pelo *The Thomson Corporation* (LEAL, 2005). O ISI publica, anualmente, os três índices de citação mais conhecidos da literatura, quais sejam, o *Science Citation Index* (SCI), o *Social Science Citation Index* (SSCI) e o *Arts and Humanities Citation Index* (AHCI). Como toda avaliação quantitativa, a utilização do fator de impacto deve considerar (PINTO; ANDRADE, 1998) alguns aspectos que influenciam o seu cálculo. O número de periódicos por área de conhecimento é muito diferente. Artigos publicados nas áreas com o maior número de periódicos têm maior probabilidade de serem citados. O número de referências citadas por artigo varia de área para área. Algumas pesquisas têm caráter regional, o que não diminui sua importância para a sociedade que a está desenvolvendo. A auto-citação, a citação afirmativa e a negativa são tratadas da mesma maneira. O fator de impacto é, portanto, um índice significativo, mas, deve considerar as características do contexto em que está inserido quando utilizado na avaliação de pesquisadores e instituições.

As técnicas bibliométricas continuam sendo objeto de estudo da comunidade científica e, recentemente, Hirsch citado por Franceschet (2010) apresentou um novo índice, o índice h, que tenta agrupar, em um único indicador, mais aspectos relacionados à qualidade das publicações. O índice h de um pesquisador é o maior número h de artigos publicados pelo pesquisador que recebeu, em cada um destes artigos, no mínimo, h citações. Este indicador tenta refletir, em um valor único, tanto a produtividade do pesquisador quanto o impacto gerado por sua produção.

2.1.6.1. Razões para citar no processo de comunicação científica

Para Alvarenga (1998), o ato de citar é envolvido por um espectro de implicações psicológicas, sociológicas, políticas e históricas. Destacam-se, também, a presença de características como o fenômeno de auto-citações, a influência entre autores e instituições e a adesão a paradigmas vigentes.

Durante o ciclo de suas atividades de pesquisa e divulgação de resultados, Borgman e Furner (2002) ressaltam que os autores tomam decisões relevantes nos processos

que envolvem a elaboração e a submissão de um trabalho, incluindo a escolha de profissionais que serão citados e, poderão, no futuro, ser associados aos autores por compartilharem o mesmo trabalho.

Weinstock, em 1971, citado por Macias-Chapula (1998), identificou quinze razões que levam um autor a citar, como mostrado no Quadro 2.

Quadro 2 - Razões que levam um autor a citar

<i>Razões que levam um autor a citar</i>	
1	Prestar homenagem aos pioneiros
2	Dar crédito aos trabalhos relacionados
3	Identificar metodologia, equipamento, etc
4	Oferecer leitura básica
5	Retificar o próprio trabalho
6	Retificar o trabalho de outros
7	Analisar trabalhos anteriores
8	Sustentar declarações
9	Informar aos pesquisadores trabalhos futuros
10	Dar destaque a trabalhos pouco disseminados, inadequadamente indexados ou não citados
11	Validar dados e categorias de constantes físicas e de fatos
12	Identificar publicações originais nas quais uma ideia ou um conceito foram discutidos
13	Identificar publicações originais que descreveram conceitos ou termos epônimos
14	Contestar trabalhos ou ideias de outros
15	Debater a primazia das declarações de outros

Fonte: MACIAS-CHAPULA, 1998

Segundo Braga (1973), a inclusão de uma ou mais referências, em um documento, evidencia relações entre partes dos textos dos documentos citados e partes do texto do documento que as inclui.

Os resultados alcançados, segundo Alvarenga (1998), refletem aspectos quantitativos de campos de conhecimento, evidenciando variáveis, tais como produtividade de autores ou de fontes discursivas. O mapeamento da rede de relações estabelecidas entre autores e textos, por meio das citações, pode ser utilizado para se evidenciar ângulos específicos do processo de produção de conhecimento.

São identificados, também, os autores que constituem as frentes de pesquisa em determinado campo de conhecimento e constatações de regularidades que podem destacar fatos históricos durante a evolução de uma disciplina.

Alvarenga (1998) ressalta, ainda, o fato de que os artigos relacionados por suas citações, geralmente, estabelecem relações semânticas entre si. A citação seria, também, uma maneira de se reportar aos fundamentos teórico-metodológicos presentes em uma área de pesquisa.

As citações são, portanto, utilizadas para indicar leituras indispensáveis à compreensão do próprio documento, para evitar explicações teóricas detalhadas e para apresentar argumentos favoráveis à pesquisa.

2.1.6.2. Dificuldades encontradas na utilização das técnicas bibliométricas

A grande dificuldade para se identificar a produtividade científica de um país ou de uma comunidade é a ausência de uma base de dados que incorpore toda a produção científica da área.

Macias-Chapula (1998) destaca que, para os sociólogos, as citações só podem ser compreendidas se as condições sociais que predisõem os cientistas a realizar suas citações forem analisadas. Os autores seriam influenciados por suas realidades sociais distintas e, portanto, desempenhariam o ato de citar de modo diferente.

MacRoberts e MacRoberts (1989) relacionam, como apresentado no Quadro 3, as seguintes dificuldades para implementar a análise de citações:

Quadro 3 - Dificuldades encontradas na implementação da análise de citações

<i>Dificuldades encontradas na implementação da análise de citações</i>	
1	Influências formais não citadas
2	Citações tendenciosas ou preconcebidas
3	Influências informais não citadas
4	Auto-citações
5	Diferentes tipos de citações, afirmativa e negativa, tratadas da mesma maneira
6	Variações nas médias de citações relacionadas ao tipo de publicação, nacionalidade, período de tempo, extensão e tipo de especialidade
7	Limitações técnicas de índices de citações e bibliografias <ol style="list-style-type: none"> a. Autoria múltipla

- | |
|--|
| <ul style="list-style-type: none"> b. Sinônimos c. Homônimos d. Erros de edição e. Cobertura da literatura |
|--|

Fonte: MACROBERTS E MACROBERSTS, 1989

Alvarenga (1998) ressalta que as críticas à utilização de técnicas bibliométricas não se restringem à sua abordagem quantitativa, mas estendem-se, também, às suas vinculações com possíveis tendências de pesquisas consideradas legitimadoras de ideologias dominantes, em que se privilegiam meios em detrimento dos fins.

2.1.6.3. Aplicações das técnicas bibliométricas

Como a bibliometria se encontra na fronteira das ciências sociais e das ciências físicas, Sengupta (1992) esclarece que suas técnicas têm aplicações na sociologia, na gestão da informação, na biblioteconomia, na história e na ciência política.

Algumas possibilidades de aplicação das técnicas bibliométricas podem ser resumidas no Quadro 4.

Quadro 4 - Aplicações das técnicas bibliométricas

<i>Aplicações das técnicas bibliométricas</i>	
1	Identificar as tendências de pesquisa e o crescimento do conhecimento em diferentes disciplinas científicas
2	Estimar os periódicos secundários
3	Identificar os usuários de diferentes disciplinas
4	Identificar a autoria e suas tendências de pesquisa em vários assuntos
5	Medir a utilidade de serviços
6	Prever as tendências de publicação do passado, do presente e do futuro
7	Desenvolver modelos experimentais relacionando-os aos existentes
8	Identificar os periódicos do núcleo de diferentes disciplinas
9	Formular uma política de aquisição baseada nas necessidades identificadas
10	Adaptar uma política precisa de busca
11	Iniciar o desenvolvimento efetivo de sistemas em rede multinível
12	Regular o fluxo da informação e da comunicação

13	Estudar a dispersão e a obsolescência da literatura científica
14	Prever a produtividade de editores, autores individuais, organizações, países ou de uma disciplina como um todo
15	Projetar uma linguagem automática de processamento para autoindexação, autoresumo e autoclassificação
16	Desenvolver normas de padronização

Fonte: SENGUPTA, 1992

Vanti (2002), ainda, apresenta aplicações como medir o grau e padrões de colaboração entre autores, analisar os processos de citação e co-citação, avaliar os aspectos estatísticos da linguagem, das palavras e das frases e avaliar a circulação e o uso de documentos em um centro de documentação.

Segundo Paulston, citado por Alvarenga (1998), a análise de citações prevê como resultado um “mapa cognitivo”, que traçaria estruturas multidimensionais e caminhos para interpretar os fenômenos sociais e educacionais inseridos nos textos e nas práticas.

2.2. Inteligência Artificial

A Inteligência Artificial é um campo de conhecimento e pesquisa que viabiliza a transferência de processos de representação de conhecimento para o computador, com a proposta de desenvolver sistemas inteligentes capazes de simular o processo de decisão do ser humano (REZENDE, 2003). Os sistemas inteligentes se caracterizam por apresentar habilidade para usar conhecimento para desempenhar tarefas ou resolver problemas e capacidade para aproveitar associações e inferência para trabalhar com problemas que se aproximam de situações reais. Os sistemas inteligentes utilizam técnicas que podem ser aplicadas isoladamente ou em conjunto para auxiliar o processo decisório. Dentre as técnicas e metodologias mais utilizadas, podem ser destacadas Aquisição de Conhecimento, Aprendizado de Máquina, RNA, Lógica *Fuzzy*, Computação Evolutiva, Agentes e Multiagentes e Mineração de Dados e de Textos

As RNA são modelos matemáticos inspirados nas estruturas neurais biológicas e que têm capacidade computacional adquirida por meio de aprendizado e generalização (HAYKIN, 1994). Os trabalhos que utilizam RNA reconhecem que o cérebro trabalha de um modo inteiramente diferente do computador digital convencional. As pessoas armazenam conhecimento por meio de modelos mentais construídos ao longo de suas vidas e adquirem

valores éticos e sociais próprios que, dificilmente, poderão ser representados por computadores. Brookes (1980) ressalta em seu trabalho sobre os fundamentos da CI que a máquina faz o que está programada para executar e que a informação utilizada é uma sequência programada de sinais. O conhecimento inerente ao ser humano não é incorporado pela máquina, ela mantém, apenas, informações objetivas.


Segundo Haykin (1994), o cérebro é um computador complexo, não linear e possui um sistema de processamento de informações paralelo. Mesmo que observadas inúmeras ações externas e seguidas reações do indivíduo, é impossível garantir que uma nova ação similar faça com que o indivíduo reaja como nas situações anteriores. Isto é o que caracteriza os processos mentais do indivíduo como estocásticos. Um sistema é dito linear se é possível supor que, conhecendo-se a sua saída para duas entradas distintas aplicadas simultaneamente, o resultado encontrado é idêntico para a superposição de suas entradas, quando aplicadas separadamente ao mesmo sistema, ou seja, quando a saída global for igual à superposição das saídas encontradas com a aplicação individual destas entradas ao sistema. Uma RNA é um algoritmo de processamento estocástico e não linear inspirado no funcionamento das redes biológicas existentes no cérebro, que armazena informação experimental e a torna disponível para uso. Assemelha-se ao cérebro em, basicamente, dois aspectos: o “conhecimento” é adquirido pela RNA por meio de um processo de aprendizagem e as forças de conexão existentes entre os neurônios, conhecidas como pesos sinápticos, são usadas para armazenar este “conhecimento”.

As próximas seções descrevem algumas considerações sobre o sistema nervoso, o histórico de RNA e as principais características das RNA.

2.2.1. O sistema nervoso e a consciência

O cérebro humano consiste de bilhões de elementos de processamento chamados neurônios. Eles se comunicam por meio de uma rede de conexão formada por compridos prolongamentos denominados axônios, que fazem contato não contíguo com os corpos celulares nervosos e suas estruturas em formato de árvore chamadas dendritos. É por meio dos múltiplos terminais sinápticos que um neurônio pode influenciar a fisiologia de todos os outros neurônios com os quais ele se conecta. A comunicação se processa essencialmente por impulsos elétricos e reações químicas e, segundo Nicoletti (2011), “qualquer tipo de informação processada pelo cérebro envolve o recrutamento altamente distribuído de populações de neurônios”. O neurônio biológico é mostrado na Figura 6.

Figura 6 - Representação de um neurônio biológico



Fonte: Ferneda, 2006

De acordo com Nicolelis (2011), estas redes celulares possuem um grau de complexidade e conectividade muito superior a qualquer outra rede elétrica, computacional, mecânica ou telefônica jamais criada por seres humanos, permitindo que cada neurônio estabeleça contato direto e se comunique com centenas ou milhares de outros neurônios por meio de mensagens eletroquímicas que atravessam os terminais sinápticos. Nicolelis ressalta que as pesquisas conduzidas em seu laboratório, nas duas últimas décadas, têm ajudado a demonstrar que um neurônio único não pode mais ser visto como a unidade fisiológica fundamental do sistema nervoso. Segundo o autor, “populações de neurônios são os verdadeiros compositores das sinfonias elétricas que dão vida a todos os pensamentos gerados pelo cérebro humano”.

Segundo Bass (2009), a plasticidade neural ou neuroplasticidade é a capacidade de organização do sistema nervoso frente ao aprendizado e à lesão. Esta organização se relaciona com a modificação de algumas conexões sinápticas. A plasticidade nervosa não ocorre apenas em processos patológicos, mas assume também funções extremamente importantes no funcionamento normal do indivíduo. Os processos de modificação pós-natais, em consequência da interação com o meio ambiente, e as conexões que se formam durante o aprendizado motor consciente (memória) e inconsciente (automatismo) são exemplos de como funciona a neuroplasticidade em indivíduos sem alteração do sistema nervoso central. Esta capacidade do cérebro de armazenar conhecimento, reorganizando e alterando as forças de conexão entre os neurônios, é o que inspira pesquisadores a desenvolver e aprimorar o funcionamento das RNA. A neuroplasticidade, vista como essa capacidade de reorganização, está associada ao processo de categorização e de classificação discutidos neste trabalho.

Ao interagir com o meio ambiente, os sentidos são preenchidos por vários estímulos. O campo visual percebe o mundo que o cerca, identificando estrelas, alimentos,

flores, caracterizados por forma, cor e posição específicos. Boisot e Canais (2004) representam esta interação entre o indivíduo e o ambiente, utilizando-se do que denominam filtro de percepção. Este filtro seleciona, dentre os estímulos recebidos em sua entrada, aqueles que registrará como dados em sua saída. Em geral, os infinitos objetos existentes têm alguma relação com outro qualquer e, mesmo assim, os indivíduos lhes atribuem nomes e conceitos distintos. Obviamente, não existe um neurônio associado a cada objeto ou sequer um mapa composto de redes de neurônios para identificar cada objeto ou situação percebida. Apesar de existir um número enorme de neurônios, esse número é finito. O que se sabe, segundo Silva e outros (2003), é que existem conjuntos de neurônios especializados em analisar características distintas de cada objeto, localizados em áreas distintas do cérebro, razão pela qual deve haver um mecanismo que enlace temporalmente a atividade de todos eles, de maneira que a percepção possa ser experimentada como uma unidade perceptual unificada. Esta ativação elétrica de grupos de circuitos num padrão temporal e espacial específico produz a percepção, a emoção, a linguagem e a motricidade, caracterizando o comportamento e o fenômeno denominado consciência. Segundo Nicoletti (2011), o cérebro humano é capaz de criar tudo o que somos capazes de ver e de sentir como realidade, incluindo nosso próprio senso de ser e existir. Sua teoria ressalta a busca incessante do indivíduo por informações e por conhecimento como sendo o que denomina de “ponto de vista próprio do cérebro”. Esta característica individual é caracterizada por sua história evolutiva, por seu estado dinâmico global a cada momento no tempo e pelas representações internas que ele mantém do corpo e do mundo.

2.2.2. Histórico de redes neurais artificiais

O conceito de RNA surgiu durante a Segunda Guerra Mundial. Meireles, Almeida e Simões (2003) discutem uma linha de evolução temporal, que é apresentada, resumidamente, a seguir. Em 1943, McCulloch e Pitts propuseram a ideia de que uma máquina poderia ser construída pela interconexão de modelos baseados no comportamento de neurônios biológicos. Wiener deu a este novo campo o nome popular de cibernética, cujo princípio é a relação interdisciplinar entre a engenharia, a biologia, os sistemas de controle e as funções cerebrais. Naquela época, a arquitetura do computador não estava completamente definida e as pesquisas levaram ao que é, hoje, definido como o computador de Von Neumann. Com o progresso da pesquisa sobre o cérebro e sobre os computadores, o objetivo da pesquisa concentrou-se no projeto de uma máquina que pudesse aprender, para o qual o

modelo de aprendizado de Hebb foi inicialmente proposto. Em 1958, Roseblatt, da *Cornell Aeronautical Laboratory*, montou a máquina denominada “Perceptron”. Esta seria a antecessora da atual RNA. Widrow e Hoff propuseram a *Adaptive Linear Element* (ADALINE), uma variação da “Perceptron”, que se baseava na regra do aprendizado supervisionado, envolvendo um supervisor e, conseqüentemente, a interação com o meio externo, e que aprendia mais rapidamente e de um modo mais preciso. Este esquema foi utilizado para cancelar o eco nas linhas telefônicas e foi considerado a primeira aplicação de RNA. Durante a década de 1960, Steinbuch desenvolveu sua “Matriz de Aprendizado”, que aceitava, na entrada, um vetor binário e produzia, na saída, outro vetor, criando associação entre pares.

Durante a década de 70, poucas investigações sobre RNA foram realizadas. Albus desenvolveu sua rede *Cerebellar Model Articulation Controller* (CMAC), que é um sistema baseado em seu modo de ver os modelos da memória humana. Em 1974, Werbos desenvolveu o algoritmo *backpropagation*, que é o algoritmo mais conhecido para treinamento das redes que utilizam treinamento supervisionado. Sua primeira aplicação prática foi determinar um modelo dinâmico para prever índices associados ao nacionalismo e à comunicação social, obra esta que permaneceu desconhecida da comunidade científica da área de Inteligência Artificial por mais de dez anos. No início dos anos 80, Hopfield introduziu um estudo que ressaltava as propriedades associativas das RNA.

A partir de meados da década de 80, a comunidade científica retomou o interesse pela pesquisa na área, reforçando a importância deste estudo para fins comerciais e aplicações industriais de vários campos diferentes. A literatura tem relatado a utilização de RNA em reconhecimento de padrões, classificação de imagens, reconhecimento de voz, otimização no planejamento de ações, identificação de modelos e controle de processos.

2.2.3. Características das redes neurais artificiais

Um neurônio artificial pode ser representado por um modelo matemático simplificado de processamento existente em um neurônio biológico. Uma RNA pode ser definida como uma topologia interconectada de neurônios artificiais, na qual, tipicamente, podem ser identificados neurônios de entrada, neurônios internos e neurônios de saída. A maneira como os neurônios estão organizados e conectados depende da arquitetura da rede. As RNA implementam algoritmos que procuram alcançar um desempenho próximo ao dos sistemas neurológicos naturais. Utilizam técnicas como aprendizado pela experiência e

generalização a partir de situações similares, que, também, podem ser observadas nas características de neuroplasticidade do cérebro.

O aprendizado está normalmente associado à capacidade de as redes adaptarem os seus parâmetros como consequência da sua interação com o meio externo. Neste caso, como destacou Rezende (2003), o processo de aprendizado é interativo e por meio dele a rede deve melhorar o seu desempenho, gradativamente, à medida que interage com o meio externo. As RNA podem, também, definir seus parâmetros por si próprias, dispensando, assim, a participação do supervisor.

As RNA são utilizadas, basicamente, em problemas de aproximação de função, predição, classificação, categorização e otimização. Meireles, Almeida e Simões (2003) destacam que a grande maioria das aplicações reportadas na literatura se concentra na área industrial. Souza (2006) ressalta que, em um Sistema de Recuperação de Informação, SRI, as RNA podem, por exemplo, ser usadas para realizar o casamento de padrões entre as consultas e os documentos do acervo do sistema.

2.2.4. Principais arquiteturas de redes neurais artificiais


Segundo Braga, Carvalho e Ludermir (2000), a definição da arquitetura de uma RNA é um parâmetro importante na sua concepção, uma vez que restringe o tipo de problema que pode ser tratado pela rede. Fazem parte da definição da arquitetura o número de camadas da rede, o número de nós em cada camada, o tipo de conexão entre os nós e a topologia da rede. A topologia da RNA está associada ao número de neurônios na camada de saída. Em um processo de categorização, por exemplo, a cada um dos neurônios da camada de saída corresponderá, depois do treinamento, um grupo de elementos afins associados por suas características comuns.

Uma classificação comum baseia-se no modo como os seus elementos estão interligados. Meireles, Almeida e Simões (2003) afirmam que, até aquele ano, 81,2% das publicações que utilizavam RNA eram do tipo *Multilayer Perceptron* (MLP), 8,3% eram redes *Self Organizing Maps* (SOM) e 5,4% eram redes Hopfield. O percentual restante, 5,1%, correspondia a outros tipos de RNA.

As redes MLP apresentam, pelo menos, uma camada intermediária e o processamento realizado por cada nó é definido pela combinação dos processamentos realizados pelos nós da camada anterior que estão conectados a ele. Não existem conexões

entre os neurônios da mesma camada. A Figura 7 apresenta um diagrama típico desta estrutura.


Figura 7 - Diagrama de uma topologia MLP



Fonte: MEIRELES, ALMEIDA e SIMÕES, 2003

As redes SOM são mapas auto-organizativos desenvolvidos por Kohonen na década de 80. São estruturas baseadas no mapa topológico presente no córtex cerebral. A rede SOM funciona, basicamente, construindo um mapa topológico onde os nós que estão topologicamente próximos respondem de modo semelhante a padrões de entrada semelhantes. Cada neurônio de entrada é conectado a cada neurônio de saída com o seu respectivo peso associado. Braga, Carvalho e Ludermir (2000) destacam que, na literatura, existem exemplos de processos de categorização de dados usando as redes SOM. A Figura 8 apresenta um diagrama utilizado na rede SOM.

Figura 8 - Diagrama topológico de uma rede SOM




Fonte: MEIRELES, ALMEIDA e SIMÕES, 2003

As redes SOM possuem a capacidade de auto-organização e são mais semelhantes às estruturas neurobiológicas do que as redes supervisionadas. A estrutura básica desses modelos constitui-se de uma camada de entrada, que é a fonte, e de uma camada de saída, que

é a representação. Para realizar uma categorização, um algoritmo *self-organizing* precisa encontrar características ou padrões significativos nos dados de entrada, observando-se as similaridades e as diferenças entre esses dados. Basicamente, a rede SOM, quando apresentada a um padrão de entrada, procura a unidade que se assemelha a esse padrão. Durante o treinamento, a rede aumenta a semelhança entre o padrão de entrada e entre o nó escolhido e seus vizinhos. Dessa maneira, a rede constrói um mapa onde os nós que estão topologicamente próximos respondem de maneira semelhante a padrões de entrada semelhantes. Kohonen citado por Lin, Soergel e Marchionini (1991) desenvolveu um algoritmo de aprendizado que produz mapas similares aos construídos no cérebro, inspirado pela possibilidade de que alguma organização de alto nível, no cérebro, pode ser criada durante a aprendizagem por meio de mapas geometricamente organizados de acordo com a representação do conhecimento em uma determinada categoria.

Como mostrado na Figura 9, uma rede Hopfield é constituída de uma única camada de neurônios e todos os neurônios estão conectados. Este é um modelo de rede não supervisionada e utilizada na identificação de sistemas lineares e não lineares.

Figura 9 - Diagrama topológico de uma rede Hopfield



Fonte: MEIRELES, ALMEIDA e SIMÕES, 2003

2.2.5. Tipos de aprendizado

Uma das principais características das RNA é a sua capacidade de aprender por meio de exemplos sem que tenham sido programadas. Redes que utilizam as informações fornecidas por um supervisor externo terão, em suas saídas, respostas desejadas para os padrões de entrada fornecidos e, por isso, este aprendizado é denominado supervisionado. Esse tipo de rede só pode ser utilizado quando dados de saída, previamente observados, são conhecidos. Deste modo, o supervisor ajusta os parâmetros da rede até encontrar uma relação

entre as entradas e as saídas fornecidas. Conhecendo-se esta relação, é possível encontrar saídas para novas entradas apresentadas à rede. Braga, Carvalho e Ludermir (2000) afirmam que o algoritmo de aprendizado mais conhecido para treinamento deste tipo de rede é o algoritmo *back-propagation*. A maioria dos métodos de aprendizado para RNA do tipo MLP utiliza variações deste algoritmo, que, basicamente, utiliza pares (entrada, saída desejada) para, por meio de um mecanismo de correção de erros, ajustar os pesos das conexões da rede. Este treinamento pode ser dividido em duas fases, a fase *forward* e a fase *backward*. A primeira fase é utilizada para definir a saída da rede para um dado padrão de entrada. A fase *backward* utiliza a saída desejada e a saída fornecida pela rede para atualizar os pesos de suas conexões e, assim, reduzir o erro.

No aprendizado não supervisionado, não há um supervisor para acompanhar o processo de aprendizado. Muitos dos sistemas biológicos trabalham por meio do aprendizado não supervisionado, como, por exemplo, os estágios iniciais dos sistemas de visão e audição. A partir do instante em que a rede identifica regularidades entre os dados de entrada, ela desenvolve uma habilidade de gerar representações internas para codificar as características de entrada e criar novos grupos automaticamente. Segundo Braga, Carvalho e Ludermir (2000), estas redes definem seus parâmetros por si próprias e os algoritmos utilizam um conjunto de regras de natureza local para o ajuste de pesos.

Existem dois grandes grupos de algoritmos de treinamento para os modelos *self-organizing*. O primeiro e mais utilizado em problemas de classificação é o aprendizado competitivo, onde os nós competem entre si pelo direito de atualizar seus pesos. O segundo algoritmo é o aprendizado hebbiano, cujo princípio de atualização de pesos baseia-se na teoria proposta pelo neurofisiologista Hebb. É utilizado em aplicações que envolvem extração de características, análise de dados e memória associativa.

A rede SOM utiliza um algoritmo de aprendizado competitivo. Os nós da camada de saída competem entre si para se tornarem ativos e, assim, gerar o maior valor de saída. Para cada padrão de entrada, apenas um nó de saída ou um nó por grupo se torna ativo, ajustando o seu peso e os dos nós localizados em sua vizinhança.

2.3. Redes neurais artificiais na recuperação de informação

Um grande número de pesquisadores tem utilizado RNA na recuperação de informação, conforme evidenciado por Lin, Soergel e Marchionini (1991) ao utilizar uma rede SOM para construir um sistema de recuperação de informação. Estes autores apresentaram

um mapa semântico como uma interface de recuperação de um sistema bibliográfico online, caracterizado como um guia de literatura que refina a busca do usuário. Os autores destacaram o papel dos computadores na pesquisa, como não apenas o de um mecanismo de busca, mas, uma ferramenta para análise e descoberta de relações semânticas entre os documentos. O mapa semântico obtido identificava relações semânticas entre os documentos da entrada e representava os dados com os seus relacionamentos. A caracterização e a organização da informação eram obtidas pela análise da frequência e da distribuição das palavras contidas nos textos. O estudo foi aplicado à base de dados LISA, que incluía 140 títulos indexados pelo descritor *Artificial Intelligence*, de janeiro de 1969 a março de 1990. Depois de excluir palavras como *information*, *artificial* e *intelligence* e palavras com frequência de ocorrência inferior a três, foram selecionadas 25 palavras (raízes), definidas, então, como o conjunto de palavras para esta coleção.


Stafylopatis e Likas (1992) descreveram, em seu trabalho, uma técnica de recuperação de imagens armazenadas utilizando informação incompleta como entrada do processo. Ressaltaram a importância da tecnologia das RNA para oferecer soluções efetivas para problemas relacionados aos sistemas de informação. O processo era constituído, basicamente, de três etapas. A primeira processava as imagens e extraía informação destas imagens. A segunda criava o banco de dados responsável pelo armazenamento e pelo gerenciamento das imagens originais e das informações extraídas. A terceira etapa gerava as interfaces com o usuário que o possibilitavam acessar as informações disponíveis.

Chen (1995) propôs a utilização de uma rede neural do tipo Hopfield para recuperar informações contidas em três bases de dados. A rede Hopfield se caracteriza por ter as entradas dos neurônios vindas do meio externo e de saídas de neurônios da própria rede. Chen cita um exemplo em que solicita ao pesquisador que identifique descritores que sejam relevantes na busca relacionada à expressão *knowledge indexed deductive search*. Foram utilizados quatro termos de pesquisa iniciais, quais sejam *information retrieval*, *knowledge base*, *thesaurus* e *automatic indexing*. A rede convergia após onze iterações, apresentando catorze termos e respectivas fontes. Solicitava, então, ao usuário que selecionasse os dez termos que melhor se adequassem à sua pesquisa. Estas etapas de seleção de termos podiam se repetir até que a demanda do usuário fosse satisfeita.

Ellis (1996) destacou que Mozer foi o primeiro a utilizar uma arquitetura de RNA em um protótipo de recuperação de informação. O sistema continha apenas duas camadas, uma camada de 407 documentos e outra camada contendo 133 termos de indexação. Os termos de indexação ativavam os documentos, que ativavam os termos de indexação,

conforme apresentado na Figura 10. Um documento ao ser ativado reduzia o nível de ativação dos demais documentos. O processo se propagava até a estabilização da rede neural, quando cessavam as atividades entre os nós. O nível de ativação de cada documento representava o grau de relevância em relação à expressão de busca. A arquitetura era simples e não utilizava uma das principais características da RNA, que é a capacidade de aprender. Mas, como o próprio autor enfatizou, eram produzidos resultados inesperados, recuperando-se documentos que não possuíam termo em comum com a expressão de busca, podendo, mesmo assim, ser relevantes para o usuário.

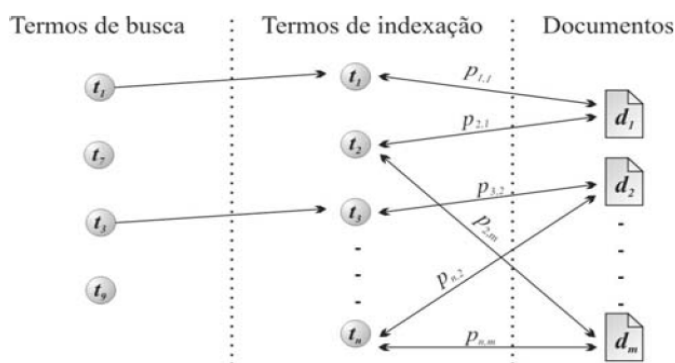
Figura 10 - Exemplo de RNA utilizando a arquitetura de Mozer



Fonte: FERNEDA, 2006

De uma maneira simplificada, o processo de recuperação de informação envolve documentos, termos de indexação e expressões de busca dos usuários. Para Ferneda (2006), em um SRI, de um lado estão as expressões de busca, do outro lado estão os documentos e, no centro, estão os termos de indexação. Esta estrutura pode ser vista como uma RNA de três camadas. A camada de termos de busca é a camada de entrada, a camada de documentos é a saída e a camada de termos de indexação é a camada central, como exemplificado na Figura 11.

Figura 11 - Representação de uma RNA aplicada à recuperação de informação



Fonte: FERNEDA, 2006

Basicamente, os termos de busca iniciam o processo de inferência mediante a ativação dos respectivos termos de indexação. Nem todos os termos da expressão de busca fazem parte do conjunto de termos de indexação e, portanto, não são considerados durante o processo de ativação da rede. Os termos de indexação ativados pelos termos de busca enviam sinais para os documentos. Estes sinais são multiplicados pelos pesos de cada ligação. Os documentos ativados enviam sinais que são conduzidos de volta aos termos de indexação. Ao receberem estes estímulos, os termos de indexação enviam novos sinais aos documentos, repetindo o processo. Os sinais tornam-se mais fracos a cada iteração e o processo de propagação eventualmente para. O resultado final de uma busca é um conjunto dos documentos que foram ativados, cada qual com um nível de ativação que pode ser interpretado como o grau de relevância do documento em relação à busca do usuário. Entre os documentos resultantes podem aparecer alguns que não estão diretamente relacionados aos termos de busca, mas que foram inferidos durante a pesquisa e possuem algum grau de relacionamento com a necessidade de informação do usuário. A utilização de RNA em sistemas de recuperação de informação, como discutido por Ferneda (2006), permite atribuir um caráter dinâmico a tais sistemas, uma vez que as representações dos documentos podem ser reavaliadas e alteradas de acordo com a especificação de relevância atribuída pelos usuários aos documentos recuperados.

Capuano (2009) utilizou RNA para automação do processo de ordenação e apresentação de resultados na recuperação de informação textual. O diferencial apresentado pelo autor era a utilização de índices, no processo de indexação, compostos por mais de um termo linguístico, como sendo uma tentativa de se reduzir a possível ambiguidade gerada ao se trabalhar com palavras-chave. O experimento utilizava uma base de índices de textos em linguagem natural representada por expressões denominadas sintagmas nominais. Os

sintagmas nominais são partes de uma sentença constituídas de substantivos associados a preposição, a artigo ou a adjetivo. Os textos utilizados eram constituídos por uma amostra dos resumos das apresentações ocorridas em eventos de Arquitetura da Informação, de 2005 a 2008, nos Estados Unidos. Foram definidos três sintagmas nominais para indexar cada texto dessa base, buscando, com este número, um equilíbrio entre o problema enfrentado pela resolução semântica no processo de recuperação de informação e a pressão exercida sobre a infraestrutura computacional. O usuário informava ao sistema três argumentos de busca constituídos por três sintagmas nominais, sugerindo, assim, o conteúdo pesquisado.

2.4. Redes neurais artificiais em processos de categorização e classificação

Muitos dos experimentos relatados na literatura descrevem a utilização da rede SOM para categorização de documentos, com o intuito de organizá-los em um formato alternativo para a recuperação de informação (LUO; ZINCIR-HEYWOOD, 2003; YEN; WU, 2006; YU et al, 2008). Sharma e outros (1994) combinaram, em seus experimentos, aprendizado supervisionado e não supervisionado e destacaram a melhoria do desempenho da RNA. Lensu e Koikkalainen (1999) apresentaram um método que pode ser usado na recuperação de documentos utilizando *queries*. O processo localizava palavras similares nos documentos e, posteriormente, categorizava os documentos baseado nos contextos em que estas palavras estavam inseridas. Para avaliar o procedimento, foram utilizados 18.937 questionários respondidos por estudantes de escolas finlandesas, e identificadas 115.474 palavras e 73.608 contextos. O procedimento de análise textual foi capaz de localizar documentos similares mesmo quando estes documentos continham palavras com terminações distintas e com erros de ortografia. O método foi capaz de identificar como pertencentes ao mesmo contexto e agrupar em um mesmo cluster dois documentos com expressões do tipo “ouça o professor e faça a tarefa de casa” e “preste atenção ao ensino e faça os exercícios dados”.

Kohonen e outros (2000) descreveram a implementação de um sistema capaz de organizar uma vasta coleção de documentos de acordo com as similaridades textuais. De acordo com os autores, a interpretação dos resultados das buscas se tornaria mais fácil se os resultados já fossem apresentados de acordo com as semelhanças de conteúdo. No trabalho, os artigos foram representados como pontos de uma estrutura bidimensional e as relações geométricas entre os pontos representavam as relações de similaridade entre os artigos, formando mapas. A proposta dos mapas de documentos era agregar valor à recuperação de

textos, fornecendo uma base visual significativa para retratar os resultados da pesquisa e fornecer pistas para selecionar os textos mais interessantes. Os mapas seriam especialmente úteis quando o usuário não conhecesse bem o domínio ou tivesse apenas uma vaga ideia do conteúdo dos textos que estavam sendo examinados. Segundo os autores, coleções organizadas de dados fornecem ao usuário a possibilidade de recuperar informação relevante que não foi explicitamente declarada em sua busca.

Bakus, Hussin e Kamel (2002) ressaltaram o crescimento do interesse dos pesquisadores por trabalhos que exploram métodos e ferramentas de organização de dados disponíveis eletronicamente. Em seu trabalho, definiram uma abordagem de categorização de documentos que identificava alguns dos contextos em que as palavras estavam inseridas, utilizando frases e não palavras. A rede SOM foi utilizada em conjunto com um algoritmo de extração de frases. O *corpus* utilizado foi composto de 21.578 artigos da base de textos REUTERS. Deste *corpus*, foram selecionados 1000 artigos para testar o método de categorização proposto. Dos artigos restantes, foram escolhidos 10.000 documentos para o treinamento da fase de extração das frases. Os autores comprovaram que houve uma melhoria na execução do processo de categorização ao se utilizar frases substituindo-se as palavras.

Em trabalho posterior, Hussin e Kamel (2003) utilizaram uma rede organizada hierarquicamente, construída de uma rede SOM e de uma rede ART, *Adaptive Resonance Theory*, denominada SOMART pelos autores. A rede SOM foi usada para separar a coleção de documentos em grupos e a rede ART foi utilizada para refinar a qualidade dos clusters. Os resultados encontrados mostraram que o experimento apresentou melhor qualidade de categorização e que a combinação das redes foi mais eficiente em termos de tempo de execução. O *corpus* foi composto, também, por 1000 artigos coletados dos 21.578 documentos disponibilizados pela REUTERS.

Wang e Yu (2008) propuseram um modelo de categorização textual baseado na combinação da utilização de uma RNA e do método *Latent Semantic Analysis* (LSA), Análise da Semântica Latente. Este método é capaz de indexar textos para recuperação de informação e estabelecer um espaço vetorial, onde cada dimensão corresponde a um termo e cada texto é representado como um somatório de seus componentes. O objetivo do método LSA é reduzir o número de dimensões do espaço vetorial produzido com a menor perda possível de informação. Além de reduzir a dimensão, o método apresenta um relacionamento importante entre os termos. O algoritmo de treinamento utilizado, *back-propagation*, é um algoritmo supervisionado que utiliza a saída desejada e a saída fornecida pela rede para atualizar os pesos de suas conexões. A RNA é uma MLP com o algoritmo de treinamento *back-*

propagation modificado. Esta modificação foi proposta para aumentar a velocidade de treinamento da rede. O método LSA, originalmente proposto como um método de recuperação de informação, foi utilizado na categorização de textos para melhorar a precisão e a eficiência do processo.

No trabalho desenvolvido por Phuc e Hung (2008), foi apresentado um sistema de categorização que utilizou grafos para agrupar documentos similares e extrair as principais ideias dos documentos. O modelo utilizado na representação dos documentos foi capaz de indicar, segundo os autores, a informação estrutural dos documentos, assim como a relação semântica entre as palavras utilizadas na representação, a posição das palavras nos documentos e alguns conceitos implícitos presentes nos documentos. Depois de realizada a categorização, a saída da rede SOM foi utilizada para identificar as palavras que ajudaram a definir as principais ideias do conjunto de 500 documentos.

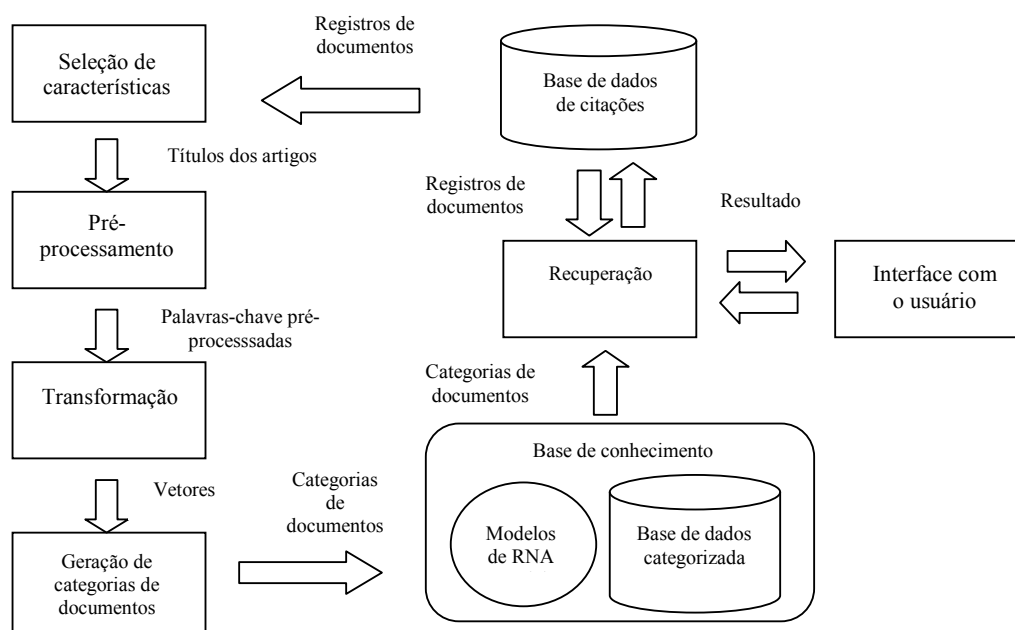
Morris, Wu e Yen (2001) ressaltaram o fato de que a maioria dos métodos descritos na literatura para a categorização de documentos utiliza histogramas de frequência de palavras como atributo de categorização. O método de visualização de artigos exposto utilizou as conexões contidas nas citações dos documentos e, segundo os autores, conseguiu identificar inovações na área pesquisada e a influência destas inovações sobre tecnologias aparentemente não relacionadas, fornecendo linhas do tempo de tendências tecnológicas. Foram utilizados 118 documentos na aplicação prática do método.

O trabalho apresentado por He e Hui (2001) descreveu um sistema de recuperação de publicações baseado em citações. Este sistema indexou as publicações científicas disponíveis em alguns sítios acessados pela *Web* e armazenou-as em um banco de dados. Foram descritos dois processos de categorização, que geravam grupos de documentos e grupos de autores. A categorização de autores agrupou autores de áreas de pesquisa diferentes baseada na análise das citações destes autores. Neste agrupamento, assumia-se que se a frequência em que dois autores eram citados juntos pela mesma publicação era alta, então, estes dois autores pertenciam ao mesmo campo de pesquisa. Para a categorização de documentos, duas técnicas foram utilizadas, as redes SOM de Kohonen e a *Fuzzy Adaptive Resonance Theory (Fuzzy ART)*. O sistema extraía palavras dos títulos das referências citadas pelos autores e as utilizava no processo de categorização. A arquitetura do sistema apresentado possuía um agente de indexação de citações, que localiza os artigos em sítios especificados pelos usuários ou sítios que continham as palavras-chave especificadas, convertia os artigos em texto, identificava a seção de referência e salvava as referências em um banco de dados. Foram realizados testes para a validação do método com publicações que utilizavam o assunto

“recuperação de informação”, no sítio ISI, *Institute for Scientific Information*, que incluía os periódicos da CI e da Biblioteconomia no período de 1987 a 1997. Foram selecionados 1466 artigos, de 367 periódicos, gerando um total de 44836 citações.

A Figura 12 representa o processo de categorização de documentos proposto pelos autores deste trabalho.

Figura 12 - O processo de categorização proposto por He e Hui (2001)



Fonte: Adaptado de He e Hui, 2001

A maioria dos trabalhos de categorização encontrados na literatura utiliza palavras-chave como atributo de categorização ou faz o agrupamento dos documentos pelas similaridades encontradas em seus conteúdos e contextos em que os mesmos estão inseridos. No trabalho descrito no parágrafo anterior, a categorização dos artigos foi realizada tomando-se como atributo as palavras extraídas dos títulos das referências citadas por estes artigos. Este trabalho também utilizou as citações dos artigos como atributo e propôs um método de categorização que utilizou as redes SOM. Diferentemente do que propôs He e Hui (2001), este trabalho gerou um arquivo para a entrada da RNA com a informação da presença ou da ausência das referências dos artigos que compunham a base de dados.

CAPÍTULO 3: METODOLOGIA

Neste capítulo, são apresentadas as quatro etapas realizadas na pesquisa, ressaltando-se os aspectos metodológicos realizados. As etapas se constituem do desenvolvimento da base de testes utilizada no trabalho, da criação das categorias pelas RNA, da identificação das características comuns aos grupos selecionados para análise e da comparação dos resultados obtidos neste trabalho com os resultados obtidos por um algoritmo de categorização que utilizou palavras-chave como atributo.

3.1. Classificação da pesquisa

O estudo proposto pode ser classificado como sendo uma pesquisa aplicada. Do ponto de vista da abordagem do problema, a pesquisa pode ser caracterizada como quantitativa. Considerando-se seus objetivos, é uma pesquisa exploratória, que envolve estudo de caso. Sob o ponto de vista dos procedimentos técnicos adotados, caracteriza-se como pesquisa experimental.

3.2. Etapas metodológicas

Todas as etapas metodológicas foram geradas a partir da ideia da concepção e da validação de um método de categorização de artigos baseado em RNA e em conceitos de bibliometria capaz de obter categorias de artigos com um significativo número de citações em comum. Neste trabalho, as palavras “característica” e “atributo” foram utilizadas no processo de categorização em duas situações. A palavra “atributo” está relacionada à variável utilizada pela RNA no processo de categorização e a palavra “característica” está associada às particularidades de cada um dos grupos gerados. Além desta abordagem, é importante destacar a utilização das palavras “categoria” e “grupo” para expressar conceitos similares. As categorias estão relacionadas ao número geral de conjuntos gerados nos quatro processos de categorização descritos neste trabalho. As categorias geradas nos quatro experimentos e selecionadas para análise foram denominadas “grupos” e nomeadas de acordo com o experimento e com a topologia utilizada conforme convenção descrita na seção 3.2.3.

As etapas metodológicas subsequentes à concepção deste método foram subdivididas em quatro grupos, descritos, resumidamente, a seguir, e apresentados, detalhadamente, nas próximas seções.

Primeira etapa: desenvolvimento da base de testes

- Foi selecionado um grupo de documentos representativos, em uma área de conhecimento, para que os dados relativos aos artigos e às referências citadas por estes artigos fossem cadastrados em um banco de dados;
- Criaram-se duas bases de dados. A primeira foi composta pelos títulos dos artigos, pelas palavras-chave, pelo ano de publicação, pelo número de referências citadas por cada artigo e pelos códigos numéricos associados a cada uma das referências bibliográficas citadas pelo artigo. Estas referências bibliográficas citadas por cada artigo da primeira tabela foram registradas na segunda tabela, que listou o seu código numérico, os títulos, os autores e o ano de publicação de cada referência;
- Foi organizada uma base de referências, eliminando os códigos numéricos distintos para a mesma referência e excluindo qualquer incoerência de caracteres presente nos títulos, nas palavras-chave e no nome dos autores;
- Foi criado o arquivo de dados utilizado na entrada da RNA.

Segunda etapa: criação das categorias pelas RNA

Utilizou-se uma RNA não supervisionada para categorizar os artigos. A entrada da RNA foi alimentada com os dados relativos às referências de cada um dos artigos e com seu respectivo ano de publicação. A saída da RNA gerou as categorias de artigos.

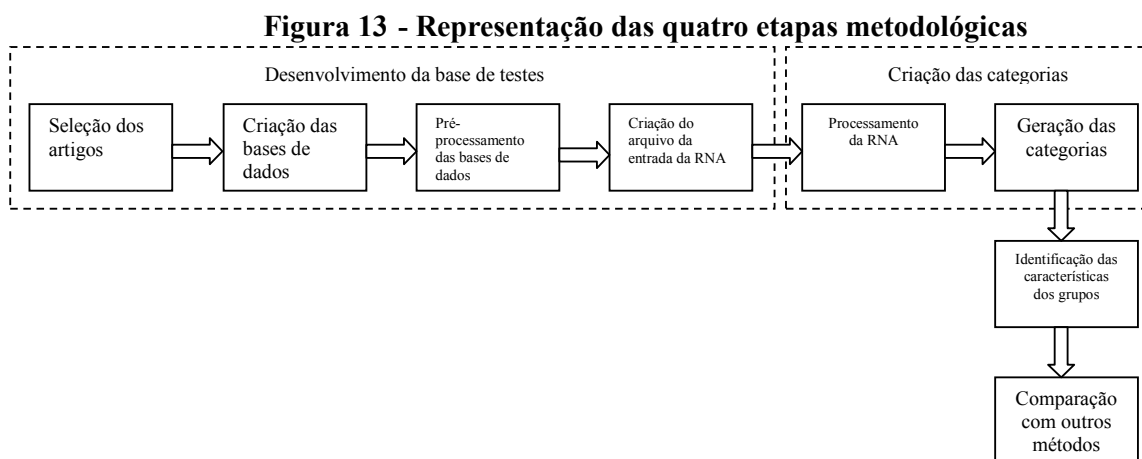
Terceira etapa: identificação das características comuns aos grupos

Foram identificadas as características comuns aos artigos agrupados em uma mesma categoria, analisando-se as referências comuns aos artigos, o número de vezes que as referências se repetiam em cada grupo e o ano de publicação dos artigos.

Quarta etapa: comparação dos resultados obtidos pelo método proposto com os resultados de um processo de categorização que utilizava palavras-chave.

Esta etapa empregou um *software* de categorização que utilizava as palavras-chave dos artigos como atributo. O resultado desta categorização foi comparado com a categorização realizada pela RNA.

As etapas metodológicas podem ser visualizadas na Figura 13.



3.2.1. Desenvolvimento da base de testes e do protótipo

A escolha do tipo de variável utilizada pelo pesquisador depende da natureza do estudo e dos recursos de que dispõe para representar, modelar ou controlar o evento. As variáveis utilizadas no experimento podem ser classificadas como quantitativas ou qualitativas. A variável quantitativa pode ser discreta, aquela que assume apenas valores inteiros e, conseqüentemente, finitos, ou contínua, a que assume valores fracionários e um conjunto infinito de valores possíveis. A variável qualitativa é subdividida em categórica nominal e categórica ordinal. As categorias da variável categórica nominal são independentes e as da variável ordinal mantêm uma relação de ordem, regular ou não, entre si. O Quadro 5 apresenta a classificação discutida.

Quadro 5 - Classificação de variáveis

<i>Tipo de variável</i>	<i>Subtipo</i>	<i>Exemplos</i>
Quantitativa	Discreta	Número de filhos, idade em anos completos
	Contínua	Estatura, peso
Qualitativa	Catagórica nominal	Nacionalidade, raça
	Catagórica ordinal	Escolaridade com categorias, classe social

Fonte: adaptado de PEREIRA, 2001

Segundo Pereira (2001), o dado qualitativo é uma expressão de quantificação do evento qualitativo que normatiza e confere objetividade à pesquisa científica, podendo ser assim definido:

O dado qualitativo é a representação simbólica atribuída a manifestações de um evento qualitativo. É uma estratégia de classificação de um fenômeno aparentemente imponderável que, fixando premissas de natureza ontológica e semântica, instrumentaliza o reconhecimento do evento, a análise de seu comportamento e suas relações com outros eventos (PEREIRA, 2001).

Este autor afirma que a falta de familiaridade com técnicas de processamento de variáveis categóricas faz com que estas variáveis sejam tratadas de modo discursivo, o que pode, em alguns casos, gerar dispersão de informações. Após avaliar o objeto de estudo por meio de diferentes medidas, o pesquisador deve selecionar aquela que lhe permita alguma conclusão para seu estudo. O autor ressalta, ainda, que as possibilidades de processamento relacionam-se ao tipo de variável categórica (nominal ou ordinal) ou tipo de medida (escalas nominal, ordinal, intervalar ou proporcional), bem como à estratégia de sua codificação.

Para iniciar esta primeira fase da metodologia, era necessário criar uma base de testes com os dados que seriam utilizados pela RNA como atributos para a categorização dos artigos. Como a mensagem que deveria ser codificada era a presença ou a ausência da referência bibliográfica no artigo, foram utilizadas, na representação do evento, variáveis qualitativas, que assumiam apenas valores 0 ou 1.

Para validar a proposta apresentada, foram utilizados, inicialmente, os dados relacionados à presença ou à ausência de um total de 64 referências citadas em dez artigos fictícios.

Após a validação do método, foram selecionados 19 artigos do periódico *Journal of the American Society for Information Science and Technology* (JASIST), publicados em 2009 e em 2010, que apresentavam a expressão “artificial neural network” em seus títulos. Os artigos apresentavam um total de 657 referências. As referências destes artigos foram organizadas para que pudessem ser identificadas as referências que os 19 artigos apresentavam em comum e para que, posteriormente, fosse avaliada a possibilidade da utilização desta base no teste com a RNA. Esta base de artigos não foi utilizada nos testes com a RNA porque os artigos apresentavam um número reduzido de referências em comum.

A segunda base de dados foi construída, utilizando artigos de um periódico especializado, para restringir o domínio de conhecimento e encontrar um maior número de referências em comum citadas pelos autores dos artigos. Foram selecionados 200 artigos da Biblioteca Digital *Institute of Electrical and Electronics Engineers Xplore* (IEEE Xplore) que continham a expressão “neural network” nos títulos dos trabalhos. Foram escolhidos artigos publicados, no período de 2001 a 2010, preferencialmente no periódico *IEEE Transactions on Neural Network*, gerando um total de 6015 referências. Esta base de artigos foi utilizada nos testes com a RNA.

Com o número de referências elevado e com a presença de um grande número de referências repetidas, característica desta base que contribuiu para que fosse selecionada, foi necessário organizar a base de referências, eliminando-se os códigos numéricos distintos associados à mesma referência. Esta fase foi realizada por um programa criado na linguagem Java, que, além de associar um mesmo código a referências iguais, criava o arquivo que seria utilizado na entrada da RNA.

3.2.2. Criação das categorias

A segunda etapa metodológica consistiu na criação, pela RNA, das categorias de artigos. Para realizar a categorização, foi utilizado o *software Matlab (Matrix Laboratory)*. O *toolbox* selecionado foi o *Neural Network*, que emprega a rede SOM.

Para gerar as categorias, as informações contidas nas bases de dados foram utilizadas, pela RNA, que dividiu os artigos em grupos que apresentavam alguma similaridade associada às suas referências ou ao seu ano de publicação.

Foram realizados três experimentos de categorização utilizando RNA. No primeiro experimento, foram utilizados o ano de publicação dos artigos e suas referências como dados de entrada da RNA. Neste experimento, o ano foi representado pelo seu valor

absoluto. No segundo experimento, o ano foi representado pelo número correspondente aos seus dois últimos dígitos dividido por 10. No terceiro experimento, o ano de publicação dos artigos não foi utilizado como atributo.

Cada um dos 200 artigos foi representado pela letra A e pelo código numérico a ele associado na tabela de artigos. As 6015 referências citadas pelos 200 artigos foram representadas pela letra R e pelo código numérico associado a ela na tabela de referências. Deste modo, o artigo 4 foi denominado A4 e a referência 44 foi denominada R44.

Depois de ajustar alguns parâmetros da RNA e variar sua topologia, alterando-se o número de neurônios da camada de saída, optou-se por definir topologias que gerassem 4, 9, 10, 12, 16, 25 e 36 categorias de artigos. O objetivo da variação do número de categorias geradas era verificar se, alterando-se o número de grupos gerados na saída da RNA, os mesmos artigos continuariam agrupados. Neste caso, os grupos de artigos que se repetiam nas saídas das RNA de topologias distintas poderiam ser identificados. Foram escolhidas as quatro topologias que apresentavam artigos concentrados nos mesmos números de grupos. Esta opção foi realizada na expectativa de que, concentrando os artigos no mesmo número de grupos, a RNA estivesse mantendo, nestes grupos, os mesmos artigos.

3.2.3. Identificação das características comuns aos grupos

Esta etapa avaliou a saída da RNA e identificou, entre as topologias, os grupos que continham artigos em comum. O objetivo desta etapa foi identificar os fatores que influenciaram a formação dos grupos e identificar possíveis relações semânticas entre os artigos do mesmo grupo. A análise dos parâmetros comuns aos artigos pertencentes ao mesmo grupo e das respectivas características identificou os atributos utilizados pela RNA para realizar a categorização proposta em sua saída.


No primeiro experimento, foram encontrados grupos distintos em cada uma das topologias utilizadas pela RNA. Estes grupos foram representados por um número de identificação, pelo número do experimento e pela topologia à qual pertenciam. A expressão GrupoUm_E1_4 nomeava o grupo 1 do primeiro experimento associado à topologia que gerava 4 categorias. Foram selecionadas, como descrito na seção anterior, as topologias da RNA que concentravam a maioria dos artigos no mesmo número de grupos.

Para identificar os artigos que compunham cada um dos grupos em cada uma das topologias selecionadas, foram analisados os dados de saída da RNA, ou seja, as matrizes binárias, apresentadas no CD anexo a este trabalho, compostas pelo número de linhas igual ao

número de categorias e por 200 colunas, cada uma delas representando um dos artigos utilizados na base de dados. O Apêndice D, para ilustração, mostra a saída da RNA, no experimento 1, para a topologia que gerou 4 categorias. Os grupos foram, então, separados por cores e nomeados por letras para que, realçados, pudessem ser encontrados os seus correspondentes nas outras topologias. A comparação dos grupos de cores encontrados em cada uma das topologias facilitou a identificação dos grupos. A identificação dos grupos em cada uma das topologias utilizou como critério a repetição do maior número de artigos em um mesmo grupo observado.

Para cada um dos grupos selecionados para análise, foi criada uma tabela, que apresentava os artigos pertencentes ao grupo em cada uma das topologias. No caso da seleção das topologias de 10, 12, 16 e 25 categorias, como as topologias que concentrassem os artigos no mesmo número de grupos, o grupo 2, por exemplo, seria avaliado nas quatro topologias correspondentes, recebendo os nomes GrupoDois_E1_10, GrupoDois_E1_12, GrupoDois_E1_16 e GrupoDois_E1_25. Observando-se estes quatro grupos, foram selecionados os artigos apresentados na maioria ou na totalidade das quatro topologias, gerando o grupo que representaria o grupo 2 nas quatro topologias, denominado GrupoDois_E1. A Figura 14 exemplifica esta análise tomando como base a topologia que gerou 10 grupos.

Figura 14 - Criação dos grupos representantes de todas as topologias



Para avaliar as características dos artigos de cada grupo, foram construídas tabelas com o número de referências citadas pelos artigos, os códigos numéricos associados às referências dos artigos, o ano de publicação dos artigos e as respectivas palavras-chave.

Avaliando-se esta tabela, foi possível gerar outras tabelas que apresentavam as referências comuns a cada dois artigos do grupo, o número de vezes que as referências se repetiam nos artigos do grupo, o número de referências que se repetiam, as referências repetidas e os artigos que apresentavam tais referências.

Foi criada, então, uma figura, a partir dos dados contidos nas tabelas, para que pudessem ser visualizados os artigos, representados por seus respectivos códigos numéricos e relacionados pelo número de referências citadas em comum.

No segundo e no terceiro experimentos, o método de análise dos artigos agrupados pela RNA foi semelhante ao utilizado no experimento 1. Após a seleção das topologias cujo número de grupos gerados era semelhante, foram identificados os artigos pertencentes aos grupos e suas respectivas características. Nestes experimentos, diferentemente do experimento 1, foram selecionados os artigos que se repetiam em mais de um grupo de cada uma das topologias selecionadas. O experimento 1 selecionou os artigos que se repetiam na maioria ou na totalidade dos grupos das topologias selecionadas. Esta alteração de procedimento está diretamente ligada ao número de grupos gerados e ao número de artigos concentrado nos grupos avaliados. Nos experimentos 2 e 3, foram identificados os autores dos artigos dos grupos que apresentavam um grande número de referências em comum e as referências mais citadas por este grupo de autores. Foram apresentadas informações relativas à formação destes autores, à área de atuação e aos seus principais interesses de pesquisa.

3.2.4. Utilização de um software de categorização baseado em palavras-chave

Nesta etapa, foi utilizada uma ferramenta de categorização de artigos utilizando-se as palavras-chave dos artigos como atributo. A proposta era comparar os grupos gerados por esta ferramenta com os grupos gerados nos experimentos realizados pela RNA.

CAPÍTULO 4: DESENVOLVIMENTO DA BASE DE TESTES

Antes de iniciar a construção da base de testes, foi criado um protótipo que permitisse a validação da metodologia proposta, assegurando-se, assim, que a saída da RNA pudesse criar grupos de artigos que tivessem referências comuns. Na etapa de desenvolvimento da base de testes, um grupo de artigos foi selecionado e organizado para criar o arquivo que seria utilizado na entrada da RNA. A construção da base de testes exigiu atenção relativa ao número de referências comuns citadas pelos artigos já que as citações comuns foram usadas como atributo de categorização.

4.1. Validação da proposta por meio de um protótipo

Para validar a proposta sugerida pelas etapas descritas anteriormente, foi proposto o treinamento de uma RNA, utilizando-se dez artigos fictícios, com algumas referências em comum. Por apresentar um número reduzido de artigos e de referências, este treinamento pôde ser avaliado por uma análise simples. Os dez artigos apresentaram, juntos, um total de 64 referências. Os resultados alcançados na validação do método por meio do protótipo, já relatados no artigo publicado na revista DataGramZero, são descritos nos próximos parágrafos (MEIRELES; CENDÓN, 2011).

A primeira seleção de experimentos utilizou, na entrada da RNA, valores numéricos associados às referências pela base 2. Cada um dos 64 bits utilizados foi associado a uma referência e, portanto, cada entrada da RNA recebeu, para cada artigo, a informação da presença ou da ausência das 64 referências encontradas.

Cada referência recebeu um código. No protótipo, este código foi um número correspondente a 2^n , sendo o valor de “n” inteiro, variando de 0 a 63. Se, por exemplo, um artigo possuía as 10 principais referências cadastradas, a cada uma delas foram associados os números $2^0, 2^1, 2^2, 2^3, 2^4, 2^5, 2^6, 2^7, 2^8, 2^9$. Este artigo foi identificado, na entrada da RNA, pelo número na base 2 correspondente a:

1111111111.0000000000.0000000000.0000000000.0000000000.0000000000.0000

A este artigo correspondeu o valor numérico, na base 10, igual à soma destes valores, ou seja:

$$2^0 + 2^1 + 2^2 + 2^3 + 2^4 + 2^5 + 2^6 + 2^7 + 2^8 + 2^9 = 1023$$

Na Tabela 1, o dígito 1 determinou a presença das 64 referências em cada um dos dez artigos do protótipo. Os artigos foram numerados de 1 a 10 e as referências foram apresentadas pelos valores 2^n associados a cada uma delas.

Tabela 1 - Relação de artigos e referências citadas

Referências citadas Artigos	2 ⁰	2 ¹	2 ²	2 ³	2 ⁴	2 ⁵	2 ⁶	2 ⁷	2 ⁸	2 ⁹	2 ¹⁰	2 ¹¹	2 ¹²	2 ¹³	2 ¹⁴	2 ¹⁵	2 ¹⁶	2 ¹⁷	2 ¹⁸	2 ¹⁹	2 ²⁰
1	1		1		1		1		1		1		1		1		1		1		
2	1		1		1										1		1		1		
3					1		1		1		1		1		1						
4		1																			1
5		1			1					1											1
6		1																			1
7								1								1					
8								1								1					
9								1						1		1					
10				1								1						1		1	

Referências citadas Artigos	2 ²¹	2 ²²	2 ²³	2 ²⁴	2 ²⁵	2 ²⁶	2 ²⁷	2 ²⁸	2 ²⁹	2 ³⁰	2 ³¹	2 ³²	2 ³³	2 ³⁴	2 ³⁵	2 ³⁶	2 ³⁷	2 ³⁸	2 ³⁹	2 ⁴⁰	2 ⁴¹
1														1							
2														1							
3														1							
4								1										1			
5								1			1							1			
6								1										1			
7	1	1							1					1					1	1	1
8	1	1							1						1				1		
9	1	1	1	1	1				1						1				1		
10						1	1			1		1	1			1	1				

Referências citadas Artigos	2 ⁴²	2 ⁴³	2 ⁴⁴	2 ⁴⁵	2 ⁴⁶	2 ⁴⁷	2 ⁴⁸	2 ⁴⁹	2 ⁵⁰	2 ⁵¹	2 ⁵²	2 ⁵³	2 ⁵⁴	2 ⁵⁵	2 ⁵⁶	2 ⁵⁷	2 ⁵⁸	2 ⁵⁹	2 ⁶⁰	2 ⁶¹	2 ⁶²	2 ⁶³
1								1														1
2								1														1
3								1														1
4									1	1	1	1		1					1	1	1	
5		1			1														1	1	1	
6									1			1			1				1	1	1	
7							1									1						
8			1	1		1							1									
9				1																		
10	1			1														1			1	1

Os dados apresentados na tabela e o ano de publicação de cada um dos artigos foram utilizados na entrada da RNA. A RNA avaliou estes dados, procurando encontrar características ou padrões significativos, que pudessem ser considerados similaridades ou diferenças, para realizar o agrupamento esperado na saída.

Como resultado do estudo preliminar realizado, observou-se que, após o treinamento da RNA, descrito no Apêndice A, os artigos foram agrupados em quatro categorias mutuamente exclusivas. A análise das características comuns dos artigos pertencentes a uma mesma categoria identificou os atributos utilizados pela RNA para realizar a categorização proposta em sua saída. No Quadro 6, podem ser observadas as características comuns às quatro categorias geradas.

Quadro 6 - Categorias geradas pela RNA

Categorias	Artigos (ano de publicação)	Características
1	1(2002), 2(2003) e 3(2003)	5 referências comuns aos três artigos e 4 comuns aos dois primeiros artigos
2	4(2005), 5(2006) e 6(2006)	7 referências comuns aos três artigos e 1 referência comum aos artigos 4 e 6
3	7(2007), 8(2008) e 9(2006)	6 referências comuns aos três artigos e 2 referências comuns aos artigos 8 e 9
4	10(2005)	1 referência comum aos artigos 8 e 9, 1 referência comum aos artigos 4, 5 e 6 e 1 referência comum aos artigos 1, 2 e 3

A primeira categoria selecionou os artigos 1, 2 e 3, que apresentaram cinco referências comuns aos três artigos e quatro referências comuns aos dois primeiros artigos. Estes artigos foram publicados nos anos de 2002, 2003 e 2003 respectivamente.

A segunda categoria agrupou os artigos 4, 5 e 6, que apresentaram sete referências comuns aos três artigos e uma referência comum aos artigos 4 e 6. Os artigos foram publicados em 2005, 2006 e 2006.

A terceira categoria foi composta pelos artigos 7, 8 e 9. Seis referências eram comuns aos três artigos e duas referências, comuns aos artigos 8 e 9. Considerou-se 2007, 2008 e 2006, como o ano de publicação destes artigos.

O artigo 10 foi indicado para a quarta categoria. Este artigo tinha referências comuns aos outros oito, dos nove artigos restantes, e seu ano de publicação era 2005.

Para realizar esta categorização, a rede utilizou o ano de publicação do artigo e as referências de cada um deles. Após alguns ajustes nos parâmetros da RNA, o resultado apresentado sugeria que a categorização havia sido realizada com sucesso, agrupando artigos que apresentaram o maior número de referências em comum e anos de publicação próximos.

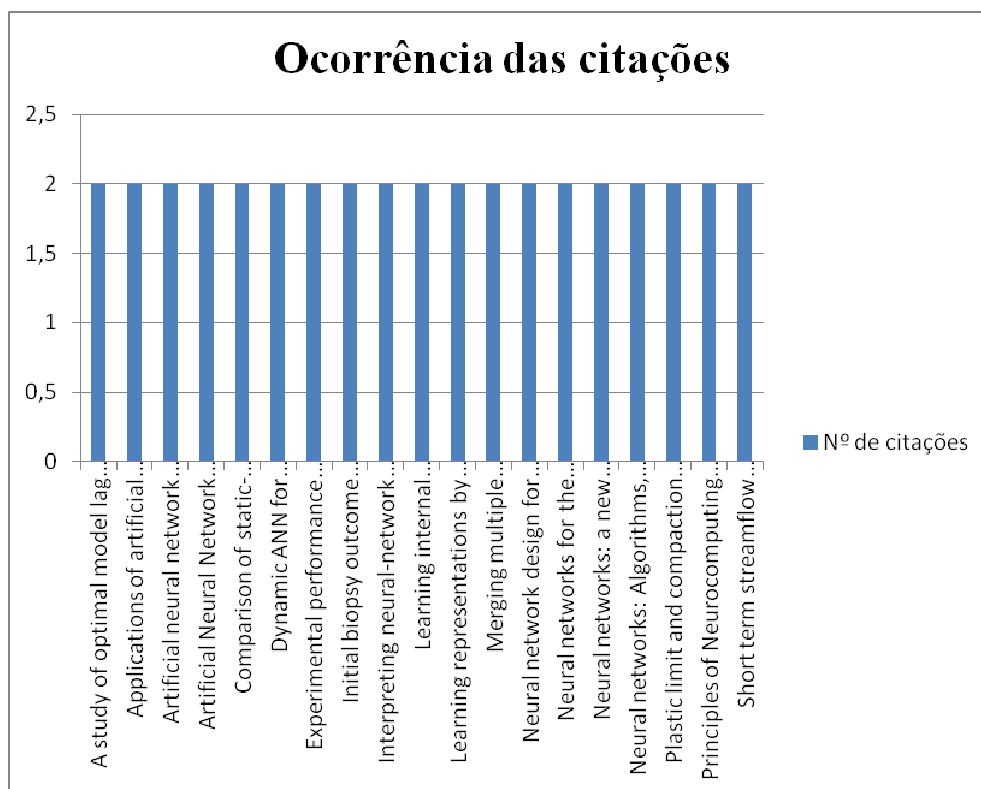
4.2. Criação da base de dados *JASIST*

Foram selecionados 19 artigos do periódico *Journal of the American Society for Information Science and Technology*, disponível no Portal de Periódicos Capes. Os artigos selecionados foram publicados nos anos de 2009 e 2010 e recuperados por uma busca avançada que exigia que a expressão “artificial neural network” estivesse presente nos títulos de artigos.

Foram criadas duas tabelas, a primeira contendo os dados dos artigos e a segunda, os dados das referências citadas nestes artigos. A primeira tabela listava os títulos dos artigos, as palavras-chave, o ano de sua publicação, o número de referências citadas por cada artigo e os códigos numéricos associados às referências citadas no artigo, que eram criados na tabela de referências. A tabela de referências citava, na ordem do cadastramento, os títulos das referências, os autores e o ano de publicação de cada referência.

Após a realização do cadastro das 662 referências citadas pelos 19 artigos, observou-se, na organização alfabética das referências, que apenas dezenove referências se repetiam. Cada uma destas dezenove referências se repetiu, no máximo, duas vezes como pode ser observado na Figura 15.

Figura 15 - Número de citações por referência: base de dados JASIST




Como a proposta da metodologia de categorização realizada pela RNA utilizava, como atributos de categorização, as referências citadas pelos artigos e o ano de publicação do artigo, era fundamental que existisse um grande número de referências em comum entre artigos distintos da base criada. A característica desta base de dados, na qual os autores dos artigos citavam poucas referências em comum, dificultaria o trabalho da RNA em encontrar similaridades entre os artigos que pudesse justificar a criação de grupos. Esta base foi, neste instante, descartada.

A base seguinte, utilizada, neste trabalho, como base de teste principal, tentou reunir artigos de um domínio de conteúdo mais restrito e com especificidades próprias para que pudesse ser encontrado um número maior de repetições entre as referências citadas pelos artigos. Escolheu-se, então, um periódico especializado para restrição do domínio e garantia de que os artigos recuperados apresentassem uma relação semântica mais forte.

4.3. Criação da base de dados *IEEE*

Foram selecionados, inicialmente, 19 artigos do periódico *IEEE Transactions on Neural Networks*. A busca avançada foi realizada, selecionando-se os artigos que continham as palavras “neural network” no título do documento. O refinamento da busca permitiu limitá-la a artigos publicados em periódicos nos anos de 2009 e 2010. Foram utilizados artigos classificados no assunto “*Computing & Processing (Hardware/Software)*”. Nestes 19 artigos, foram encontradas 846 citações. Destas, 86 citações se repetiram e algumas delas foram citadas por sete artigos distintos, o que caracterizou a amostra como sendo mais adequada do que a anterior para a proposta deste trabalho. A Figura 16 apresenta as 16 citações mais referenciadas e o número de vezes que cada uma foi citada.

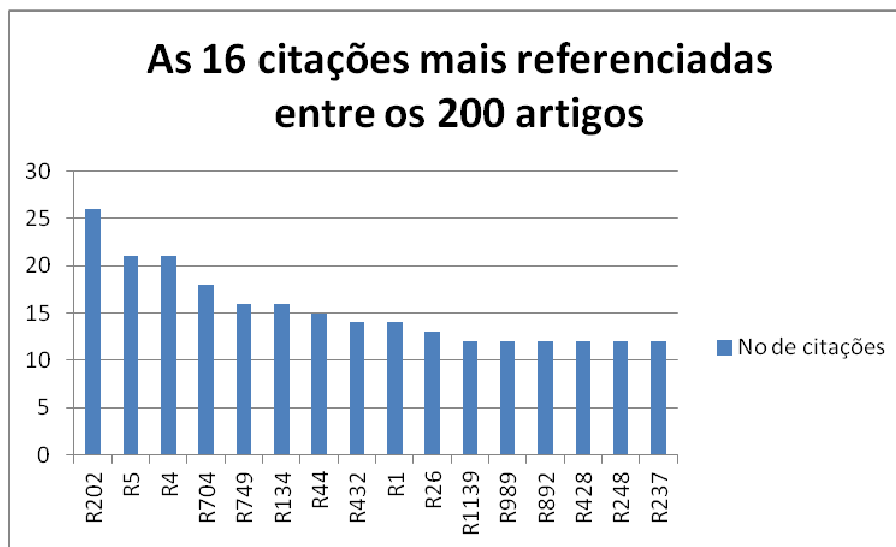
Figura 16 - Número de citações por referência: base de dados *IEEE*



A base de dados foi, então, ampliada para 200 artigos, publicados entre 2001 e 2010. Utilizou-se a busca avançada da Biblioteca Digital *IEEE Xplore*. Foram escolhidos, na busca do ano, preferencialmente, artigos publicados no periódico *IEEE Transactions on Neural Networks*. Foram selecionados, usualmente, os 20 primeiros artigos que apresentassem acesso completo ao texto do artigo e cujas referências apresentassem todos os dados exigidos para o cadastramento da base de referências. As referências dos artigos selecionados somaram

um total de 6015 referências bibliográficas. A Figura 17 apresenta as 16 citações mais referenciadas pelos 200 artigos que compõem a base de dados utilizada no trabalho. Neste gráfico, as citações foram denominadas pela letra R seguida do número com o qual foram cadastradas na base de referências.

Figura 17 - Número de citações por referência: base de dados *IEEE* completa



Entre as 16 referências mais citadas pelos 200 artigos, observa-se que as referências são citadas, no mínimo, por 10 artigos distintos, o que confirma a expectativa de que a base apresenta um número de artigos com um significativo número de referências em comum.

4.4. Pré-processamento da base de dados

Segundo Durães (2009), a etapa de pré-processamento compreende as funções relacionadas à captação, à organização, ao tratamento e à preparação dos dados. Esta etapa do trabalho envolveu desde a identificação de dados incorretos até o ajuste da formatação dos dados, eliminando erros do banco de dados e otimizando, assim, as próximas etapas do processo.

4.4.1. Eliminação das inconsistências dos dados

O objetivo da fase de tratamento dos dados, neste trabalho, foi preparar esses dados, assegurando a eficiência do processo de identificação de citações iguais. Durães (2009) afirma que oitenta por cento do tempo consumido em todo o processo de pré-processamento

de aplicações reais se concentra na limpeza de dados. Informações ausentes, errôneas ou inconsistentes nas bases de dados devem ser corrigidas de modo a não comprometer a qualidade dos dados. Além dos erros identificados nos dados, contendo valores considerados divergentes do padrão normal esperado, podem ser encontradas inconsistências, contendo alguma discrepância semântica. A fase de limpeza dos dados envolveu uma verificação da consistência das informações, a correção de possíveis erros e o preenchimento ou a eliminação de valores desconhecidos e redundantes. Algumas destas inconsistências foram apresentadas nos próximos parágrafos.

A fase de pré-processamento das bases de dados dos artigos e de suas referências preparou os dados pra evitar que qualquer inconsistência prejudicasse a criação do arquivo que foi utilizado na entrada da RNA.

No cadastramento dos dados dos artigos e de suas referências, foram identificados alguns caracteres inseridos nos títulos, nas palavras-chave e nos nomes dos autores. Antes de iniciar a comparação das citações, estes caracteres foram excluídos para que o programa pudesse avaliar a existência de referências repetidas. Eram códigos em HTML usados para que a grafia dos nomes fosse indicada corretamente, em páginas web, em nomes que apresentavam acento ou expressão alfanumérica. O nome do autor M. Möller, por exemplo, foi registrado em alguns artigos como M. Møl;ller e o autor P. Julián, como P. Julián.

Algumas palavras foram encontradas, nos títulos do mesmo artigo referenciado em mais de um trabalho, no singular e no plural (exemplo, *inequality* e *inequalities*) ou com o acréscimo de aspas ou de hífen. Estas diferenças entre os títulos do mesmo artigo referenciado em mais de um trabalho eram identificadas pelo programa utilizado na fase de preparação do arquivo de entrada da RNA como uma diferença entre os títulos dos trabalhos. Foram encontradas, também, duas palavras sem o espaçamento necessário para separá-las ou títulos incompletos e sem algumas das palavras (exemplo, *for solving monotone variational...*, *for monotone...* ou *for solvingmonotone...*). No cadastramento dos autores dos trabalhos, foram identificados sobrenomes abreviados de modo distinto (por exemplo, X. Hu e X. L. Hu) ou, ainda, a ausência de algum dos autores.

Além destes erros de edição ou de registro distinto de trabalhos iguais, foram encontrados problemas como a utilização, no mesmo artigo, de citações repetidas. Um dos artigos, o numerado na tabela de artigos com o número 66 e intitulado *A New Jacobian Matrix for Optimal Learning of Single-Layer Neural Networks*, por exemplo, apresentava 46 referências bibliográficas. No entanto, existiam duas das 46 referências repetidas, o que

reduzia o número de referências para 44. A primeira referência, transcrita a seguir, se repetia com o número 18 e com o número 36, como pode ser observado na Figura 18.

G.-B. Huang , Q.-Y. Zhu , K. Z. Mao , C.-K. Siew , P. Saratchandran and N. Sundararajan "Can threshold networks be trained directly?", *IEEE Trans. Circuits Syst. II, Exp. Briefs*, vol. 53, pp.187 2006.

Figura 18 - Repetição das referências de número 18 e 36

- | | |
|---|--|
| <p>[9] S. Liu and J. Wang, "A simplified dual neural network for quadratic programming with its KWTA application," <i>IEEE Trans. Neural Netw.</i>, vol. 17, no. 6, pp. 1500–1510, Nov. 2006.</p> <p>[10] F. L. Lewis and T. Parisini, "Guest editorial: Neural network feedback with guaranteed stability," <i>Int. J. Control</i>, vol. 70, no. 3, pp. 337–339, 1998.</p> <p>[11] J.-T. Tsai, J.-H. Chou, and T.-K. Liu, "Tuning the structure and parameters of a neural network by using hybrid Taguchi-genetic algorithm," <i>IEEE Trans. Neural Netw.</i>, vol. 17, no. 1, pp. 69–80, Jan. 2006.</p> <p>[12] N. Xie and H. Leung, "Blind equalization using a predictive radial basis function neural network," <i>IEEE Trans. Neural Netw.</i>, vol. 16, pp. 709–720, May 2005.</p> <p>[13] H. Leung, T. Lo, and S. Wang, "Prediction of noisy chaotic time series using an optimal radial basis function neural network," <i>IEEE Trans. Neural Netw.</i>, vol. 12, no. 5, pp. 1163–1172, Sep. 2001.</p> <p>[14] C. C. Min, D. Srinivasan, and R. Cheu, "Neural networks for continuous online learning and control," <i>IEEE Trans. Neural Netw.</i>, vol. 17, no. 5, pp. 1511–1531, Nov. 2006.</p> <p>[15] A. Zhu and S. Yang, "A neural network approach to dynamic task assignment of multirobots," <i>IEEE Trans. Neural Netw.</i>, vol. 17, no. 5, pp. 1278–1287, Sep. 2006.</p> <p>[16] G.-B. Huang, P. Saratchandran, and N. Sundararajan, "A generalized growing and pruning RBF (ggap-RBF) neural network for function approximation," <i>IEEE Trans. Neural Netw.</i>, vol. 16, no. 1, pp. 57–67, Jan. 2005.</p> <p>[17] J. Peng, K. Li, and D. S. Huang, "A hybrid forward algorithm for RBF neural network construction," <i>IEEE Trans. Neural Netw.</i>, vol. 17, no. 6, pp. 1439–1451, Nov. 2006.</p> <p>[18] G.-B. Huang, Q.-Y. Zhu, K. Z. Mao, C.-K. Siew, P. Saratchandran, and N. Sundararajan, "Can threshold networks be trained directly?", <i>IEEE Trans. Circuits Syst. II, Exp. Briefs</i>, vol. 53, no. 3, pp. 187–191, Mar. 2006.</p> | <p>[27] D. Gorinevsky, "An approach to parametric nonlinear least square optimization and application to task-level learning control," <i>IEEE Trans. Autom. Control</i>, vol. 42, no. 7, pp. 912–927, Jul. 1997.</p> <p>[28] M. T. Hagan and M. B. Menhaj, "Training feedforward networks with the Marquardt algorithm," <i>IEEE Trans. Neural Netw.</i>, vol. 5, no. 5, pp. 989–993, Sep. 1994.</p> <p>[29] S. Kollias and D. Anastassiou, "An adaptive least squares algorithm for the efficient training of multilayered networks," <i>IEEE Trans. Circuit Syst.</i>, vol. 36, no. 8, pp. 1092–1101, Aug. 1989.</p> <p>[30] N. Ampazis and S. J. Perantonis, "Two highly efficient second-order algorithms for training feedforward networks," <i>IEEE Trans. Neural Netw.</i>, vol. 13, no. 5, pp. 1064–1074, Sep. 2002.</p> <p>[31] H. Peng, T. Ozaki, V. Haggan-Ozaki, and Y. Toyoda, "A parameter optimization method for radial basis function type models," <i>IEEE Trans. Neural Netw.</i>, vol. 14, no. 2, pp. 432–438, Mar. 2003.</p> <p>[32] K. Li, J. Peng, and G. W. Irwin, "A fast nonlinear model identification method," <i>IEEE Trans. Autom. Control</i>, vol. 50, no. 8, pp. 1211–1216, Aug. 2005.</p> <p>[33] K. Li, J. Peng, and E. W. Bai, "A two-stage algorithm for identification of nonlinear dynamic systems," <i>Automatica</i>, vol. 42, no. 7, pp. 1189–1197, 2006.</p> <p>[34] S. McLoone, M. D. Brown, G. W. Irwin, and G. Lightbody, "A hybrid linear/nonlinear training algorithm for feedforward neural networks," <i>IEEE Trans. Neural Netw.</i>, vol. 9, no. 4, pp. 669–684, Jul. 1998.</p> <p>[35] S. Chen, S. A. Billings, and W. Luo, "Orthogonal least squares methods and their application to non-linear system identification," <i>Int. J. Control</i>, vol. 50, no. 5, pp. 1873–1896, 1989.</p> <p>[36] G.-B. Huang, Q.-Y. Zhu, K. Z. Mao, C.-K. Siew, P. Saratchandran, and N. Sundararajan, "Can threshold networks be trained directly?", <i>IEEE Trans. Circuits Syst. II, Exp. Briefs</i>, vol. 53, no. 3, pp. 187–191, Mar. 2006.</p> |
|---|--|

Fonte: PENG; LI; IRWIN, 2008

A segunda referência repetida no mesmo artigo, citada a seguir, se repetia com o número 5 e com o número 35. A repetição pode ser constatada observando-se a referência 35, na Figura 15, e a referência 5 na Figura 19.

S. Chen , S. A. Billings and W. Luo "Orthogonal least squares methods and their application to non-linear system identification", *Int. J. Control*, vol. 50, pp.1873 1989.

Figura 19 - Repetição das referências 5 e 35

IEEE TRANSACTIONS ON NEURAL NETWORKS, VOL. 19, NO. 1, JANUARY 2008

REFERENCES

- [1] J. Park and I. W. Sandberg, "Universal approximation using radial-basis-function networks," *Neural Comput.*, vol. 3, pp. 246–257, 1991.
- [2] K. Hornik, M. Stinchcombe, and H. White, "Multilayer feedforward networks are universal approximator," *Neural Netw.*, vol. 2, pp. 359–366, 1989.
- [3] R. M. Sanner and J. E. Slotine, "Gaussian networks for direct adaptive control," *IEEE Trans. Neural Netw.*, vol. 3, no. 6, pp. 837–863, Nov. 1992.
- [4] S. S. Ge, C. C. Hang, T. H. Lee, and T. Zhang, *Stable Adaptive Neural Network Control*. Boston, MA: Kluwer, 2001.
- [5] S. Chen, S. A. Billings, and W. Luo, "Orthogonal least squares methods and their application to non-linear system identification," in *Int. J. Control*, 1989, vol. 50, pp. 1873–1896.
- [6] S. Huang, K. Tan, and T. Lee, "Nonlinear adaptive control of interconnected systems using neural networks," *IEEE Trans. Neural Netw.*, vol. 17, no. 1, pp. 243–246, Jan. 2006.
- [7] B. Lin, B. Lin, F. Chong, and F. Lai, "Higher-order-statistics-based radial basis function networks for signal enhancement," *IEEE Trans. Neural Netw.*, vol. 18, no. 3, pp. 823–832, May 2007.
- [8] A. Vemuri, M. Polycarpou, and S. Diakouritis, "Neural network based fault detection and accommodation in robotic manipulators," *IEEE Trans. Robot. Autom.*, vol. 14, no. 2, pp. 342–348, Apr. 1998.
- [9] S. Liu and J. Wang, "A simplified dual neural network for quadratic programming with its KWTA application," *IEEE Trans. Neural Netw.*, vol. 17, no. 6, pp. 1500–1510, Nov. 2006.
- [10] F. L. Lewis and T. Parisini, "Guest editorial: Neural network feedback with guaranteed stability," *Int. J. Control*, vol. 70, no. 3, pp. 337–339, 1998.

Fonte: PENG; LI; IRWIN, 2008

Para este caso, a entrada da RNA considerou apenas as 44 referências distintas.

4.4.2. Preparação do arquivo de entrada da RNA

Cada uma das citações recebeu, durante o respectivo cadastramento, um código numérico para representá-la na entrada da RNA. Este código, presente na representação do artigo, definia a presença desta citação no artigo. Como as citações se repetiam em vários artigos, era fundamental que cada citação estivesse cadastrada com um único código numérico, mesmo que se repetisse em diferentes pontos da tabela, associada a artigos distintos. Para garantir esta condição e associar um único código numérico a uma mesma publicação, mesmo que referenciada por artigos distintos, foi elaborado um programa na linguagem *Java*. O programa gerava, também, o arquivo que foi utilizado na entrada da RNA.

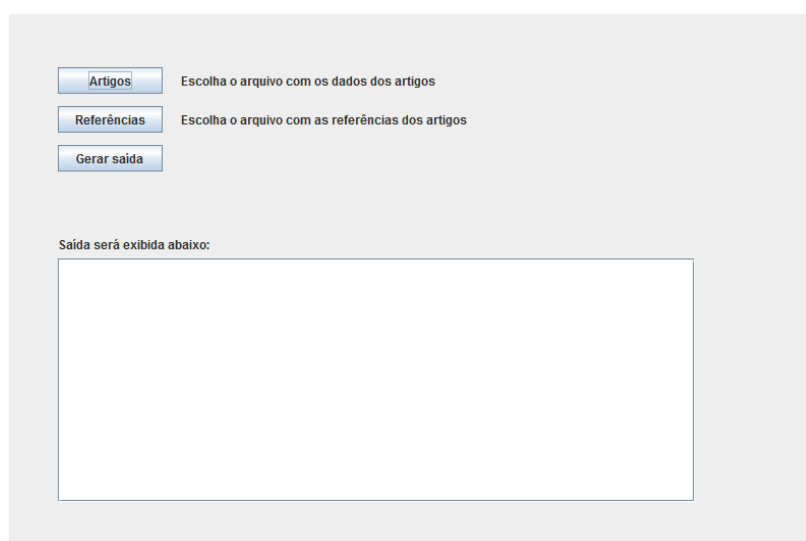
4.4.2.1 Eliminação de códigos numéricos distintos

Ao executar o programa, muitas das referências foram identificadas como distintas e apresentadas no processamento com as inconsistências definidas na fase anterior. Estas inconsistências, presentes nos títulos destes artigos e nos nomes dos autores, foram

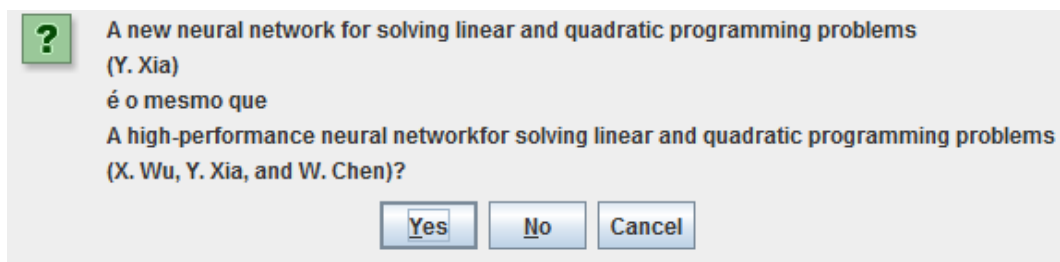
alteradas, manualmente, baseadas nas informações apresentadas pela Biblioteca digital *IEEE Xplore*.

A interface inicial do programa elaborado solicita os arquivos com os dados dos artigos selecionados e com os dados das respectivas referências destes artigos. Esta interface pode ser observada na Figura 20.

Figura 20 - Interface inicial do programa



O programa que compara as citações utiliza, inicialmente, o ano de publicação dos trabalhos citados para comparar os trabalhos e constatar se é o mesmo trabalho. A partir desta constatação, o programa verifica o percentual de palavras iguais nos títulos das citações. Se o ano de publicação é igual e se o percentual de palavras repetidas é igual a 100%, o programa substitui o maior código numérico pelo menor, garantindo a presença de um único código para a mesma citação. Se o percentual varia entre 60% e 100%, o responsável pela entrada de dados nas tabelas é consultado, pela interface do programa Java, para que avalie, pela comparação dos títulos e dos autores da obra, se as duas referências selecionadas são equivalentes. Nesta fase do trabalho, todas as diferenças encontradas pelo programa relativas à mesma citação foram eliminadas manualmente. Desse modo, eliminando-se as inconsistências, o próprio programa identificava a semelhança de 100% dos títulos e dos autores sem a necessidade de consultar o usuário pela interface. A janela de interface que compara as citações e consulta o usuário é apresentada na Figura 21.

Figura 21 - Janela de interface com o usuário

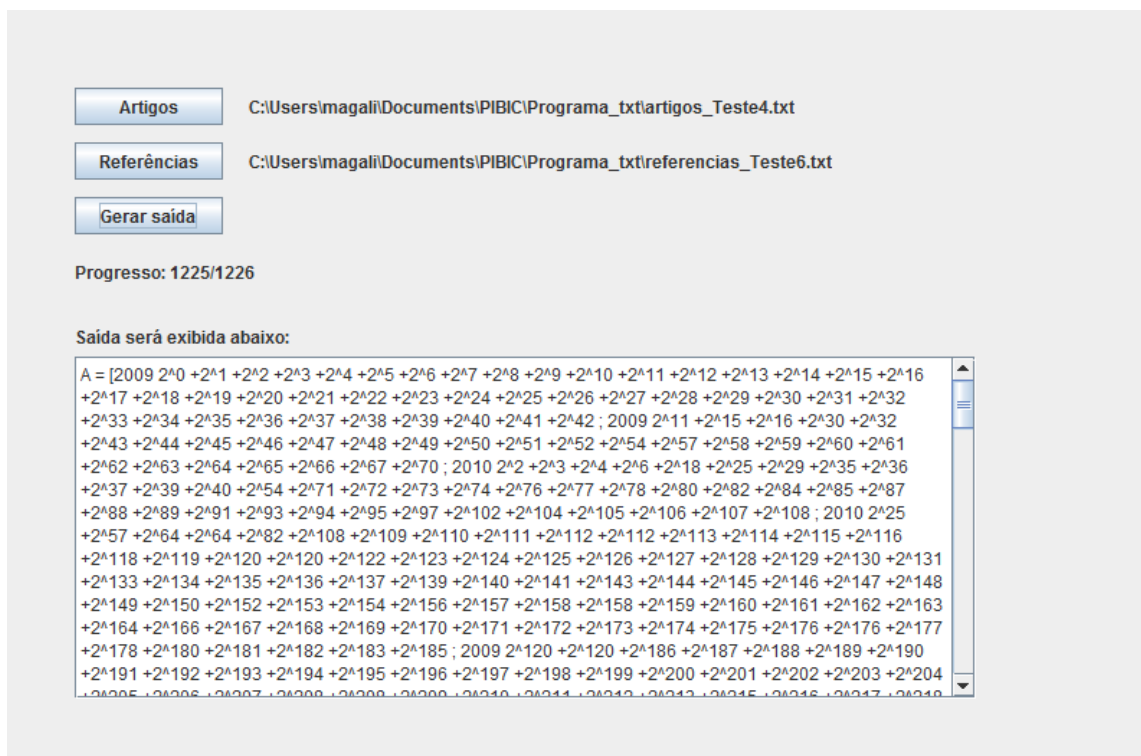
Se a resposta do usuário é “No”, como deve ser no exemplo utilizado pela Figura 18, onde os títulos dos trabalhos são diferentes, o programa mantém os códigos numéricos de cada uma das referências e continua sua execução. Em caso de constatada, pelo responsável pela entrada de dados nas tabelas, a existência de duas referências idênticas cadastradas com códigos numéricos diferentes, os títulos dos trabalhos são iguais e a resposta para a pergunta é “Yes”. O código numérico de maior valor é, então, substituído pelo de menor valor de modo que as referências bibliográficas iguais recebam, sempre, o mesmo código numérico na entrada da RNA.

4.4.2.2 Geração do arquivo utilizado pela RNA

Depois de organizada a base de referências e garantida a existência de um único código para a mesma referência, foi necessário gerar o arquivo utilizado pela RNA. Para gerar a sequência de dados utilizada na entrada da RNA, o programa, durante o processamento dos dados das bases de artigos e de referências, gerou um número para cada artigo. Este número, utilizado na entrada da RNA, contém a informação da presença ou da ausência, no artigo, de cada uma das 6015 referências cadastradas.

Na primeira fase de testes, cada uma das referências foi associada a um número $2n-1$, na base 2, como nos testes realizados com o protótipo, sendo “n” o código numérico designado à referência na tabela de artigos e na tabela de referências. A presença de cada uma das referências em um determinado artigo foi representada pelo valor 1 na posição relativa ao número designado para a referência e a ausência, pelo valor 0. A Figura 22 apresenta um resultado parcial gerado pelo programa em um dos testes realizados.

Figura 22 - Geração da entrada da RNA



A primeira linha da janela apresentada na Figura 22 pode ser utilizada como exemplo para um melhor entendimento do arquivo gerado pelo programa para ser utilizado na entrada da RNA. A linha caracterizava o primeiro artigo cadastrado, publicado em 2009 e que possuía 43 citações:

$$A = [2009 2^0 +2^1 +2^2 +2^3 +2^4 +2^5 +2^6 +2^7 +2^7 +2^7 +2^9 +2^10 +2^11 +2^12 +2^13 +2^14 +2^15 +2^16 +2^17 +2^18 +2^19 +2^20 +2^21 +2^23 +2^24 +2^25 +2^26 +2^27 +2^28 +2^29 +2^30 +2^31 +2^32 +2^33 +2^34 +2^35 +2^36 +2^37 +2^38 +2^39 +2^40 +2^41 +2^42;$$

Cada um dos expoentes representava o código numérico da referência subtraído de uma unidade. Estavam, portanto, associados, ao primeiro artigo, as suas 43 referências, cadastradas com códigos numéricos que variavam de 1 a 43 e que estavam representadas no expoente pelos valores que variavam de 0 a 42.

A validação do *software* desenvolvido exigiu a utilização de bases que pudessem ser avaliadas manualmente. Foram criadas, assim, bases menores de artigos e de referências para garantir que o software desenvolvido funcionasse corretamente, sem a presença de erros

gerados no seu desenvolvimento. Os primeiros testes envolveram os 10 primeiros artigos e suas 456 referências. A segunda etapa de testes foi realizada utilizando-se os 30 primeiros artigos e suas 1226 referências. A cada execução do programa, novas correções das bases foram realizadas, com o objetivo de tornar o processo de identificação de semelhança de citações o mais automático possível e capaz de ser realizado pelo programa sem consultar o usuário. A terceira etapa de testes utilizou a base completa de artigos e suas 6015 referências.

Para trabalhar com as 6015 referências, optou-se por utilizar oito entradas da RNA. As referências foram, então, distribuídas em entradas distintas da RNA, definindo-se, assim, que o código numérico de cada referência não ultrapassasse o número 1000 em cada uma das entradas. A primeira entrada recebia o ano de publicação do artigo, a segunda, as referências cujos códigos numéricos estivessem entre 1 e 1000, a terceira, as referências cujos códigos estivessem entre 1001 e 2000 e, assim por diante, até que a oitava entrada recebesse as referências cujos códigos estivessem entre 6001 e 7000. O programa direcionava a referência para a entrada correspondente, com o código numérico reduzido a um valor entre 1 e 1000.

Os exemplos a seguir ilustram este direcionamento. A referência cujo código numérico era 2003 na tabela de referências era direcionada à entrada 4 com o expoente 2, ou seja, referências entre 2001 e 3000 eram direcionadas à entrada 4 e o expoente 2 era calculado subtraindo-se uma unidade do número 3. A referência de código 5044, era direcionada à entrada 7, com o valor do expoente “n-1” igual a 43. O Quadro 7 sintetiza as informações das entradas da RNA nesta fase de experimentos.

Quadro 7 - Informações relativas às entradas da RNA

Entradas da RNA	Dado
1	Ano de publicação
2	Referências cujos códigos numéricos estejam entre 1 e 1000
3	Referências cujos códigos numéricos estejam entre 1001 e 2000
4	Referências cujos códigos numéricos estejam entre 2001 e 3000
5	Referências cujos códigos numéricos estejam entre 3001 e 4000
6	Referências cujos códigos numéricos estejam entre 4001 e 5000
7	Referências cujos códigos numéricos estejam entre 5001 e 6000
8	Referências cujos códigos numéricos estejam entre 6001 e 6015

Ao treinar a RNA, utilizando-se os dados de entrada distribuídos em oito entradas, como descrito anteriormente, observou-se que os resultados obtidos não eram satisfatórios. Optou-se, então, pela utilização de 6016 entradas, que recebiam o ano de publicação do artigo, quando o ano fosse um atributo utilizado pelo teste, e os valores 0 ou 1, representando a ausência ou a presença daquela referência no artigo. A representação do artigo, com a informação da presença de suas referências utilizando a base 2 foi descartada neste instante. Cada artigo foi, então, representado por um código de 6016 posições. A Figura 23 apresenta parte do arquivo que a RNA utilizou em suas 6016 entradas. Nesta figura, podem ser identificadas as primeiras 70 entradas da RNA para os 29 primeiros artigos.

Figura 23 - Parte do arquivo utilizado pela RNA em suas entradas

The image shows a portion of a binary matrix with 29 rows and 6016 columns. The rows are indexed from 1 to 29. The first column contains the year of publication (2009 or 2010). The subsequent columns contain binary values (0 or 1) representing the presence of references. For example, row 1 (article A1) has a '1' in the first column and '1's in columns 1 through 43, with all other columns being '0's.

Na primeira linha do arquivo, podem ser identificadas as características do artigo A1. Avaliando-se esta linha, observa-se o ano de publicação do artigo, 2009, na primeira coluna, designada aqui, coluna 0, e o valor 1 presente nas colunas seguintes, colunas 1 a 43, representando a presença das referências cadastradas com códigos numéricos que variavam de 1 a 43.

Na linha 2, podem ser observadas as informações relativas ao artigo A2. Este artigo, publicado em 2009, possuía 28 referências cadastradas com códigos numéricos que variavam de 44 a 71. Nesta linha, é possível perceber que muitas das colunas entre 44 e 71 foram preenchidas com o valor zero. O programa, nesta fase de geração do arquivo de entrada da RNA, já havia identificado a repetição de referências cadastradas anteriormente e substituía os códigos pelos valores menores, justificando a presença de 0 entre as colunas 44 e 71 e de valores 1 em colunas anteriores à coluna 44. Observa-se que, entre as posições

relativas às referências R44 e R69, apresentadas na Figura 20, cinco referências foram substituídas por códigos numéricos menores.

A linha 3 apresenta o artigo A3, publicado em 2010, cujas 38 referências foram cadastradas com códigos numéricos que variavam de 72 a 109. Nesta linha, também é possível perceber que muitas das colunas anteriores à coluna 72 foram preenchidas com o valor 1, identificando a presença de referências repetidas. A Tabela 2 apresenta um resumo das informações discutidas nos últimos parágrafos.

Tabela 2 - Relação entre os artigos e os códigos numéricos de suas referências

Artigo	Número de Referências	Códigos Numéricos das Referências	Códigos Substituídos (Códigos Inseridos) na fase anterior do programa
A1	43	R1 a R43	
A2	28	R44 a R71	R54(R33), R56(R16), R57(R17), R68(R28), R69(R31), R70(R12)
A3	38	R72 a R109	R76(R36), R80(R26), R82(R3), R84(R41), R87(R5), R91(R30), R93(R19), R97(R40), R99(R38), R100(R4), R101(R37), R102(R7), R104(R55)

CAPÍTULO 5: ANÁLISE DAS CARACTERÍSTICAS COMUNS ÀS CATEGORIAS

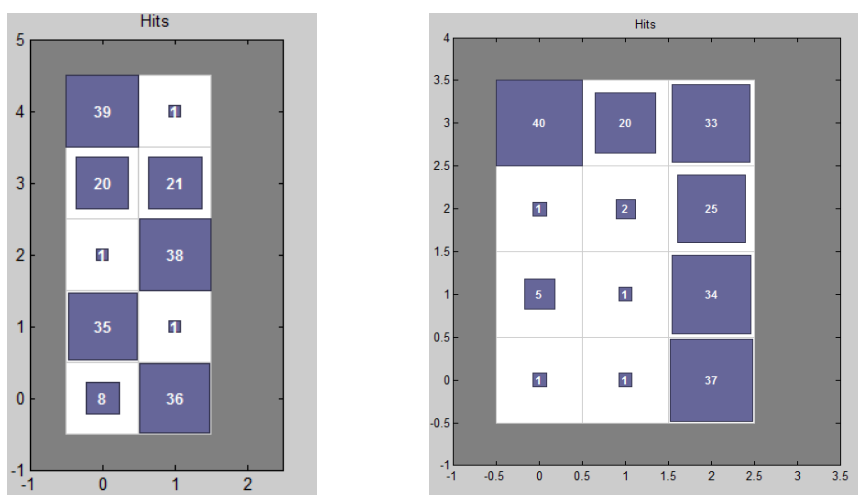
As próximas seções apresentaram os resultados dos quatro processos de categorização realizados e a análise das características comuns às categorias geradas. Os três primeiros experimentos foram realizados pela RNA. O primeiro experimento mantinha, na entrada da RNA, o ano de publicação como um dos atributos utilizado para a categorização dos artigos variando de 2001 a 2010. O segundo teste representava o ano com uma variação de 0,1 a 1,0 e o terceiro teste não utilizava o ano de publicação para a geração das categorias. O quarto teste utilizou uma ferramenta de categorização de artigos que empregava as palavras-chave dos artigos como atributo de categorização.

5.1. Apresentação e análise dos resultados do experimento 1

Em quatro das sete topologias da RNA utilizadas, uma significativa parte dos artigos foi agrupada pelo algoritmo SOM em sete categorias. Nas outras três topologias, os artigos foram agrupados em 3, 5 e 6 categorias. Optou-se por avaliar as topologias que concentravam os artigos no mesmo número de grupos para que os artigos pudessem ser identificados como representantes de um grupo que se repetia nas quatro topologias.

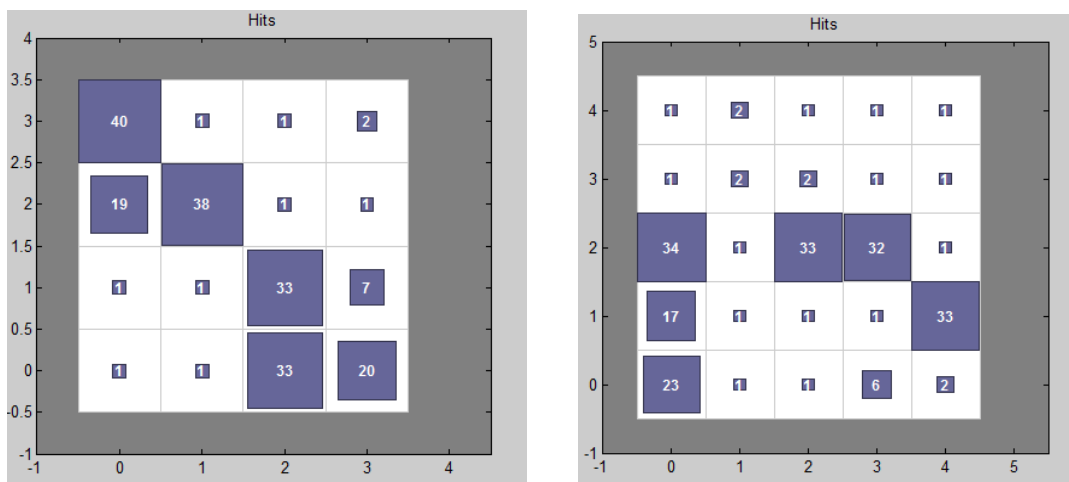
Os grupos gerados pelas topologias de 10 e 12 categorias podem ser observados na Figura 24. Dentro dos quadrados de cada topologia, que representam os grupos de artigos gerados, podem ser observados os números de artigos agrupados em cada categoria.

Figura 24 - Grupos de artigos gerados pelas topologias de 10 e 12 categorias



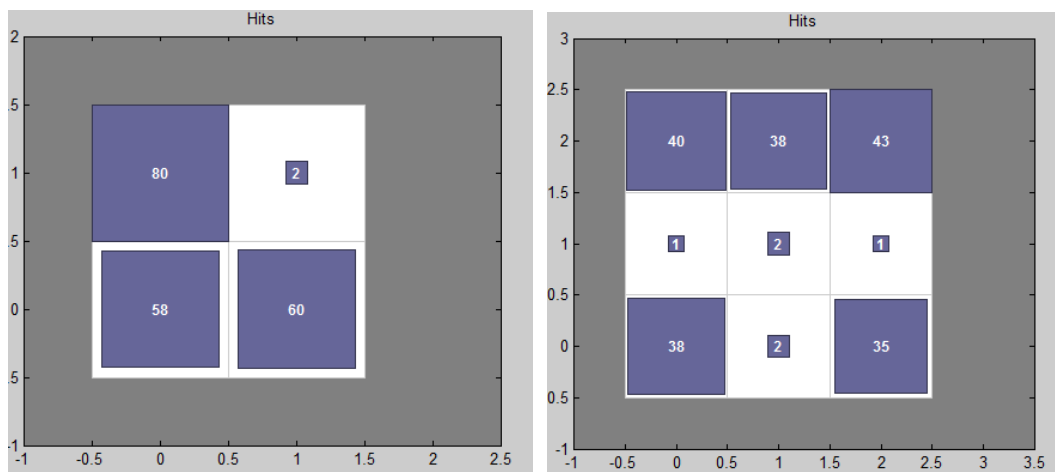
A Figura 25 apresenta os grupos gerados pelas topologias de 16 e 25 categorias.

Figura 25 - Grupos de artigos gerados pelas topologias de 16 e 25 categorias



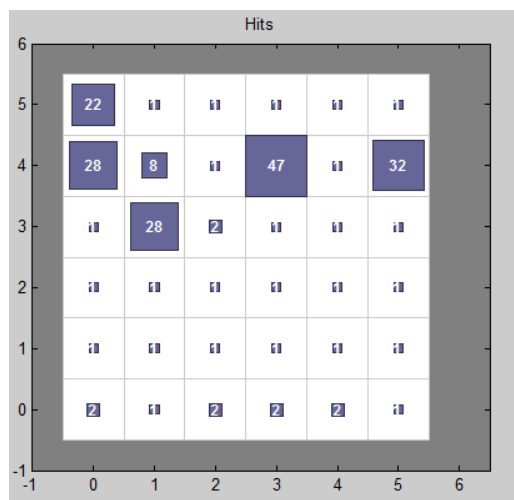
Diferentemente das outras três topologias, que podem ser observadas na Figura 26 e na Figura 27, estas quatro topologias apresentadas anteriormente tinham, predominantemente, seus artigos distribuídos em 7 grandes grupos.

Figura 26 - Grupos de artigos gerados pelas topologias de 4 e 9 categorias



Como pode ser observado na Figura 26, na topologia de 4 categorias, os artigos foram distribuídos em 3 grandes grupos e na topologia de 9 categorias, cinco grupos concentraram a maior parte dos artigos.

A Figura 27 apresenta a distribuição dos artigos em 36 categorias e mostra que os artigos se concentraram em seis categorias.

Figura 27 - Grupos de artigos gerados pela topologia de 36 categorias

Foram selecionadas, entre as sete topologias avaliadas, quatro topologias, que geravam 10, 12, 16 e 25 categorias. Estas topologias foram caracterizadas pela predominância de sete grandes grupos. O número de artigos agrupados em cada um dos sete grandes grupos, encontrado nas figuras apresentadas anteriormente, pode ser observado na Tabela 3.

Tabela 3 - Número de artigos agrupados nos sete grupos

Topologias	Número de artigos agrupados nos sete grandes grupos
10	39,20,21,38,35,8,36
12	40,20,33,25,5,34,37
16	40,19,38,33,7,33,20
25	34,33,32,17,33,23,6

Neste instante, mesmo conhecendo-se o número de artigos pertencentes a cada grupo, os artigos que compunham os grupos em cada topologia não eram identificados. Os sete grandes grupos presentes nas quatro topologias foram nomeados para facilitar sua identificação. Além do número do grupo e do experimento, os grupos também foram associados à topologia à qual pertenciam. Assim, na topologia que gerou 16 categorias, os grupos foram chamados de GrupoUm_E1_16, GrupoDois_E1_16, GrupoTrês_E1_16, GrupoQuatro_E1_16, GrupoCinco_E1_16, GrupoSeis_E1_16 e GrupoSete_E1_16 em cada uma das quatro topologias. Cada topologia tinha, portanto, os seus sete grandes grupos próprios com número de artigos distintos. Era necessário, então, identificar os artigos pertencentes a estes grupos, utilizando-se os dados de saída da RNA. Foi construída, então,

uma tabela com 200 colunas e 4 linhas. Cada um dos artigos representava uma coluna e cada uma das quatro linhas caracterizava a distribuição dos artigos em uma das topologias selecionadas. Cada um dos grupos, em cada uma das linhas, foi nomeado por uma letra e diferenciado por uma cor, facilitando, assim, a identificação do grupo em cada uma das topologias. O objetivo principal foi encontrar os artigos que se repetiam nos sete grupos nas quatro topologias selecionadas e criar um grupo único de artigos que representaria o grupo nas quatro topologias. A Tabela 4 representa, para ilustrar o processo, os primeiros 20 artigos separados por cores.

Tabela 4 - Identificação dos grupos em cada topologia

Artigos \ Topologias	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
10	A	B	B	B	B	B	B	B	B	B	A	B	B	B	B	B	B	A	B	B
12	D	C	C	C	C	C	C	C	C	C	C	C	C	C	C	C	C	E	C	C
16	H	F	G	G	F	H	F	F	G	G	G	F	F	F	F	G	G	H	F	F
25	I	J	J	J	T	J	J	J	J	J	M	J	J	J	P	J	J	I	J	J

Pela observação da sequência de cores por coluna (vermelho, lilás, verde e cinza) ou da sequência de letras por coluna (B, C, G e J), foi possível identificar, entre os 20 primeiros artigos, aqueles que pertenciam a um mesmo grupo (A3, A4, A9, A10, A16, A17). Se estivessem sendo observados apenas estes 20 artigos, outro grupo (A2, A7, A8, A12, A13, A14, A19, A20), caracterizado por uma única sequência de cores (vermelho, lilás, laranja e cinza) ou uma única sequência de letras (B, C, F e J), também, poderia ser identificado. A decisão de se adotar um ou outro grupo foi tomada considerando-se o grupo que apresentava o maior número de artigos, entre os 200 artigos, com a mesma sequência de cores.

A Tabela 5 apresenta o número de artigos identificados como pertencente a cada um dos grupos nas quatro topologias avaliadas considerando a análise dos 200 artigos.

Tabela 5 - Número de artigos dos grupos em cada topologia

Topologias	GrupoUm_E1	GrupoDois_E1	GrupoTrês_E1	GrupoQuatro_E1	GrupoCinco_E1	GrupoSeis_E1	GrupoSete_E1
10	8	36	35	39	20	21	38
12	5	37	34	40	20	33	25
16	7	20	33	40	19	38	33
25	6	33	32	23	34	---	33

A Tabela 6 apresenta os artigos pertencentes ao GrupoUm_E1 em cada uma das topologias. O grupo GrupoUm_E1 recebeu uma denominação diferenciada em cada uma das topologias, caracterizado pelo número de categorias formadas. O grupo foi chamado GrupoUm_E1_10, na topologia que gerava 10 categorias, GrupoUm_E1_12, na topologia que gerava 12 categorias, GrupoUm_E1_16, na topologia que gerava 16 categorias e GrupoUm_E1_25 na topologia que gerava 25 categorias.

Tabela 6 - Categorização do GrupoUm_E1 nas 4 Topologias

GrupoUm_E1	Número de Artigos	Artigos								
GrupoUm_E1_10	8	A1		A11	A18	A35	A47	A48	A49	A50
GrupoUm_E1_12	5	A1					A47	A48	A49	A50
GrupoUm_E1_16	7	A1	A6		A18		A47	A48	A49	A50
GrupoUm_E1_25	6	A1			A18	A35	A47	A48	A49	A50

Os artigos A1, A47, A48, A49 e A50 estavam presentes nas quatro topologias selecionadas e o artigo A18 estava presente em três destas topologias. Estes artigos foram, portanto, selecionados para compor o GrupoUm_E1, representante único das quatro topologias selecionadas. Para avaliar as características dos artigos, as referências, o ano de publicação e as palavras-chave dos seis artigos foram apresentados na Tabela 7.

Tabela 7 - Características dos artigos presentes no GrupoUm_E1

Artigos	Referências	Ano/No. de referências	Palavras-chave
A1	R1,R2,R3,R4,R5,R6,R7,R8,R9, R10,R11,R12,R13,R14,R15, R16,R17,R18,R19,R20,R21, R22,R23,R24,R25,R26,R27, R28,R29,R30,R31,R32,R33, R34,R35,R36,R37,R38,R39, R40,R41,R42,R43	2009/43	Asymptotic stability, k-winners-take-all (WTA), linear programming, neural network, quadratic programming
A18	R1,R3,R4,R5,R6,R9,R10,R11, R12,R13,R15,R18,R19,R20, R22,R25,R26,R30,R32,R34, R41,R44,R55,R85,R283,R287, R289,R295,R297,R304,R307, R308,R432,R704,R762,R764,	2010/47	Convergence, linear and quadratic programming, neural network, stability


	R769,R772,R774,R775,R786, R795,R798,R800,R802,R805, R806		
A47	R1,R3,R4,R5,R9,R12,R13,R15, R16,R17,R19,R20,R24,R26, R30,R36,R40,R44,R50,R53, R92,R94,R134,R295,R802, R806,R1351,R1800,R1817, R1818,R1821,R1822,R1826, R1827,R1828,R1829	2008/36	Winners-take-all (k-WTA), Global asymptotic stability, optimization, quadratic programming (QP), recurrent neural network
A48	R1,R4,R5,R7,R9,R12,R18,R19, R24,R26,R55,R131,R134,R158, R160,R311,R439,R445,R802, R806,R1202,R1248,R1351, R1688,R1800,R1843,R1854, R1858,R1859,R1860,R1861, R1862,R1864,R1865,R1866, R1868,R1869,R1870,R1871	2008/39	Differential inclusion, Lyapunov stability, global convergence, hard-limiting activation function, nonlinear programming, quadratic programming, recurrent neural network
A49	R4,R6,R9,R13,R17,R18,R19, R24,R26,R33,R55,R120,R288, R292,R311,R426,R432,R434, R439,R445,R762,R806,R1204, R1348,R1351,R1354,R1688, R1689,R1712,R1843,R1858, R1873,R1874,R1875,R1877, R1883,R1885,R1886,R1890, R1907,R1908,R1909,R1911, R1912,R1914,R1915,R1916, R1917,R1919,R1920,R1922	2008/51	Constrained optimization, convergence, convex and nonconvex problems, recurrent neural networks
A50	R1,R3,R5,R9,R11,R12,R16, R17,R18,R19,R20,R21,R24, R26,R28,R33,R48,R49,R50, R52,R53,R55,R295,R1346, R1351,R1689,R1843,R1925, R1948	2007/29	Global convergence, linear programming, linear variational inequality (LVI), quadratic programming, recurrent neural network

A Tabela 8 apresenta as referências comuns a cada dois dos seis artigos que compõem o GrupoUm_E1.

Tabela 8 - Referências comuns a cada dois artigos do GrupoUm_E1

Artigos	Número de Referências Comuns (Referências)
A1 e A18	21(R1,R3,R4,R5,R6,R9,R10,R11,R12,R13,R15,R18,R19,R20,R22,R25,R26,R30,R32,R34,R41)
A1 e A47	17(R1,R3,R4,R5,R9,R12,R13,R15,R16,R17,R19,R20,R24,R26,R30,R36,R40)
A1 e A48	10(R1,R4,R5,R7,R9,R12,R18,R19,R24,R26)
A1 e A49	10(R4,R6,R9,R13,R17,R18,R19,R24,R26,R33)
A1 e A50	16 (R1,R3,R5,R9,R11,R12,R16,R17,R18,R19,R20,R21,R24,R26,R28,R33)
A18 e A47	14(R1,R3,R4,R5,R9,R12,R13,R15,R19,R20,R26,R30,R44,R295)
A18 e A48	8 R1,R4,R5,R9,R12,R18,R19,R26)
A18 e A49	9(R4,R6,R9,R13,R18,R19,R26,R432,R762)
A18 e A50	10(R1,R3,R5,R9,R11,R12,R18,R19,R20,R26)
A47 e A48	10(R1,R4,R5,R9,R12,R19,R24,R26,R134,R1800)
A47 e A49	7(R4,R9,R13,R17,R19,R24,R26)
A47 e A50	13(R1,R3,R5,R9,R12,R16,R17,R19,R20,R24,R26,R50,R53)
A48 e A49	11(R4,R5,R9,R18,R19,R24,R26,R311,R439,R1688,R1858)
A48 e A50	8(R1,R5,R9,R12,R18,R19,R24,R26)
A49 e A50	8(R9,R17,R18,R19,R24,R26,R33,R1689)

A relação de referências comuns a cada dois artigos do GrupoUm_E1, mostrada na Tabela 5, pode ser visualizada na Figura 28.

Figura 28 - Relação de referências comuns aos artigos do GrupoUm_E1

A Tabela 9 mostra as referências citadas por cada um dos artigos do GrupoUm_E1, que são comuns a, pelo menos, três artigos.

Tabela 9 - Referências repetidas no GrupoUm_E1

Número de vezes que as referências se repetem (Número de referências repetidas)	Referência (Artigos)
2(24)	R7(A1,A48),R10(A1,A18),R21(A1,A50),R22(A1,A18),R25(A1,A18), R28(A1,A50),R32(A1,A18),R34(A1,A18),R36(A1,A47),R40(A1,A47), R41(A1,A18),R44(A18,A47),R50(A47,A50),R53(A47,A50), R134(A47,A48),R295(A18,A47),R311(A48,A49),R432(A18,A49), R439(A48,A49),R762(A18,A49),R1688(A48,A49),R1689(A49,A50), R1800(A47,A48),R1858(A48,A49)
3(8)	R6(A1,A18,A49),R11(A1,A18,A50), R15(A1,A18,A47),R16(A1,A47,A50),R30(A1,A18,A47), R33(A1,A49,A50),R802(A18,A47,A48),R1843(A48,A49,A50)
4(7)	R3(A1,A18,A47,A50),R13(A1,A18,A47,A49),R17(A1,A47,A49,A50), R20(A1,A18,A47,A50),R55(A18,A48,A49,A50), R806(A18,A47,A48,A49),R1351(A47,A48,A49,A50)
5(6)	R1(A1,A18,A47,A48,A50),R4(A1,A18,A47,A48,A49), R5(A1,A18,A47,A48,A50),R12(A1,A18,A47,A48,A50), R18(A1,A18,A48,A49,A50),R24(A1,A47,A48,A49,A50)
6 (3)	R9(A1,A18,A47,A48,A49,A50),R19(A1,A18,A47,A48,A49,A50), R26(A1,A18,A47,A48,A49,A50)

Oito destas citações (R6, R11, R15, R16, R30, R33, R802, R1843) foram referenciadas em três artigos, não necessariamente nos mesmos três artigos. Sete destas citações (R3, R13, R17, R20, R55, R806, R1351) foram referenciadas por quatro artigos. Seis citações (R1, R4, R5, R12, R18, R24) foram referenciadas em cinco artigos e três destas referências (R9, R19, R26) foram referenciadas em seis artigos. Cada dois dos artigos que compõem o GrupoUm_E1 têm, pelo menos, 7 referências em comum, como se pode constatar na Tabela 8, podendo chegar a 21 referências em comum, como é o caso dos artigos A1 e A18.

Estes artigos agrupados em uma mesma categoria foram publicados em quatro diferentes anos (2007, 2008, 2009 e 2010), enquanto os artigos da base de dados têm 10 diferentes anos de publicação, de 2001 a 2010. Percebe-se, assim, que o ano de publicação do

artigo não é um atributo predominante usado pela RNA no processo de criação desta categoria.

O segundo grupo avaliado neste experimento, observado nas quatro topologias selecionadas, apresentou uma média de 32 artigos. A Tabela 10 foi dividida em três tabelas para apresentar os artigos pertencentes a este grupo em cada uma das topologias. O grupo recebeu uma denominação diferenciada em cada uma das topologias, caracterizado pelo número de categorias formadas. Para compor o grupo avaliado neste trabalho, denominado GrupoDois_E1, representante das quatro topologias, foram selecionados os artigos que pertenciam a todas as topologias apresentadas. O grupo foi chamado GrupoDois_E1_10, na topologia que gerava 10 categorias, GrupoDois_E1_12, na topologia que gerava 12 categorias, GrupoDois_E1_16, na topologia que gerava 16 categorias e, finalmente, GrupoDois_E1_25 na topologia que gerava 25 categorias.

Tabela 10 - Categorização do GrupoDois_E1 nas 4 topologias

GrupoDois_E1	Número de Artigos	Artigos													
GrupoDois_E1_10	36	A2	A3	A4	A5	A6	A7	A8	A9	A10		A12	A13	A14	
GrupoDois_E1_12	37	A2	A3	A4	A5	A6	A7	A8	A9	A10	A11	A12	A13	A14	
GrupoDois_E1_16	20		A3	A4					A9	A10	A11				
GrupoDois_E1_25	33	A2	A3	A4		A6	A7	A8	A9	A10		A12	A13	A14	

GrupoDois_E1	Número de Artigos	Artigos													
GrupoDois_E1_10	36	A15	A16	A17	A19	A20	A21	A22	A23	A24	A25	A26	A27	A28	
GrupoDois_E1_12	37	A15	A16	A17	A19	A20	A21	A22	A23	A24	A25	A26	A27		
GrupoDois_E1_16	20		A16	A17								A26	A27		
GrupoDois_E1_25	33		A16	A17	A19	A20	A21	A22		A24	A25	A26	A27	A28	

GrupoDois	Número de Artigos	Artigos													
GrupoDois_E1_10	36	A29	A30	A31	A32	A33	A34		A36	A37	A38	A39	A40		
GrupoDois_E1_12	37	A29	A30	A31	A32	A33	A34	A35	A36	A37	A38	A39	A40		
GrupoDois_E1_16	20		A30	A31	A32	A33	A34	A35	A36	A37	A38	A39	A40		
GrupoDois_E1_25	33	A29	A30	A31	A32	A33	A34		A36	A37	A38	A39	A40		

Para compor o GrupoDois_E1, 18 artigos presentes em todas as quatro topologias foram selecionados. Foram agrupados os artigos A3, A4, A9, A10, A16, A17, A26, A27, A30 a A34 e A36 a A40. A Tabela 11 apresenta as características destes artigos.

Tabela 11 - Características dos artigos presentes no GrupoDois_E1

Artigo	Referências	Ano/No. de referências	Palavras-chave
A3	R3,R4,R5,R7,R19,R26,R30,R36, R37,R38,R40,R41,R55,R72,R73, R74,R75,R77,R78,R79,R81,R83, R85,R86,R88,R89,R90,R92,R94, R95,R96,R98,R103,R105,R106, R107,R108,R109	2010 /38	Global convergence in finite time, k-winners-take-all operation, Lyapunov function, recurrent neural network
A4	R26,R58,R79,R83,R109,R110,R111, R112,R113,R114,R115,R116,R117, R118,R119,R120,R121,R122,R123, R124,R125,R126,R127,R129,R130, R131,R132,R134,R135,R136,R137, R138,R140,R141,R142,R144,R145, R146,R147,R148,R149,R150,R151, R152,R153,R154,R155,R156,R157, R158,R159,R160,R161,R162,R163, R164,R165,R166,R167,R168,R169, R170,R171,R172,R173,R174,R175, R176,R177,R178,R179,R180,R181, R182,R183,R184,R186	2010/77	Almost periodic functions, common asymptotic behavior, delays, discontinuous neural networks, global exponential stability, impulses
A9	R247,R250,R401,R402,R403,R404, R405,R406,R407,R408,R410,R411, R412,R413,R414,R415,R416,R417, R418,R419,R420,R422,R423,R424, R425,R426,R427	2010/27	Forward-only computation, Levenberg–Marquardt algorithm, neural network training
A10	R4,R5,R6,R26,R35,R73,R77,R79, R120,R134,R158,R160,R167,R292, R428,R432,R434,R437,R439,R443, R444,R445,R449,R450,R451,R452, R454,R455,R456	2009/29	Convergence in finite time, differential inclusion, neural network, nonsmooth nonconvex optimization, slowsolution
A16	R714,R715,R716,R717,R718,R719, R720,R721,R722,R723,R724,R725, R726,R727,R728,R729	2010/16	Complex-valued neural networks, minimality, reducibility, rotation-equivalence
A17	R36,R142,R202,R562,R563,R730, R732,R733,R734,R736,R737,R738, R739,R740,R741,R742,R743,R744, R746,R747,R749,R750,R751,R752,	2010/30	Competition, convergence analysis, lateral inhibition, neural networks, neurodynamics, shunting and additive, very large scale integration (VLSI)

	R753,R754,R755,R756,R757,R758		neural networks, winner-take-all(WTA)
A26	R332,R343,R351,R1047,R1048, R1049,R1050,R1051,R1052,R1054, R1056,R1057,R1058,R1059,R1060, R1061,R1062,R1063,R1064,R1065, R1066,R1067,R1068,R1069,R1070, R1071,R1073,R1074,R1075,R1076, R1077,R1078,R1079,R1080,R1081, R1082,R1083	2010/37	Associative memory, Brain-State-in-a-Box (BSB), image storage and retrieval, neural networks, pattern decomposition, pattern sequence storage and retrieval
A27	R369,R371,R373,R428,R1084, R1085,R1086,R1087,R1088,R1089, R1090,R1091,R1092,R1094,R1096, R1097,R1098,R1099,R1100,R1101, R1102,R1103,R1104,R1105,R1106, R1107,R1108,R1109,R1110,R1111, R1112,R1113,R1115,R1116,R1117, R1119,R1120,R1121,R1122,R1123, R1124,R1125	2010/42	Broadcast scheduling problems, hysteretic, noisy chaotic neural network, packet radio network
A30	R714,R715,R716,R717,R718,R719, R720,R721,R722,R723,R724,R725, R726,R727,R728,R729	2010/16	Complex-valued neural networks, minimality, reducibility, rotation-equivalence
A31	R404,R413,R943,R1228,R1229, R1230,R1232,R1234,R1235,R1236, R1237,R1238,R1239,R1240,R1241, R1242,R1243,R1244,R1245,R1246, R1247,R1248,R1249,R1250,R1251, R1252,R1253	2010/27	Information theory, maximal-margin (MM) principle, multilayer perceptron (MLP), pattern recognition, supervised learning
A32	R179,R1254,R1255,R1256,R1257, R1258,R1259,R1260,R1261,R1262, R1263,R1264,R1265,R1266,R1267, R1268,R1269,R1270,R1271,R1272, R1273,R1274,R1275,R1276,R1278, R1279,R1280,R1281,R1282,R1283, R1284,R1285,R1286,R1287,R1288, R1289,R1290,R1291,R1292,R1293, R1294,R1295	2010/42	Differential inequality, discrete time-varying delays, distributed time-varying delays, impulsive delay, impulsive perturbations interval neural networks, linear matrix inequality, stationary oscillation
A33	R202,R697,R1296,R1297,R1298, R1299,R1300,R1301,R1302,R1303, R1304,R1305,R1306,R1308,R1310, R1311,R1312,R1313,R1314,R1315,	2010/36	Competitive predictor, file prediction, Levenberg–Marquardt (LM) backpropagation, multilayer perceptron (MLP), probabilistic predictor, radial

	R1316,R1317,R1318,R1319,R1320, R1321,R1322,R1323,R1324,R1325, R1326,R1327,R1328,R1329,R1330, R1331		basis function (RBF) network, success rate
A34	R1,R5,R15,R16,R33,R49,R55,R134, R295,R335,R428,R434,R762,R1334, R1344,R1345,R1346,R1348,R1349, R1350,R1351,R1353,R1354	2010/23	Discrete-time neural networks, global exponential stability, hybrid constraints, linear variational inequality, quadratic optimization
A36	R202,R323,R622,R892,R989,R1394, R1395,R1396,R1397,R1398,R1399, R1400,R1401,R1402,R1403,R1404, R1405,R1406,R1408,R1410,R1411, R1412,R1413,R1414,R1415,R1416, R1417,R1418,R1419,R1420,R1421, R1423,R1424,R1426,R1427,R1428, R1429,R1430,R1432	2010/39	Cost function, finite state automaton (FSA), hybrid greedy simulated annealing (HGSA), recurrent neural network (RNN), system identification
A37	R502,R698,R1433,R1434,R1435, R1436,R1437,R1439,R1440,R1441, R1442,R1443,R1444,R1445,R1446, R1447,R1448,R1449,R1450,R1451	2010/20	Backstepping, dynamic surface control (DSC), Fourier series expansion (FSE), integral-type Lyapunov function (ILF), multilayer neural network (MNN), nonlinearly parameterized systems, periodically time-varying disturbances
A38	R248,R1254,R1401,R1418,R1421, R1426,R1430,R1454,R1455,R1456, R1457,R1458,R1459,R1461,R1462, R1463,R1464,R1465,R1467,R1468, R1469,R1470,R1471,R1472,R1473, R1474,R1475,R1477,R1478,R1479, R1480,R1481,R1483,R1484,R1485, R1487,R1488,R1489,R1490,R1491, R1492,R1493,R1494,R1495,R1496, R1497,R1499	2010/47	Bayesian regularization, recurrent neural network (RNN), sequential Levenberg–Marquardt
A39	R59,R183,R1143,R1159,R1500, R1501,R1503,R1505,R1506,R1507, R1508,R1509,R1510,R1511,R1512, R1513,R1515,R1517,R1518,R1519, R1520,R1521,R1522,R1523,R1524, R1525,R1526,R1527,R1528,R1529	2010/30	Delays, exponential stability, impulsive control, impulsive synchronization, neural network, reaction–diffusion
A40	R1159,R1530,R1532,R1533,R1534, R1535,R1536,R1537,R1538,R1539,	2010/21	Delay dependent, exponential stability, linear matrix inequality (LMI), neural

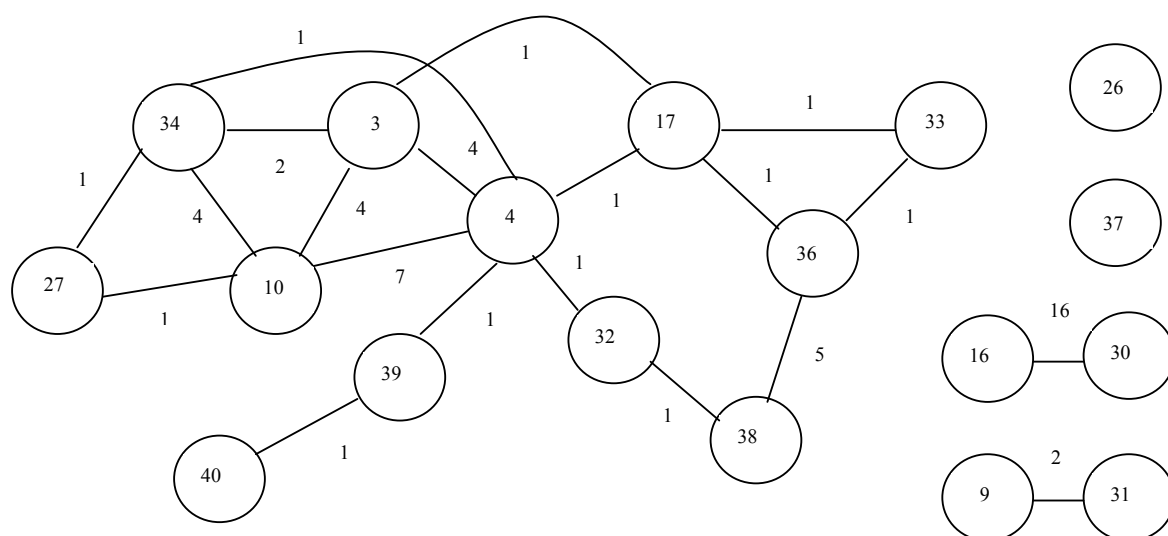
R1540,R1541,R1542,R1543,R1544, R1545,R1546,R1547,R1548,R1549, R1550	networks, time-varying delays
---	-------------------------------

A Tabela 12 apresenta as referências comuns a cada dois artigos do **GrupoDois_E1**.

Tabela 12 - Referências comuns a cada dois artigos do GrupoDois_E1

Artigos	Número de Referências Comuns (Referências)
A3 e A4	4(R26,R83,R79,R109)
A3 e A10	4(R4,R5,R26,R79)
A3 e A17	1(R36)
A3 e A34	2(R5,R55)
A4 e A10	7(R26,R79,R134,R120,R158,R160,R167)
A4 e A17	1(R142)
A4 e A32	1(R179)
A4 e A34	1(R134)
A4 e A39	1(R183)
A9 e A31	2(R404,R413)
A10 e A27	1(R428)
A10 e A34	4(R5,R134,R428,R434)
A16 e A30	16(R714 a R729)
A17 e A33	1(R202)
A17 e A36	1(R202)
A27 e A34	1(R428)
A32 e A38	1(R1254)
A33 e A36	1(R202)
A36 e A38	5(R1401,R1418,R1421,R1426,R1430)
A39 e A40	1(R1159)

A relação de referências comuns a cada dois artigos do GrupoDois_E1, mostrada na Tabela 11, pode ser visualizada na Figura 29.

Figura 29 - Relação de referências comuns aos artigos do GrupoDois_E1

Na Tabela 13 podem ser identificadas as referências que se repetem e os artigos que as citam no grupo.

Tabela 13 - Referências repetidas no GrupoDois_E1

Número de vezes que as referências se repetem (Número de referências repetidas)	Referências (Artigos)
2 (38)	R4(A3,A10),R36(A3,A17),R55(A3,A4),R83(A3,A34),R109(A3,A4), R120(A4,A10),R142(A4,A17),R158(A4,A10),R160(A4,A10), R167(A4,A10),R179(A4,A32),R183(A4,A39),R404(A9,A31), R413(A9,A31),R434(A10,A34),R714 a R729 (A16,A30), R1159(A39,A40),R1254(A32,A38),R1401(A36,A38),R1418(A36,A38), R1421(A36,A38),R1426(A36,A38),R1430(A36,A38)
3 (6)	R5(A3,A10,A34),R26(A3,A4,A10),R79(A3,A4,A10),R134(A4,A10,A34), R202(A17,A33,A36), R428(A10,A27,A34)

Este grupo se caracterizou por ter um grande número de referências comuns a apenas dois artigos. Entre dois artigos, foram encontradas 1, 2, 4, 5 ou 7 referências comuns. Os artigos A16 e A30 eram iguais. O banco de dados foi criado com esta repetição para que fosse possível verificar se dois artigos com as mesmas referências seriam agrupados na mesma categoria. Neste caso, as 16 referências citadas pelos artigos A16 e A30 foram identificadas como repetidas. Os artigos A26 e A37 não tinham referências comuns com os artigos do grupo. Mas, foram ambos publicados em 2010. Neste grupo, 17 dos 18 artigos

foram publicados em 2010. Apenas o artigo A10 foi publicado em 2009. Este artigo tinha referências comuns com 4 artigos do grupo.

O terceiro grupo foi denominado GrupoTrês_E1 e foi apresentado na Tabela 14, onde podem ser observadas as características do grupo nas quatro topologias avaliadas. Em cada topologia, este grupo foi chamado de GrupoTrês_E1_10, GrupoTrês_E1_12, GrupoTrês_E1_16 e GrupoTrês_E1_25, respectivamente.

Tabela 14 - Categorização do GrupoTrês_E1

GrupoTrês_E1	Número de Artigos	Artigos													
GrupoTrês_E1_10	35														
GrupoTrês_E1_12	34														
GrupoTrês_E1_16	33	A2	A5	A7	A8	A12	A13	A14	A15	A19	A20	A21	A22	A23	A24
GrupoTrês_E1_25	32														

GrupoTrês_E1	Número de Artigos	Artigos													
GrupoTrês_E1_10	35					A42	A43	A44	A45	A46	A51	A52	A53	A54	
GrupoTrês_E1_12	34				A41	A42	A43	A44	A45	A46	A51	A52	A53	A54	
GrupoTrês_E1_16	33	A25	A28	A29	A41	A42	A43	A44		A46				A54	
GrupoTrês_E1_25	32				A41	A42		A44	A45	A46	A51	A52	A53	A54	

GrupoTrês_E1	Número de Artigos	Artigos													
GrupoTrês_E1_10	35	A55	A56	A57	A58	A59	A60	A61	A62	A63	A64	A65	A66	A67	
GrupoTrês_E1_12	34	A55	A56	A57	A58		A60	A61		A63	A64	A65	A66	A67	
GrupoTrês_E1_16	33			A57	A58					A63	A64		A66		
GrupoTrês_E1_25	32	A55	A56	A57	A58		A60	A61		A63	A64	A65	A66		

GrupoTrês_E1	Número de Artigos	Artigos													
GrupoTrês_E1_10	35	A68	A69	A70	A71	A72	A73	A74	A75	A76	A77	A78	A79	A80	
GrupoTrês_E1_12	34	A68	A69	A70	A71	A72	A73	A74	A75	A76	A77	A78	A79	A80	
GrupoTrês_E1_16	33		A69	A70	A71							A78		A80	
GrupoTrês_E1_25	32	A68	A69	A70	A71	A72	A73	A74	A75	A76	A77	A78	A79	A80	

Dentre os artigos apresentados, 14 artigos estavam presentes em todas as topologias selecionadas. Foram agrupados, para compor o GrupoTrês_E1, os artigos A42, A44, A46, A54, A57, A58, A63, A64, A66, A69, A70, A71, A78 e A80. A Tabela 15 apresenta as características destes artigos.

Tabela 15 - Características dos artigos presentes no GrupoTrês_E1

Artigo	Referências	Ano/No. de referências	Palavras-chave
A42	R1328,R1599,R1600,R1601,R1602, R1603,R1604,R1605,R1606,R1607, R1608,R1609,R1610,R1611,R1612, R1613, R1614,R1616,R1617,R1618, R1619	2008/21	Radial basis function neural network (RBFNN), sequential learning, wavelet basis function neural network (WBFNN)
A44	R1177,R1656,R1657,R1658,R1659, R1660,R1661,R1662,R1663,R1664, R1665,R1667,R1668,R1669,R1670, R1671, R1672,R1673,R1674,R1675	2008/20	Linearly coupled recurrently connected neural networks, global u-synchronization, moore-penrose inverse , unbounded time-varying delay
A46	R202,R1015,R1251,R1400,R1401, R1405,R1683,R1717,R1718,R1719, R1720,R1721,R1722,R1723,R1724, R1725,R1726,R1727,R1728,R1729, R1730, R1731,R1733,R1734,R1735, R1736,R1737,R1739,R1740,R1741, R1742,R1743,R1744,R1745,R1746, R1747,R1748,R1749,R1750,R1751, R1752, R1753,R1754,R1755,R1756, R1757,R1758,R1760,R1761,R1762, R1763,R1764,R1765,R1766,R1767, R1768,R1770,R1771,R1772,R1773, R1774, R1775,R1776,R1777,R1778, R1779,R1780,R1782,R1783,R1784, R1785,R1786,R1787,R1788,R1789, R1790,R1791,R1792,R1793,R1794, R1795,R1796	2008/82	Memetic algorithms , multiobjective, recurrent neural networks (RNNs), time series
A54	R65,R167,R184,R1142,R1158,R1162, R1202,R1265,R1537,R1542,R1584, R1649,R1656,R1674,R2004,R2049, R2051, R2052,R2053,R2054,R2055, R2056,R2057,R2058,R2059,R2061, R2062,R2063,R2064,R2065,R2067, R2068,R2069,R2071,R2072,R2073, R2074, R2075,R2079,R2083,R2084, R2089,R2090,R2091,R2093	2008/45	Coupled neural networks, Kronecker product, discrete time, matrix functional, robust synchronization, stochastic perturbation, time-varying delay
A57	R969,R970,R1402,R1405,R2017, R2018,R2040,R2163,R2165,R2166,	2008/66	Context-free grammar, formal languages, fuzzy all-permutations rule base (FARB),

	R2167,R2168,R2169,R2170,R2171, R2172,R2173,R2174,R2176,R2177, R2178, R2180,R2181,R2182,R2184, R2185,R2186,R2187,R2188,R2189, R2190,R2191,R2192,R2193,R2194, R2195,R2196,R2197,R2198,R2199, R2200, R2201,R2202,R2203,R2204, R2205,R2206,R2207,R2208,R2209, R2210,R2211,R2212,R2213,R2214, R2215,R2216,R2217,R2218,R2219, R2221, R2222,R2223,R2224,R2225, R2228		knowledge insertion, knowledge-based neurocomputing, neurofuzzy systems, recurrent neural networks (RNNs), regular grammar
A58	R892,R1015,R1032,R1720,R1741, R1742,R1749,R1757,R1788,R2023, R2025,R2230,R2231,R2232,R2233, R2234,R2235,R2236,R2237,R2238, R2239, R2241,R2242,R2243,R2244, R2247,R2248,R2249,R2250,R2251, R2253,R2254,R2255,R2256,R2257, R2258,R2259,R2260,R2261,R2262, R2263, R2264,R2265,R2266,R2268, R2269,R2270,R2273,R2274,R2276, R2277,R2278,R2279,R2280,R2281, R2282,R2283,R2284,R2285,R2286, R2287, R2288,R2290,R2291,R2292	2008/65	Artificial neural network (ANN), evolutionary algorithms, local search, multiobjective optimization, singular value decomposition (SVD)
A63	R202,R412,R503,R504,R861,R1599, R2346,R2432,R2433,R2434,R2435, R2436,R2437,R2438,R2439,R2440, R2441, R2442,R2443,R2444,R2445, R2446,R2447,R2448,R2449,R2450, R2451,R2452,R2456,R2457,R2458, R2459,R2460,R2461,R2462,R2463, R2464, R2466,R2467,R2471,R2472	2008/41	Dynamics, recurrent neural network (RNN), road vehicle, suspension testing, tire
A64	R60,R184,R755,R1135,R1142,R1151, R1156,R1161,R1162,R1276,R1292, R1575,R2416,R2425,R2478,R2480, R2481, R2482,R2483,R2484,R2485, R2486,R2489,R2492,R2493,R2494, R2496,R2497,R2498,R2499,R2500, R2501,R2502, R2503,R2506,R2507	2008/36	Delay-dependent criteria, global robust periodicity, recurrent neural networks (RNN), switched systems, time-varying delay

A66	R19,R249,R403,R412,R496,R556, R820,R892,R1418,R1421,R1437, R2274,R2523,R2555,R2557,R2558, R2562,R2563,R2564,R2565,R2566, R2568,R2569,R2570,R2571,R2572, R2574, R2575,R2578,R2579,R2581, R2583,R2584,R2585,R2586,R2589, R2590,R2591,R2592,R2593,R2594, R2595,R2596,R2597	2008/44	Approximation, Jacobian matrix, convergence, single-hidden layer feedforward neural network (SLFN), supervised learning, training accuracy
A69	R114,R134,R155,R184,R237,R744, R749,R1131,R1132,R1133,R1134, R1135,R1138,R1139,R1141,R1142, R1157,R1295,R2698,R2701	2008/20	Global exponential stability, M-matrix, recurrent neural networks, time-varying delays
A70	R237,R1139,R1153,R1158,R1160, R1161,R1532,R1537,R1542,R1543, R1544,R1574,R2004,R2049,R2064, R2067,R2144,R2421,R2703,R2704, R2705, R2706,R2709,R2710,R2711, R2712,R2713,R2716,R2721,R2724, R2729,R2730,R2733,R2734,R2735, R2736,R2738, R2739,R2740	2008/39	Delay distribution dependent, discrete- time recurrent neural networks (DRNNs), exponential stability, linear matrix inequality (LMI), stochastic delay
A71	R729,R825,R892,R1611,R2238, R2244,R2521,R2523,R2555,R2639, R2652,R2742,R2743,R2744,R2745, R2746,R2747,R2749,R2750,R2751, R2752, R2753,R2754,R2755,R2757, R2758,R2759,R2760,R2761,R2762, R2763,R2764,R2765,R2766,R2767, R2768,R2769,R2770,R2772,R2773, R2774, R2776,R2777,R2779,R2780, R2782,R2783,R2784,R2785,R2786, R2787,R2789,R2791,R2792,R2793, R2794,R2795,R2796,R2800,R2801, R2802, R2803,R2804,R2805,R2806, R2807,R2808,R2809,R2810,R2811	2008/70	Best approximation, Gaussian radial basis functions (RBFs), existence, functions band-limited in frequency, sampling theory, truncation, uniqueness
A78	R2563,R2934,R2935,R2936,R2937, R2938,R2939,R2940,R2941,R2942, R2943,R2944,R2945,R2946,R2947, R2949, R2950,R2951	2008/18	Canonical representation, function approximation, hinging hyperplanes, piecewise-linear approximation, piecewise-linear neural network
A80	R698,R988,R989,R1204,R1451,	2008/22	Adaptive control, asymptotic stability,

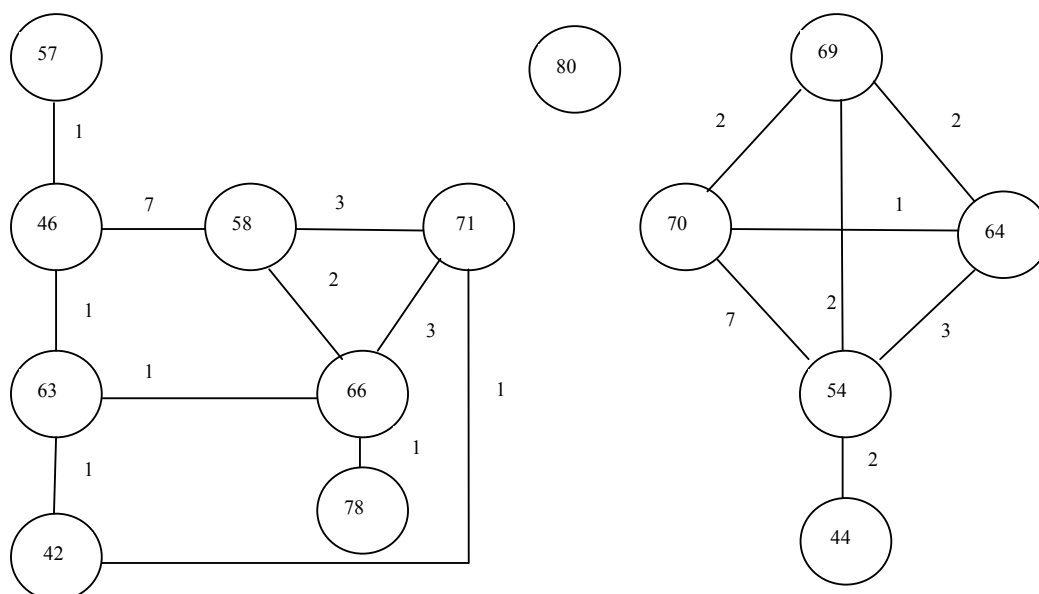
R1642,R2536,R2603,R2986,R2990, R2993,R2995,R2996,R2997,R2999, R3000,R3001,R3002,R3003,R3004, R3005,R3006	input-to-state stable internal dynamics, neural networks (NNs), partial stability, sector-bounded nonlinearities
---	--

A Tabela 16 apresenta as referências comuns a cada dois artigos do **GrupoTrês_E1**.

Tabela 16 - Referências comuns a cada dois artigos do GrupoTrês_E1

Artigos	Número de Referências Comuns (Referências)
A42 e A63	1(R1599)
A42 e A71	1(R1611)
A44 e A54	2(R1656,R1674)
A46 e A57	1(R1405)
A46 e A58	7(R1015,R1720,R1741,R1742,R1749,R1757,R1788)
A46 e A63	1(R202)
A54 e A64	3(R184,R1142,R1162)
A54 e A69	2(R184,R1142)
A54 e A70	7(R1158,R1537,R1542,R2004,R2049,R2064,R2067)
A58 e A66	2(R892,R2274)
A58 e A71	3(R892,R2238,R2244)
A63 e A66	1(R412)
A64 e A69	2(R184,R1142)
A64 e A70	1(R1161)
A66 e A71	3(R892,R2523,R2555)
A66 e A78	1(R2563)
A69 e A70	2(R237,R1139)

A relação de referências comuns a cada dois artigos do GrupoTrês_E1, mostrada na Tabela 15, pode ser visualizada na Figura 30.

Figura 30 - Relação de referências comuns aos artigos do GrupoTrês_E1

A Tabela 17 apresenta o número de vezes que cada um das referências é citada no grupo.

Tabela 17 - Referências repetidas no GrupoTrês_E1

Número de vezes que as referências se repetem (Número de referências repetidas)	Referência (Artigos)
2(31)	R202(A46,A63),R237(A69,A70),R412(A63,A66),R1015(A46,A58), R1162(A54,A64),R1139(A69,A70),R1158(A54,A70), R1161(A64,A70),R1405(A46,A57),R1599(A42,A63), R1537(A54,A70),R1542(A54,A70),R1611(A42,A71), R1656(A44,A54),R1674(A44,A54),R1720(A46,A58), R1741(A46,A58),R1742(A46,A58),R1749(A46,A58), R1757(A46,A58),R1788(A46,A58),R2004(A54,A70), R2049(A54,A70),R2064(A54,A70),R2067(A54,A70), R2274(A58,A66),R2238(A58,A71),R2244(A58,A71), R2563(A66,A78),R2555(A66,A71),R2523(A66,A71)
3 (3)	R184(A54,A64,A69),R892(A58,A66,A71),R1142(A54,A64,A69)

Todos os artigos do GrupoTrês_E1 foram publicados em 2008. Apenas o artigo A80 não tinha referências em comum com o grupo. Os artigos apresentaram uma, duas, três ou sete referências em comum. As referências foram citadas por dois ou por três artigos.

Destas, 31 referências eram comuns a dois artigos e 3 referências eram comuns a três artigos. Dentro do grupo, existiam dois subgrupos relacionados por suas referências.

O quarto grupo foi denominado GrupoQuatro_E1 e foi apresentado na Tabela 18, onde podem ser observadas as características do grupo nas quatro topologias avaliadas. Em cada topologia, este grupo foi chamado de GrupoQuatro_E1_10, GrupoQuatro_E1_12, GrupoQuatro_E1_16 GrupoQuatro_E1_25 respectivamente.

Tabela 18 - Categorização do GrupoQuatro_E1

GrupoQuatro_E1	Número de Artigos	Artigos													
GrupoQuatro_E1_10	39	A81	A82	A83	A84	A85	A86	A87	A88	A89	A90	A91	A92	A93	A94
GrupoQuatro_E1_12	40	A81	A82	A83	A84	A85	A86	A87	A88	A89	A90	A91	A92	A93	A94
GrupoQuatro_E1_16	40	A81	A82	A83	A84	A85	A86	A87	A88	A89	A90	A91	A92	A93	A94
GrupoQuatro_E1_25	23	A81	A82	A83	A84	A85	A86	A87	A88	A89	A90	A91	A92	A93	A94

GrupoQuatro_E1	Número de Artigos	Artigos													
GrupoQuatro_E1_10	39	A95	A96	A97	A98	A99	A100	A101	A102	A103	A104	A105	A106	A107	
GrupoQuatro_E1_12	40	A95	A96	A97	A98	A99	A100	A101	A102	A103	A104	A105	A106	A107	
GrupoQuatro_E1_16	40	A95	A96	A97	A98	A99	A100	A101	A102	A103	A104	A105	A106	A107	
GrupoQuatro_E1_25	23	A95	A96	A97	A98	A99	A100	A101							

GrupoQuatro_E1	Número de Artigos	Artigos													
GrupoQuatro_E1_10	39		A109	A110	A111	A112	A113	A114	A115	A116	A117	A118	A119	A120	
GrupoQuatro_E1_12	40	A108	A109	A110	A111	A112	A113	A114	A115	A116	A117	A118	A119	A120	
GrupoQuatro_E1_16	40	A108	A109	A110	A111	A112	A113	A114	A115	A116	A117	A118	A119	A120	
GrupoQuatro_E1_25	23							A114	A115						

Dentre os artigos apresentados, 23 artigos estavam presentes em todas as topologias selecionadas. Os artigos comuns, representantes do GrupoQuatro_E1, eram os artigos A81 a A101, A114 e A115. A Tabela 19 apresenta as características destes artigos.

Tabela 19 - Características dos artigos presentes no GrupoQuatro_E1

Artigo	Referências	Ano/No. de referências	Palavras-chave
A81	R5,R752,R762,R1348,R3008, R3010,R3012,R3013,R3015	2001/9	Global exponential stability, quadratic optimization with bound constraints, recurrent neural networks
A82	R202,R3016,R3017,R3018,R3019, R3020,R3021,R3022,R3023, R3024,R3025,R3026,R3027,R3029	2001/14	Cochlear implants, neural networks for cochlearimplants
A83	R257,R1611,R1618,R2639,R3033, R3035,R3036,R3037,R3038, R3039,R3040,R3041,R3042	2001/13	Multiwavelet, multiwavelet neural network, neural network, wavelet
A84	R348,R867,R3043,R3044,R3045, R3046,R3047,R3048,R3049, R3050,R3051,R3052,R3053, R3054,R3056,R3057,R3058, R3059, R3060,R3061,R3062, R3063	2001/22	Edge, image compression, neural network, unsupervised learning, vector quantization
A85	R4,R5,R6,R8,R9,R23,R283,R311, R432,R774,R1345,R1354,R1688, R1714,R1800,R1875,R3067, R3074,R3078,R3083,R3084, R3085,R3086,R3087,R3088	2001/25	Asymptotic stability, convergence, duality theory, linear programming, neural network, quadratic programming
A86	R5,R9,R22,R44,R237,R301,R334, R483,R749,R762,R1056,R1076, R1354,R2121,R3092,R3094, R3095,R3098,R3099,R3100, R3101,R3102,R3103,R3110, R3113	2001/25	Associative memory, basin of attraction, equilibrium points, neural networks, projection operator
A87	R202,R428,R969,R3115,R3116, R3117,R3118,R3119,R3120, R3121,R3122,R3123,R3124, R3125,R3126,R3127,R3128, R3129,R3130,R3131,R3132, R3133,R3135,R3136,R3137, R3138,R3139,R3140,R3142, R3143,R3144,R3146,R3147,R3148	2001/34	Fuzzy theory, image processing, image restoration, neural networks, regularization
A88	R3149,R3150,R3151,R3152, R3153,R3154,R3155	2001/7	Binary neural networks, Boolean function mapping, one-layer networks,

			two-layer networks
A89	R428,R2551,R3156,R3158,R3160, R3161,R 3162,R3163,R3164	2001/9	Neural networks, shortest path computation problem, two-layer Hopfield neural network
A90	R202,R892,R976,R989,R1430, R1461,R2517,R2535,R2753, R3166,R3167,R3169,R3170, R3172,R3173,R3174,R3176, R3178,R3179,R3180,R3181, R3184,R3185,R3186,R3187, R3188,R3189,R3190,R3191, R3192,R3194,R3195,R3196, R3197,R3198,R3199,R3200, R3201,R3202,R3203,R3204, R3205,R3206,R3207,R3208,R3210	2001/46	Adaptive state filtering, dynamic networks, extended Kalman filters (EKFs), nonlinear state filtering, recurrent networks
A91	R3211,R3212,R3213,R3214, R3215,R3216,R3217,R3218, R3219,R3220,R3221,R3222, R3223,R3224,R3225,R3226, R3227	2001/17	Incident detection, model adaptation, network pruning, probabilistic neural network
A92	R2040,R3228,R3229,R3230, R3231,R3232,R3233,R3235, R3236,R3237	2001/10	Fault diagnosis, fuzzy systems, neural networks, nonlinear systems
A93	R202,R1490,R3026,R3180,R3238, R3239,R3240,R3241,R3242, R3243,R3244,R3245,R3248, R3249,R3251,R3252,R3253, R3254,R3255,R3256,R3257	2001/21	Active control of sound and vibration, gradient computations, multilayer feedforward neural networks, nonlinear control, recursive-least-squares algorithms, steepest descent algorithms
A94	R892,R1611,R1613,R2758,R2759, R3033,R3263,R3264,R3267, R3268,R3269,R3270	2001/12	Error functions, neural network training, pattern recognition
A95	R2637,R3271,R3272,R3273, R3274,R3275,R 3276	2001/7	Backpropagation, multilevel threshold function, multiplevalued neural network
A96	R1,R4,R49,R134,R142,R162,R287, R295,R311,R749,R751,R757,R762, R1295,R1334,R1348,R1353, R1890,R1959,R3013,R3084, R3100,R3283,R3285,R3287, R3288,R3290,R3291,R3292,	2001/32	Global exponential stability, global Lipschitz continuous activations, linear variational inequality problems, recurrent neural networks extraction, feedforward neural networks

	R3295,R3297,R3298		
A97	R825,R892,R989,R1601,R1604, R1608,R1611,R2244,R2521, R2523,R2785,R2947,R3269, R3311,R3312,R3314,R3315, R3316,R3320,R3322,R3323, R3325,R3326,R3327,R3330, R3332,R3333,R3335,R3338, R3339,R3340	2001/31	Function approximation, neural network, nonlinear system, radial basis function
A98	R432,R3341,R3342,R3343,R3344, R3345,R3346,R3347,R3348, R3349,R3350,R3351,R3352, R3354,R3355,R3356,R3357, R3358, R3359,R3360,R3361, R3362	2001/22	Cross-associative neural network, global asymptotic stability, learning rate, signal processing, singular value decomposition
A99	R4,R5,R162,R295,R434,R704, R1344,R3012,R3084,R3369, R3373	2001/11	Closed convex subsets, convex minimization, global convergence, global existence of solutions, global exponential convergence, recurrent neural networks, uniform convexity
A100	R4,R5,R44,R162,R295,R434,R704, R1334,R1821,R3012,R3084	2001/11	Compact convex subset, convergence, convex minimization, nonlinear optimization, projection operator, recurrent neural networks
A101	R5,R35,R122,R142,R337,R744, R749,R2934,R2941,R3084,R3094, R3095,R3385,R3389,R3390, R3391,R3393,R3394,R3397, R3401,R3402,R3404,R3406, R3407,R3409	2002/25	Neural networks, piecewise-linear functions, stability
A114	R1,R4,R5,R44,R50,R295,R434, R704,R1334,R1344,R3084,R3369, R3646,R3648,R3650,R3652, R3653,R3656	2002/18	Convergence, equilibrium points, exponential convergence, limit cycles, monotone variational inequalities, nonsymmetric monotone variational inequalities, recurrent neural networks, solution trajectories, stability analysis, strictly monotone variational inequalities, uniformly monotone variational inequalities
A115	R202,R1979,R3348,R3362,R3658,	2002/20	Chaos, dynamical behavior, Hebbian

R3659,R3660,R3661,R3664, R3665,R3666,R3668,R3669, R3670,R3672,R3673,R3674, R3675,R3676,R3677	neural networks, stochastic approximation
---	--

A Tabela 20 apresenta as referências comuns a cada dois artigos do **GrupoQuatro_E1**.

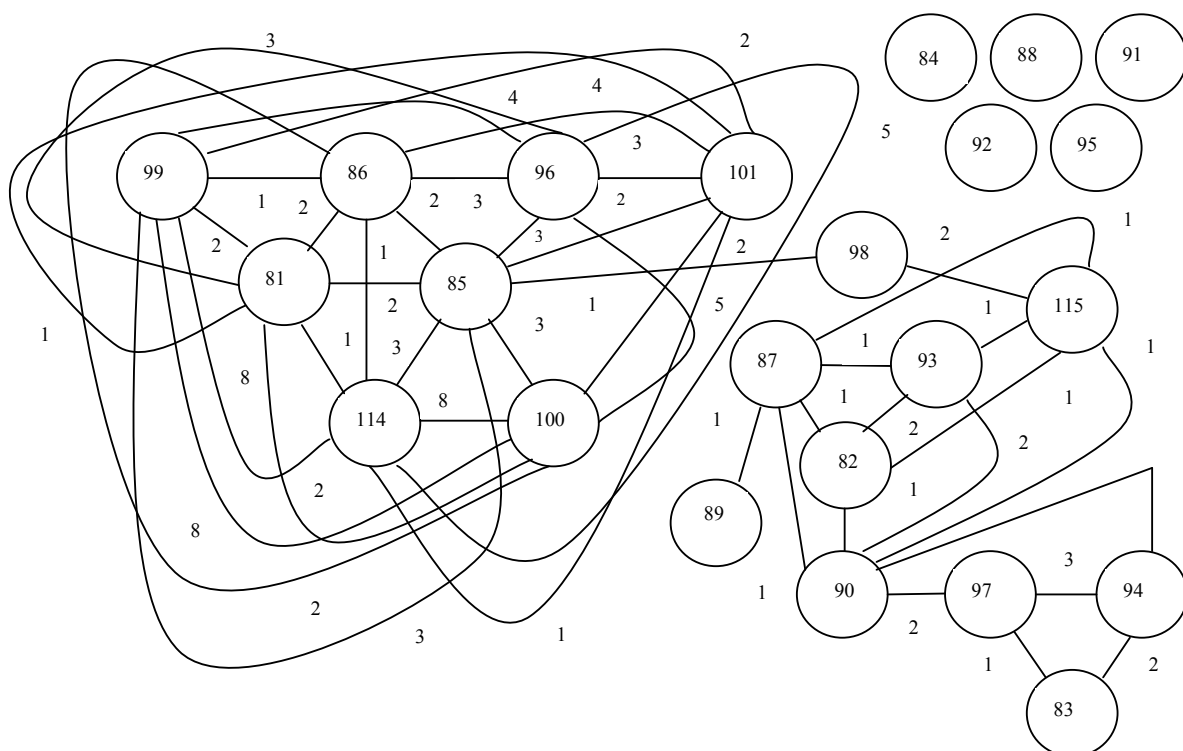
Tabela 20 - Referências comuns a cada dois artigos do GrupoQuatro_E1

Artigos	Número de Referências Comuns (Referências)
A81 e A85	1(R5)
A81 e A86	2(R5,R762)
A81 e A96	3(R762,R1348,R3013)
A81 e A99	2(R5,R3012)
A81 e A100	2(R5,R3012)
A81 e A101	1(R5)
A81 e A114	1(R5)
A82 e A87	1(R202)
A82 e A90	1(R202)
A82 e A93	2(R202,R3026)
A82 e A115	1(R202)
A83 e A94	2(R1611,R3033)
A83 e A97	1(R1611)
A85 e A86	2(R5,R9)
A85 e A96	3(R4,R311,R3084)
A85 e A98	1(R432)
A85 e A99	3(R4,R5,R3084)
A85 e A100	3(R4,R5,R3084)
A85 e A101	2(R5,R3084)
A85 e A114	3(R4,R5,R3084)
A86 e A96	3(R749,R762,R3100)
A86 e A99	1(R5)
A86 e A100	2(R5,R44)
A86 e A101	4(R5,R749,R3094,R3095)
A86 e A114	2(R5,R44)
A87 e A89	1(R428)
A87 e A90	1(R202)
A87 e A93	1(R202)
A87 e A115	1(R202)

A90 e A93	2(R202,R3180)
A90 e A94	1(R892)
A90 e A97	2(R892,R989)
A90 e A115	1(R202)
A93 e A115	1(R202)
A94 e A97	3(R892,R1611,R3269)
A96 e A99	4(R4,R162,R295,R3084)
A96 e A100	5(R4,R162,R295,R1334,R3084)
A96 e A101	3(R142,R749,R3084)
A96 e A114	5(R1,R4,R295,R1334,R3084)
A98 e A115	2(R3348,R3362)
A99 e A100	8(R4,R5,R162,R295,R434,R704,R3012,R3084)
A99 e A101	2(R5,R3084)
A99 e A114	8(R4,R5,R295,R434,R704,R1344,R3084,R3369)
A100 e A101	2(R5,R3084)
A100 e A114	8(R4,R5,R44,R295,R434,R704,R1334,R3084)
A101 e 114	1(R5)

A relação de referências comuns a cada dois artigos do GrupoQuatro_E1, mostrada na Tabela 20, pode ser visualizada na Figura 31.

Figura 31 - Relação de referências comuns aos artigos do GrupoQuatro_E1



A Tabela 21 apresenta o número de vezes que as referências são citadas pelos artigos do grupo.

Tabela 21 - Referências repetidas no GrupoQuatro_E1

Número de vezes que as referências se repetem (Número de referências repetidas)	Referência (Artigos)
2 (20)	R1(A96,A114),R9(A85,A86),R142(96,101),R311(A85,A96), R428(A87,A89),R432(A85,A98),R989(A90,A97),R1348(A81,A96), R1344(A99,A114),R3013(A81,A96),R3026(A82,A93),R3033(A83,A94), R3094(A86,A101),R3095(A86,A101),R3100(A86,A96),R3180(A90,A93), R3269(A94,A97),R3348(A98,A115),R3369(A99,A114),R3362(A98,A115)
3 (11)	R44(A86,A100,A114),R162(A96,A99,A100),R434(A99,A100,A114), R704(A99,A100,A114),R749(A86,A96,A101),R762(A81,A86,A96), R892(A90,A94,A97),R1334(A96,A100,A114),R1611(A83,A94,A97), R3012(A81,A99,A100),R3013(A81,A96)
4 (1)	R295(A96,A99,A100,A114)
5 (2)	R4(A85,A96,A99,A100,A114),R202(A82,A87,A90,A93,A115)
6 (1)	R3084(A85,A96,A99,A100,A101,A114)
7 (1)	R5(A81,A85,A86,A99,A100,A101,A114)

Dos vinte e três artigos do GrupoQuatro_E1, 20 foram publicados em 2001 e 3, em 2002. Cinco artigos (A84, A88, A91, A92 e A95) publicados em 2001 não tinham referências comuns com os artigos do grupo. Alguns artigos apresentaram de 1 a 4 referências em comum, chegando a 7 e 8 referências em comum. As referências foram citadas por 2 artigos, chegando a serem citadas por sete artigos. A grande maioria dos artigos tinha 2 ou 3 referências em comum.

O quinto grupo foi denominado GrupoCinco_E1 e é apresentado na Tabela 22, onde podem ser observadas as características do grupo nas quatro topologias avaliadas. Em cada topologia, este grupo foi chamado de GrupoCinco_E1_10, GrupoCinco_E1_12, GrupoCinco_E1_16 e GrupoCinco_E1_25 respectivamente.

Tabela 22 - Categorização do GrupoCinco_E1

GrupoCinco_E1	Número de Artigos	Artigos												
GrupoCinco_E1_10	20	A121	A122	A123	A124	A125	A126	A127	A128	A129	A130	A131	A132	A133
GrupoCinco_E1_12	20	A121	A122	A123	A124	A125	A126	A127	A128	A129	A130	A131	A132	A133
GrupoCinco_E1_16	19	A121	A122	A123	A124		A126	A127	A128	A129	A130	A131	A132	A133
GrupoCinco_E1_25	34	A121	A122			A125	A126	A127	A128	A129	A130	A131	A132	

GrupoCinco_E1	Número de Artigos	Artigos												
GrupoCinco_E1_10	20	A134	A135	A136	A137	A138	A139	A140						
GrupoCinco_E1_12	20	A134	A135	A136	A137	A138	A139	A140						
GrupoCinco_E1_16	19	A134	A135	A136	A137	A138	A139	A140						
GrupoCinco_E1_25	34	A134	A135	A136	A137	A138	A139	A140	A141	A143	A144	A145	A147	

GrupoCinco_E1	Número de Artigos													
GrupoCinco_E1_10	20													
GrupoCinco_E1_12	20													
GrupoCinco_E1_16	19													
GrupoCinco_E1_25	34	A148	A149	A150	A151	A152	A153	A154	A156	A157	A158	A159	A160	

Dentre os artigos apresentados, 16 artigos estavam presentes em todas as topologias selecionadas. Os artigos comuns às topologias eram os artigos A121, A122, A126, A127, A128, A129, A130, A131, A132, A134, A135, A136, A137, A138, A139 e A140. A Tabela 23 apresenta as características destes artigos.

Tabela 23 - Características dos artigos presentes no GrupoCinco_E1

Artigo	Referências	Ano/No. de referências	Palavras-chave
A121	R1,R22,R23,R71,R311,R432,R802, R1346,R1350,R1688,R3369,R3488, R3766,R3767,R3768,R3769,R3770, R3771,R3772,R3773,R3774,R3775, R3776, R3777,R3778,R3779,R3780, R3781,R3785,R3786,R3787,R3788, R3791,R3795,R3796,R3801,R3802, R3803,R3804	2003/39	Drift-free, dual neural network, joint limits, joint velocity limits, kinematically redundant manipulators
A122	R202,R1246,R1720,R2165,R2269, R2288,R3805,R3806,R3807,R3808, R3809,R3810,R3811,R3812,R3813, R3814,R3815,R3816,R3817,R3818,	2003/37	Genetic algorithm (GA), neural networks, parameter learning, structure learning

	R3819, R3820,R3821,R3824,R3825, R3826,R3828,R3829,R3830,R3831, R3832,R3833,R3835,R3836,R3837, R3838,R3839		
A126	R202,R249,R251,R1248,R1712, R3970,R3971,R3972,R3973,R3974, R3975,R3976,R3977,R3978,R3979, R3980,R3981,R3982,R3983,R3984, R3985, R3986,R3991,R3992,R3993, R3994,R3996,R3997,R3998,R3999, R4000,R4001,R4002,R4003	2003/34	Adaptive neural networks, MPEG-4, video object extraction
A127	R704,R1414,R2621,R3706,R3845, R3939,R3958,R4004,R4005,R4006, R4009,R4010,R4011,R4014,R4016, R4017,R4018,R4019,R4020,R4022, R4023,R4025	2003/22	Adaptive law, antilock braking system, recurrent neural network (RNN), sliding-mode control
A128	R697,R4026,R4027,R4028,R4029, R4030,R4031,R4032,R4033,R4035, R4036,R4037,R4038,R4039	2003/14	Analog very large-scale integration (VLSI), Euclidean distance circuit, hardware synapse, neural network
A129	R1010,R1011,R1012,R1013,R1017, R2017,R2018,R2023,R2637,R4041, R4044,R4045,R4046,R4047,R4048, R4049, R4052,R4054,R4055,R4056, R4057,R4058,R4060,R4061,R4063, R4064,R4065,R4066, R4067,R4068, R 4070,R4071	2003/32	Artificial neural networks, ensemble learning, machine learning, rule induction
A130	R202,R867,R3043,R3058,R3748, R4072,R4073,R4074,R4075,R4076, R4077,R4078,R4079,R4080,R4081, R4082,R4083,R4084,R4088,R4089, R4090, R4091,R4092,R4094,R4095, R4097,R4098,R4099,R4100	2003/29	Clustering, gravitation, k-means, neural networks, quantization
A131	R248,R250,R251,R861,R1481,R2557, R3201,R4048,R4101,R4102,R4103, R4104,R4106,R4110,R4111,R4112, R4113, R4114,R4116,R4117,R4120, R4121,R4122,R4123,R4124,R4125, R4127,R4128,R4129,R4130,R4131, R4132,R4133, R4134,R4135,R4136	2003/36	Growing and pruning procedures, ill-conditioning detection, input selection, least squares (LS) estimation, leave-one-out cross validation, linear Taylor expansion, model selection, neural networks, nonlinear regression, statistical hypothesis tests
A132	R202,R237,R428,R4137,R4138,	2003/20	Neural networks, optical diffraction,


	R4139,R4140,R4141,R4142,R4143, R4144,R4145,R4146,R4147,R4149, R4150,R4151, R4152,R4153,R4155		optimization methods, packet switching
A134	R36,R105,R749,R1829,R3095,R3588, R4175,R4177,R4180, R4181,R4182	2003/11	Continuous-time Hopfield network, K- winners-take-all, large gain behavior, processing time
A135	R4184,R4185,R4186,R4187,R4188, R4189,R4190,R4191,R4192,R4193, R4194,R4195,R4196,R4197,R4198, R4199	2003/16	Network processors, neural network, packet switched networks, random neural networks
A136	R2634,R4200,R4201,R4202,R4203, R4204,R4205,R4206,R4207,R4208, R4210,R4211,R4212	2003/13	Digital signal processor (DSP) implementation, hierarchical neural network classifier, modulation signal classification
A137	R737,R746,R1968,R1969,R2672, R3870,R4213,R4214,R4215,R4219, R4223	2003/11	Flow invariance, global exponential stability, multi timescale neural network
A138	R2886,R4224,R4225,R4227,R4228, R4229,R4230,R4231,R4232,R4233, R4234,R4235,R4236,R4237,R4238, R4239,R4240,R4241,R4242,R4243, R4244	2003/21	Application specific integrated circuit (ASIC), cellular neural networks, image processing, nonlinear filtering
A139	R593,R1975,R4245,R4246,R4248, R4249,R4250,R4251,R4252,R4253, R4254,R4255,R4257,R4258,R4259, R4260,R4261	2003/17	Field-programmable gate array (FPGA), learning ability, neural networks (NNs), pulse density, simultaneous perturbation
A140	R2853,R4262,R4263,R4264,R4265, R4266,R4267,R4268,R4269,R4271, R4272	2003/11	Associative memory, attractor neural network(ANN), connectivity, coupled systems, feedback, Hopfield model, Ising model, self-trapping

A Tabela 24 apresenta as referências comuns a cada dois artigos do **GrupoCinco_E1**.

Tabela 24 - Referências comuns a cada dois artigos do GrupoCinco_E1

Artigos	Número de Referências Comuns (Referências)
A122 e A126	1(R202)
A122 e A130	1(R202)
A122 e A132	1(R202)
A126 e A130	1(R202)
A126 e A131	1(R251)
A126 e A132	1(R202)
A129 e A131	1(R4048)
A130 e A132	1(R202)

A relação de referências comuns a cada dois artigos do GrupoCinco_E1, mostrada na Tabela 24, pode ser visualizada na Figura 32.

Figura 32 - Relação de referências comuns aos artigos do GrupoCinco_E1

A Tabela 25 apresenta o número de vezes que cada um das referências foi citada no grupo.

Tabela 25 - Referências repetidas no GrupoCinco_E1

Número de vezes que as referências se repetem (Número de referências repetidas)	Referência (Artigos)
2(2)	R251(A126,A131),R4048(A129,A131)
4(1)	R202(A122,A126,A130,A132)

Dos 16 artigos do GrupoCinco_E1, apenas seis artigos apresentaram referências em comum (A122, A126, A129, A130, A131 e A132). Duas referências se repetiram em dois

grupos de artigos e uma referência é comum a quatro artigos. Todos os artigos foram publicados em 2003, o que demonstrou a forte influência do ano de publicação como atributo de categorização deste grupo.

O sexto grupo foi denominado GrupoSeis_E1 e é apresentado na Tabela 26, onde podem ser observadas as características do grupo em três topologias avaliadas. O grupo, caracterizado pelos artigos encontrados nas outras três topologias, não foi encontrado na topologia que gerava 25 categorias. Em cada topologia, este grupo foi chamado de GrupoSeis_E1_10, GrupoSeis_E1_12 e GrupoSeis_E1_16 respectivamente.

Tabela 26 - Categorização do GrupoSeis_E1

GrupoSeis_E1	Número de Artigos	Artigos													
GrupoSeis_E1_10	21	A141	A142	A143	A144	A145	A146	A147	A148	A149	A150	A151	A152	A153	A154
GrupoSeis_E1_12	33		A142	A143	A144	A145	A146	A147	A148	A149	A150	A151	A152	A153	A154
GrupoSeis_E1_16	38	A141	A142	A143	A144	A145	A146	A147	A148	A149	A150	A151	A152	A153	A154

GrupoSeis_E1	Número de Artigos	Artigos													
GrupoSeis_E1_10	21	A155	A156	A157	A158	A159	A160								
GrupoSeis_E1_12	33		A156	A157	A158	A159	A160	A161		A169	A170		A173	A175	
GrupoSeis_E1_16	38	A155	A156	A157	A158	A159	A160	A161	A163	A169	A170	A172	A173	A175	

GrupoSeis_E1	Número de Artigos	Artigos													
GrupoSeis_E1_10	21					A184									
GrupoSeis_E1_12	33	A176		A178	A179		A185	A186	A187	A188	A189	A191	A192		
GrupoSeis_E1_16	38	A176	A177	A178	A179	A184		A186	A187	A188	A189	A191	A192		

Dentre os artigos apresentados, 18 artigos estavam presentes em todas as topologias selecionadas. Os artigos comuns às três topologias eram os artigos A142 a A154 e A156 a A160. A Tabela 27 apresenta as características destes artigos.

Tabela 27 - Características dos artigos presentes no GrupoSeis_E1

Artigo	Referências	Ano/No. de referências	Palavras-chave
A142	R1,R5,R6,R44,R52,R283,R287, R288,R295,R297,R306,R307,R311, R432,R704,R762,R764,R774,R775, R3088,R3648,R3801,R4316,R4325	2004/24	Convergence and stability, neural network, nonlinear convex programming
A143	R704,R1414,R2621,R3939,R3958, R4004,R4006,R4329,R4330, R4331,R4332,R4334,R4335, R4337,R4339,R4340,R4341, R4343,R4344,R4345,R4346, R4348,R4349,R4350,R 4352	2004/25	Recurrent fuzzy neural network (RFNN), supervisory
A144	R704,R892,R1451,R1611,R2238, R2555,R2794,R3033,R3236, R4357,R4358,R4359,R4360, R4361,R4362,R4363,R4364, R4365,R4366,R4367,R4371, R4372,R4376,R4377,R4378, R4379,R4380,R4381	2004/28	Bank-to-turn (BTT) missiles, Gaussian neural networks, H control theory, ridge functions
A145	R428,R749,R1116,R4382,R4383, R4384,R4385,R4386,R4387, R4388,R4391,R4393,R4394, R4395,R4396,R4397,R4398, R4399,R4400	2004/19	Bipartite subgraph problem, gradient ascent learning, Hopfield neural network, NP-complete problem, total coloring problem
A146	R2498,R2779,R2997,R4403, R4404,R4406,R4407,R4408, R4409,R4410,R4411,R4412, R4413	2004/13	Chaos generation, identification, recurrent neural networks, variable structure system
A147	R656,R704,R989,R1414,R3885, R4014,R4414,R4415,R4416, R4417,R4418,R4419,R4420, R4421,R4423,R4424,R4425, R4427,R4428,R4430,R4431, R4432,R4433,R4434,R4435, R4436,R4437,R4439,R4440, R4441,R4442,R4443	2004/32	Adaptive hybrid control, cerebellar-model-articulation-computer (CMAC), diagonal recurrent, linear piezoelectric ceramic motor (LPCM), LLCC resonant invert
A148	R205,R244,R250,R257,R2024, R2844,R3197,R4447,R4448,	2004/36	Delta rules, generalized recursive neuron, information entropy, multilayer perceptrons,

	R4449,R4450,R4452,R4453, R4454,R4455,R4456,R4458, R4459,R4460,R4461,R4462, R4463,R4464,R4466,R4467, R4468,R4469,R4470,R4472, R4473,R4475,R4476,R4478, R4479,R4480,R4481		structured patterns
A149	R989,R993,R1433,R2238,R2555, R2753,R2779,R3850,R3955, R4409,R4432,R4486,R4487, R4491,R4492,R4493,R4494, R4495,R4496,R4497,R4499, R4502,R4503,R4505,R4506, R4507,R4508,R4509,R4510, R4511,R4512,R4513,R4514, R4515,R4516,R4517,R4518, R4519	2004/38	Neural control, nonlinear systems, robust adaptive control, unmodeled dynamic
A150	R9,R34,R44,R52,R283,R287,R288, R302,R305,R311,R704,R762,R775, R1890,R2133,R3652,R3801, R4527,R4529	2004/19	Convergence and stability, minimax problem, neural network, saddle point
A151	R3533,R3543,R4539,R4540, R4541,R4542,R4543,R4544, R4545,R4547,R4548,R4549, R4550,R4551,R4552,R4553, R4554,R4556,R4557,R4558	2004/20	Accelerated convergence, approximation theory, direct-sequence code-division-multiple-access (DS-CDMA) systems, importance sampling (IS), minimum bit-error rate (BER), minimum probability of error, multilayer perceptron, neural networks (NNs), stochastic approximation, supervised learning algorithm
A152	R253,R2629,R3685,R4559,R4560, R4561,R4562,R4563,R4564, R4565,R4566,R4567,R4568, R4569,R4570,R4572,R4573, R4574,R4575,R4576,R4577, R4578,R4579,R4581,R4582, R4583,R4584,R4585,R4586, R4587,R4588,R4589,R4591,R4592	2004/34	Back-propagation (BP) algorithm, fuzzy BP algorithm, fuzzy conjugate gradient algorithm, regular fuzzy neural network, function
A153	R3043,R3053,R3748,R4075, R4091,R4593,R4594,R4595, R4596,R4597,R4598,R4599,	2004/24	Competitive learning, self-creating neural network, vector quantization

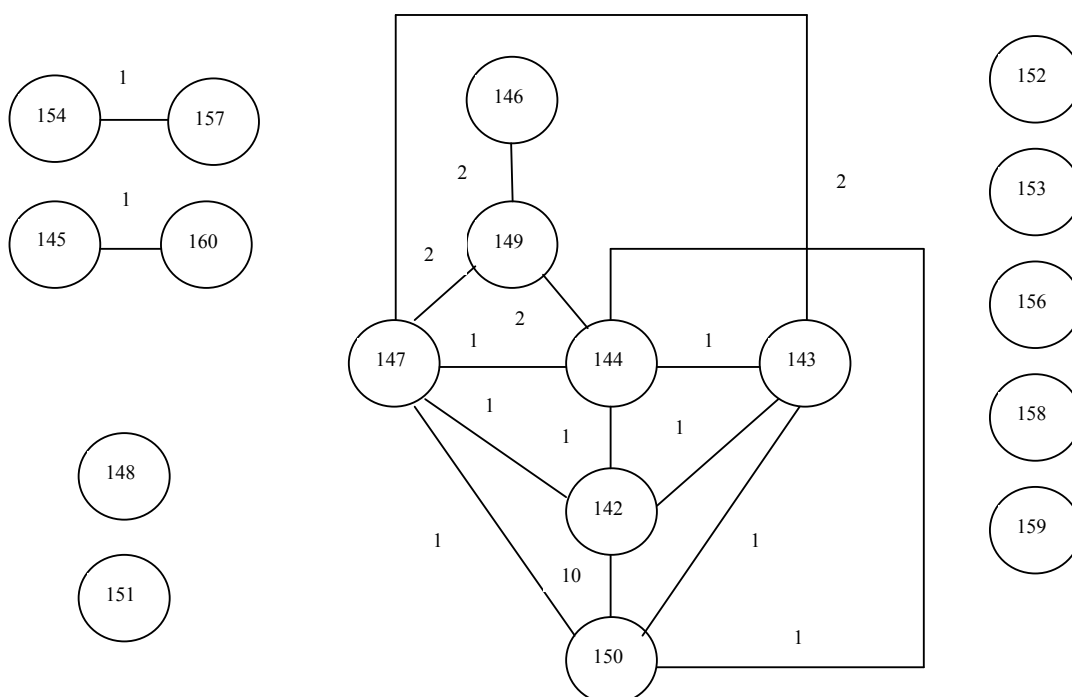
	R4600,R4603,R4606,R4607, R4608,R4609,R4610,R4611, R4612,R4613,R4614,R4615		
A154	R121,R122,R337,R1066,R4617, R4619,R4620,R4621,R4622, R4626	2004/10	Associative memories, brain-state-in-a-box (BSB) neural networks, gray-scale images, multilayer architecture
A156	R576,R577,R3710,R3711,R3717, R3726,R4666,R4667,R4668, R4670,R4671,R4672,R4674, R4675,R4678,R4679,R4680, R4681,R4682,R4683,R4684, R4685,R4686,R4687	2004/24	Image matching, primary cortex, prior knowledge, pulse-coupled neural network (PCNN), temporal codin
A157	R121,R4688,R4689,R4690,R4691, R4692,R4693,R4694,R4695, R4696,R4697,R4698,R4699, R4700,R4701,R4702,R4704, R4705	2004/18	Chaos, grouping, integrate-and-fire, pulse-coupled network (PCN), spiking neuron, synchronization
A158	R3430,R4706,R4707,R4708, R4709,R4710,R4711,R4713, R4714,R4715,R4716,R4717, R4718,R4719,R4720,R4721, R4722,R4723,R4724,R4725	2004/20	Mixture of experts, modular architecture, robot grasping, robot learning
A159	R4726,R4727,R4728,R4729, R4730,R4731,R4732,R4733, R4734,R4735,R4736,R4737, R4738,R4739,R4740,R4741, R4742,R4743,R4744,R4745, R4746,R4747	2004/22	Hierarchical self-organizing neural network, trajectory analysis and learning, anomaly detection, behavior prediction
A160	R749,R4748,R4749,R4750,R4751, R4752,R4753,R4754,R4755, R4756,R4757,R4758,R4759, R4761,R4762,R4763,R4764,R4765	2004/18	Deformable models, image segmentation, intravascular ultrasound (IVUS)

A Tabela 28 apresenta as referências comuns a cada dois artigos do **GrupoSeis_E1**.

Tabela 28 - Referências comuns a cada dois artigos do GrupoSeis_E1

Artigos	Número de Referências Comuns (Referências)
A142 e A150	10(R44,R52,R283,R287,R288,R311,R704,R762,R775,R3801)
A142 e A143	1(R704)
A142 e A144	1(R704)
A142 e A147	1(R704)
A143 e A144	1(R704)
A143 e A147	2(R704,R1414)
A143 e A150	1(R704)
A144 e A147	1(R704)
A144 e A149	2(R2238,R2555)
A144 e A150	1(R704)
A145 e A160	1(R749)
A146 e A149	2(R2779,R4409)
A147 e A149	2(R989,R4432)
A147 e A150	1(R704)
A154 e A157	1(R121)

A relação de referências comuns a cada dois artigos do GrupoSeis_E1, mostrada na Tabela 28, pode ser visualizada na Figura 33.

Figura 33 - Relação de referências comuns aos artigos do GrupoSeis_E1

A Tabela 29 apresenta o número de vezes que as referências foram citadas pelos artigos do grupo.

Tabela 29 - Referências repetidas no GrupoSeis_E1

Número de vezes que as referências se repetem (Número de referências repetidas)	Referência (Artigos)
2 (18)	R44(A142,A150),R52(A142,A150),R121(A154,A157), R283(A142,A150),R287(A142,A150),R288(A142,A150), R311(A142,A150),R749(A145,A160),R762(A142,A150), R775(A142,A150),R989(A147,A149),R1414(A143,A147), R2238(A144,A149),R2555(A144,A149),R2779(A146,A149), R3801(A142,A150), R4409(A146,A149),R4432(A147,A149)
5 (1)	R704(A142,A143,A144,A147,A150)

Dos 18 artigos do GrupoSeis_E1, sete não tinham referências em comum com o grupo (A148, A151, A152, A153, A156, A158, A159). Dois artigos, o A142 e o A150 tinham dez referências em comum. A grande maioria dos artigos que tinha referência em comum apresentava uma referência em comum. Dezoito referências se repetiam em dois artigos e uma referência se repetia em cinco artigos. Todos os artigos foram publicados em 2004.

O sétimo grupo foi denominado GrupoSete_E1 e é apresentado na Tabela 30, onde podem ser observadas as características do grupo nas quatro topologias avaliadas. Em cada topologia, este grupo foi chamado de GrupoSete_E1_10, GrupoSete_E1_12, GrupoSete_E1_16 e GrupoSete_E1_25 respectivamente.

Tabela 30 - Categorização do GrupoSete_E1

GrupoSete_E1	Número de Artigos	Artigos														
GrupoSete_E1_10	38															
GrupoSete_E1_12	25										A62					
GrupoSete_E1_16	33	A45	A51	A52	A53	A55	A56	A59	A60	A61		A65	A67	A68	A72	A73
GrupoSete_E1_25	33															

GrupoSete_E1	Número de Artigos	Artigos														
GrupoSete_E1_10	38					A161	A162	A163	A164	A165	A166	A167	A168	A169	A170	A171
GrupoSete_E1_12	25						A162	A163	A164	A165	A166	A167	A168			A171
GrupoSete_E1_16	33	A74	A75	A76	A77					A165	A166	A167	A168			A171
GrupoSete_E1_25	33					A161	A162	A163	A164	A165	A166	A167		A169	A170	A171

GrupoSete_E1	Número de Artigos	Artigos													
GrupoSete_E1_10	38	A172	A173	A174	A175	A176	A177	A178	A179	A180	A181	A182	A183	A185	A186
GrupoSete_E1_12	25	A172		A174			A177			A180	A181	A182	A183		
GrupoSete_E1_16	33			A174						A180	A181	A182			
GrupoSete_E1_25	33		A173	A174	A175	A176		A178	A179	A180	A181	A182		A185	A186

GrupoSete_E1	Número de Artigos	Artigos													
GrupoSete_E1_10	38	A187		A189	A190	A191	A192	A193	A194	A195	A196	A197	A198	A199	A200
GrupoSete_E1_12	25				A190			A193	A194	A195	A196	A197	A198	A199	A200
GrupoSete_E1_16	33				A190				A194		A196		A198	A199	A200
GrupoSete_E1_25	33	A187	A188	A189	A190	A191	A192		A194	A195	A196		A198	A199	A200

Dentre os artigos apresentados, 14 artigos estavam presentes em todas as topologias selecionadas. Os artigos comuns às topologias eram os artigos A165, A166, A167, A171, A174, A180, A181, A182, A190, A194, A196, A198, A199 e A200. A Tabela 31 apresenta as características destes artigos.

Tabela 31 - Características dos artigos presentes no GrupoSete_E1

Artigo	Referências	Ano/No. de referências	Palavras-chave
A165	R4880,R4881,R4882,R4883, R4884,R4885,R4886,R4887,R4888	2006/9	BSNN, DRNN, Hybrid Neural Network, RPE
A166	R121,R122,R337,R1066,R4617, R4619,R4620,R4621,R4622,R4626	2006/10	Associative memories, brain-state-in-a-box (BSB) neural networks, gray-scale images, multilayer architectures
A167	R257,R2637,R4899,R4900,R4901, R4902,R4903,R4904,R4907, R4908,R4909	2006/11	Convergence, feedforward neural network, gradient method, momentum
A171	R81,R202,R518,R704,R989, R2558,R2572,R3251,R4996, R4999,R5001,R5003,R5005, R5006,R5007,R5008,R5009, R5010,R5012,R5013,R5014, R5015,R5017	2006/23	Adaptive filtering, Lyapunov stability, backpropagation (BP), convergence, feedforward neural networks
A174	R202,R247,R1401,R1720,R1790, R2115,R2238,R3139,R3832, R5094,R5095,R5097,R5098,	2006/49	Descriptive encoding, evolutionary neural networks, modular neural network

	R5099,R5100,R5101,R5102, R5104,R5105,R5106,R5107, R5108,R5109,R5110,R5111, R5113,R5114,R5115,R5117, R5118,R5119,R5120,R5121, R5122,R5123,R5124,R5125, R5126,R5127,R5128,R5129, R5132,R5134,R5135,R5137, R5138,R5139,R5141,R5142		
A180	R248,R1025,R1035,R1248,R1601, R1604,R1611,R2564,R2639, R2926,R2927,R2930,R4011, R5282,R5309,R5323,R5338, R5345,R5347,R5348,R5350, R5352,R5353,R5356,R5359, R5360,R5368,R5370,R5371, R5372,R5373,R5374,R5376, R5377,R5379,R5380,R5381, R5384,R5385,R5386,R5387, R5388,R5389	2006/43	Bayesian method, discriminant analysis, radial basis function neural networks (RBFNNs)
A181	R64,R114,R122,R155,R1132, R1135,R1138,R1142,R1202, R1574,R1593,R1628,R2405, R3451,R4795,R4808,R5024, R5391,R5399,R5401,R5403, R5406,R5410	2006/23	Delayed cellular neural networks, S- procedure, global asymptotic stability, linear matrix inequality (LMI)
A182	R202,R338,R1134,R1139,R1987, R2317,R2411,R2423,R4807, R4828,R5420,R5421,R5422, R5423,R5425	2006/15	Delay, Volterra integro-differential systems, recurrent neural networks (RNNs), stability
A190	R7,R50,R89,R124,R134,R326, R749,R795,R1133,R1139,R1295, R1353,R1533,R1626,R1638, R1998,R2144,R2401,R2409, R2480,R4182,R5222,R5443, R5684,R5694,R5700,R5701, R5703,R5704,R5705,R5708,R5713	2006/32	Delays , output convergence, recurrent neural networks, time-varying inputs
A194	R63,R65,R118,R124,R132,R323, R1144,R1147,R1202,R1557, R2051,R2144,R2403,R2895,	2006/20	Discrete delay, distributed delays, global asymptotical stability, linear matrix inequality (LMI), recurrent neural

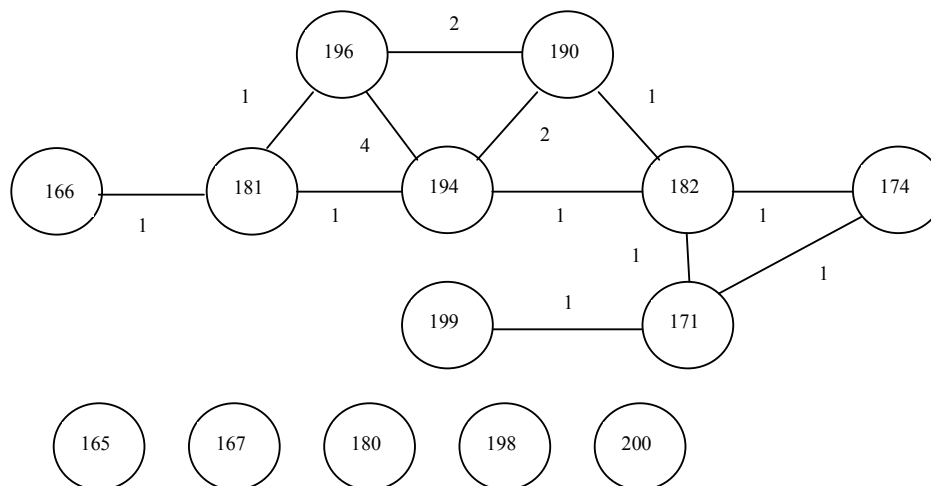
	R4828,R4926,R5798,R5799, R5806,R5811		networks (RNNs), time-varying delays
A196	R65,R124,R158,R744,R1202, R1292,R1533,R1544,R1552, R1553,R1560,R1569,R1582, R2067,R2403,R2729,R2888, R5855,R5858,R5860,R5862, R5864,R5871,R5872,R5873, R5876	2006/26	Cohen-Grossberg neural networks, discrete delays, distributed delays, global asymptotic stability, linear matrix inequality (LMI), Lyapunov-krasovskii functional, stochastic systems
A198	R2024,R2047,R3606,R5913, R5914,R5915,R5917,R5918, R5920,R5921,R5922,R5923, R5924,R5925,R5926,R5927, R5928,R5929,R5930,R5931, R5932,R5933,R5934,R5935, R5936,R5937,R5938,R5939, R5941,R5942,R5943,R5944, R5945,R5946,R5947,R5948, R5949,R5950,R5951	2006/39	Machine learning, class imbalance learning, cost-sensitive learning, data mining, ensemble learning, neural networks, sampling, threshold-moving
A199	R655,R656,R658,R660,R685,R704, R1451,R1599,R1619,R3036, R3704,R3885,R4415,R4443, R4494,R5952,R5954,R5956, R5957,R5958,R5960,R5961, R5962,R5964,R5965,R5966, R5967,R5969,R5972,R5973, R5974,R5975,R5976,R5977, R5979,R5983,R5984,R5985, R5986,R5987,R5988,R5989, R5990,R5991,R5992,R5993	2006/46	Adaptive wavelet neural network (AWNN), hysteresis friction model, lumped uncertainty, piezo-positioning mechanism, robust compensator
A200	R1433,R1435,R2555,R2996, R5998,R5999,R6000,R6002, R6004,R6005,R6006,R6007, R6008,R6009,R6010,R6011, R6012,R6013	2006/18	Adaptive control, backstepping design, neural networks (NNs), triangular forms

A Tabela 32 apresenta as referências comuns a cada dois artigos do GrupoSete_E1.

Tabela 32 - Referências comuns a cada dois artigos do GrupoSete_E1

Artigos	Número de Referências Comuns (Referências)
A166 e A181	1(R122)
A171 e A174	1(R202)
A171 e A182	1(R202)
A171 e A199	1(R704)
A174 e A182	1(R202)
A181 e A194	1(R1202)
A181 e A196	1(R1202)
A182 e A190	1(R1139)
A182 e A194	1(R4828)
A190 e A194	2(R124,R2144)
A190 e A196	2(R124,R1533)
A194 e A196	4(R65,R124,R1202,R2403)

A relação de referências comuns a cada dois artigos do GrupoSete_E1, mostrada na Tabela 32, pode ser visualizada na Figura 34.

Figura 34 - Relação de referências comuns aos artigos do GrupoSete_E1

A Tabela 33 apresenta o número de vezes que as referências foram citadas pelos artigos do grupo.

Tabela 33 - Referências repetidas no GrupoSete_E1

Número de vezes que as referências se repetem (Número de referências repetidas)	Referência (Artigos)
2 (8)	R65(A194,A196),R122(A166,A181),R704(A171,A199), R1139(A182,A190),R1533(A190,A196),R2144(A190,A194), R2403(A194,A196),R4828(A182,A194)
3 (3)	R124(A190,A194,A196),R202(A171,A174,A182), R1202(A181,A194,A196)

Todos os 14 artigos do GrupoSete_E1 foram publicados em 2006. Oito referências se repetiram em dois artigos e três referências se repetiram em três artigos do grupo. Cinco artigos (A165, A167, A180, A198 e A200) não tinham referências em comum com o grupo. A grande maioria dos artigos tinha uma referência em comum. Apenas dois artigos citavam quatro referências iguais. Oito referências se repetiram duas vezes entre os artigos deste grupo e três foram citadas por três artigos.

A Tabela 34 apresenta um resumo das características dos grupos gerados no Experimento 1. A segunda coluna da tabela mostra o número total de artigos do grupo, a terceira coluna apresenta os artigos do grupo, a quarta coluna indica o ano de publicação dos artigos agrupados com o respectivo número de artigos publicados naquele ano entre parênteses e a quinta e sexta coluna exibem, respectivamente, o número máximo de referências comuns a cada dois artigos do grupo e o número máximo de vezes que as referências se repetiam.

Tabela 34 - Características dos Grupos do Experimento 1

Grupos	Número de Artigos	Artigos	Ano de Publicação (Número de Artigos)	Número máximo de Referências comuns a 2 artigos	Número máximo de vezes que as Referências se repetiam
GrupoUm_E1	6	A1,A18,A47,A48,A49,A50	2007(1),2008(3), 2009(1), 2010(1)	21	6
GrupoDois_E1	18	A3,A4,A9,A10,A16,A17,A26, A27,A30,A31,A32,A33,A34, A36,A37,A38, A39,A40	2009(1),2010(17)	16	3
GrupoTrês_E1	14	A42,A44,A46,A54,A57,A58, A63,A64,A66,A69,A70,A71,	2008(14)	7	3

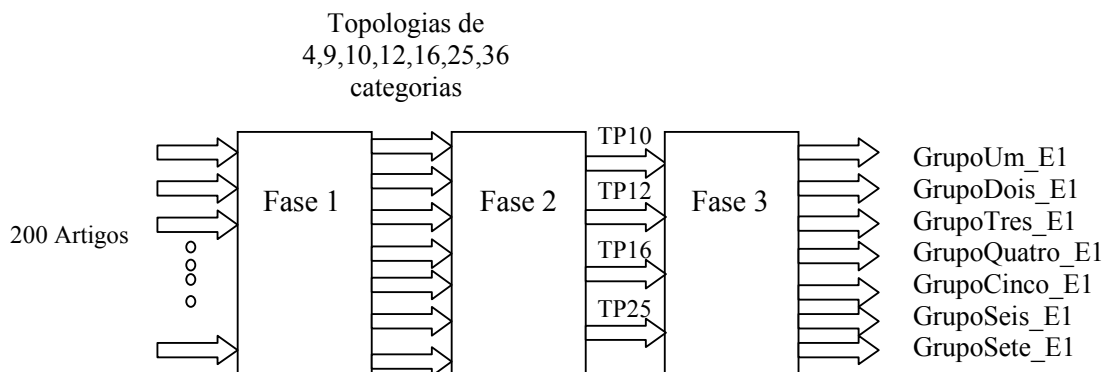
		A78,A80			
GrupoQuatro_E1	23	A81,A82,A83,A84,A85,A86, A87,A88,A89,A90,A91,A92, A93,A94,A95,A96,A97,A98, A99,A100,A101,A114,A115	2001(20),2002(3)	8	7
GrupoCinco_E1	16	A121,A122,A126,A127,A128, A129,A130,A131,A134,A135, A136,A137,A138,A139, A140	2003(16)	1	4
GrupoSeis_E1	18	A142,A143,A144,A145,A146, A147,A148,A149,A150,A151, A152,A153,A154,A156,A157, A158,A159,A160	2004(18)	2	5
GrupoSete_E1	14	A165,A166,A167,A171,A174, A180,A181,A182,A190,A194, A196,A198,A199,A200	2006(14)	4	3

A quarta coluna da Tabela 34 mostrou que a influência do ano de publicação do artigo como atributo de categorização era grande e os grupos gerados foram, predominantemente, formados pelos artigos de um mesmo ano. Como observado na análise das duas últimas colunas da Tabela 34, o GrupoUm_E1 era o grupo que apresentava artigos com o maior número de referências comuns a cada dois artigos do grupo. O número máximo de vezes que as referências se repetiam também era alto comparado aos outros grupos. No caso do GrupoUm_E1, três referências se repetiram 6 vezes e, no caso dos grupos GrupoQuatro_E1, GrupoCinco_E1 e GrupoSeis_E1, apenas uma referência se repetiu 7, 4 e 5 vezes, respectivamente. O GrupoUm_E1 era, portanto, o grupo caracterizado pelo maior número de referências em comum, podendo ser também interpretado como o grupo que apresentava a relação semântica mais forte entre os artigos que o integravam.

A Figura 35 resume as fases do experimento 1. A primeira fase do experimento utilizou os dados relativos aos 200 artigos na entrada da RNA. Nesta fase, cada artigo carregava a informação do ano de sua publicação e da presença ou da ausência das 6015 referências cadastradas. A RNA gerou, nesta fase do experimento, 7 saídas distintas. Cada uma delas gerava um número diferente de categorias, quais sejam 4, 9, 10, 12, 16, 25 e 36 categorias. Estas 7 topologias, caracterizadas por um número diferente de categorias geradas, foram analisadas na fase 2 do experimento, responsável pela definição das topologias que concentrassem a maioria dos artigos em um número semelhante de grupos. Foram selecionadas quatro topologias, denominadas, na Figura 35, TP10, TP12, TP16 e TP25, que

concentravam a maior parte dos artigos em sete categorias. A fase 3 gerou a saída do experimento pela análise dos sete grupos principais das quatro topologias. Foram selecionados os artigos que estavam presentes em todos os grupos de cada uma das quatro topologias.

Figura 35 - Fases do experimento 1



Os dois próximos experimentos tiveram o objetivo de reduzir a influência do ano de publicação do artigo no processo de categorização realizado pela RNA, constatada nas análises dos resultados do experimento 1, e valorizar a presença das referências como atributo de categorização.

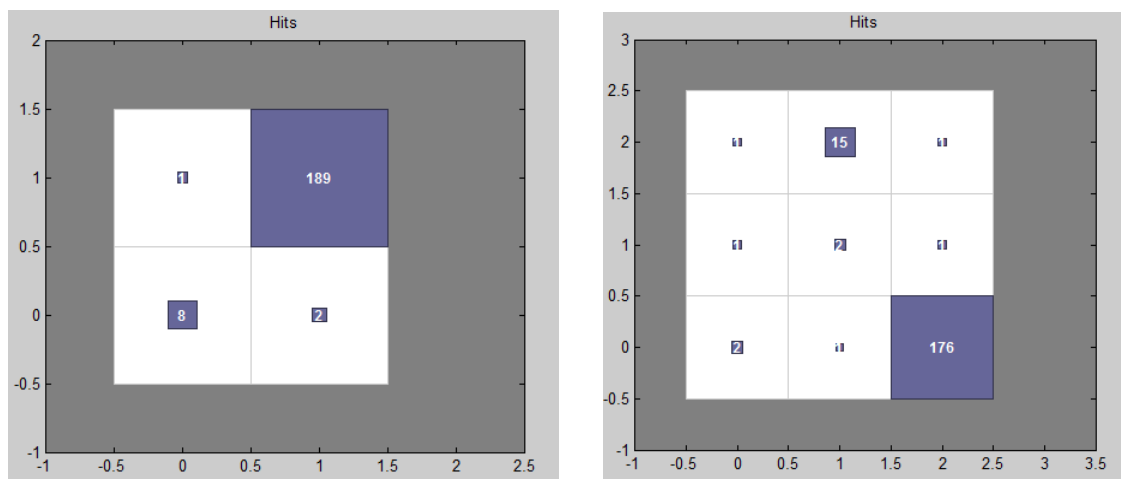
5.2. Apresentação e análise dos resultados do experimento 2

Com o objetivo de reduzir a forte influência do ano como atributo de categorização, a codificação utilizada para a representação do ano foi alterada. Como a presença e a ausência da referência no artigo era representada pelos algarismos 1 e 0, reduziu-se o valor absoluto do algarismo representativo do ano na tentativa de aumentar a influência das referências como atributo de categorização. O ano de publicação do artigo era representado pelos valores 2001 a 2010. Neste experimento, os anos foram representados com uma variação de 0,1 a 1,0. O artigo publicado em 2001 tinha 0,1 como representação do ano, o publicado em 2002, 0,2 e, assim por diante, até o valor 1,0 como representação do artigo publicado em 2010.

Esta categorização apresentou, para 6 das 7 topologias avaliadas, um grupo com uma grande concentração de artigos, um grupo menor, denominado GrupoA_E2, neste experimento, e o restante dos artigos distribuídos nas demais categorias. Este resultado pode

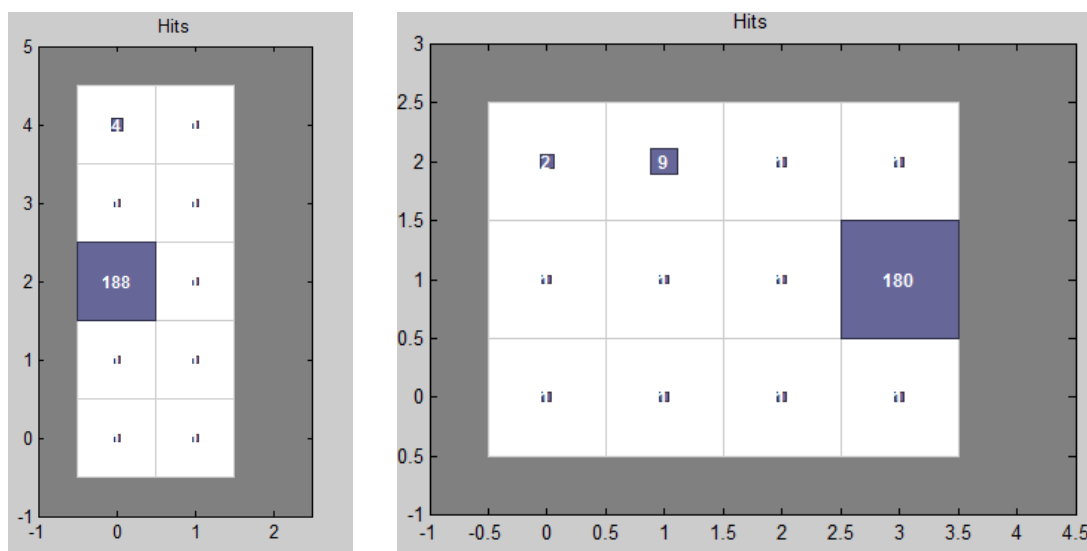
ser observado nas figuras seguintes. A Figura 36 apresenta os grupos de artigos gerados pelas topologias da RNA que geravam 4 e 9 categorias.

Figura 36 - Grupos de artigos gerados pelas topologias de 4 e 9 categorias



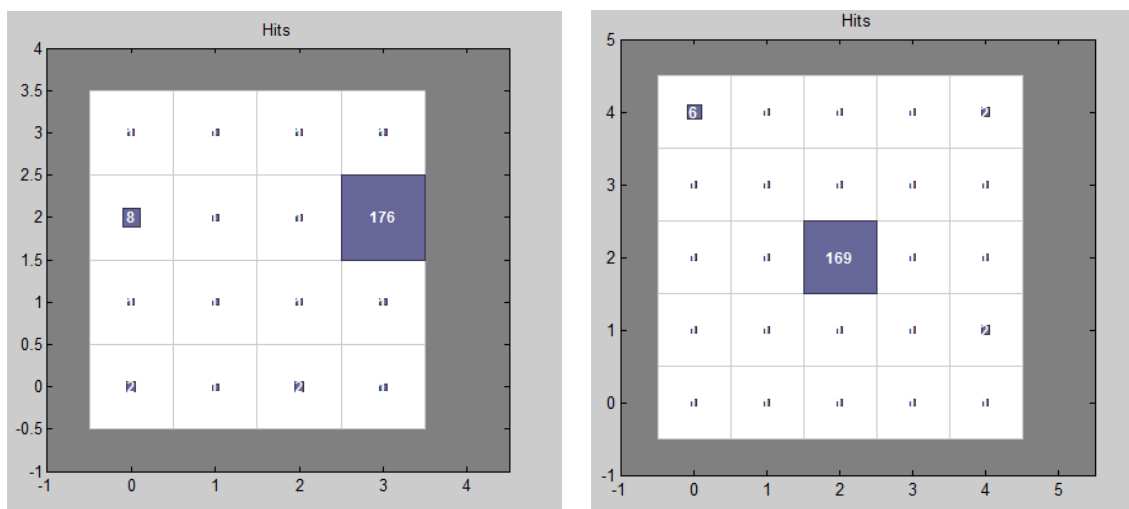
A Figura 37 apresenta os grupos de artigos criados pelas topologias da RNA que geravam 10 e 12 categorias.

Figura 37 - Grupos de artigos gerados pelas topologias de 10 e 12 categorias




A Figura 38 apresenta os grupos de artigos criados pelas topologias da RNA que geravam 16 e 25 categorias.

Figura 38 - Grupos de artigos gerados pelas topologias de 16 e 25 categorias



A Figura 39 apresenta os grupos de artigos criados pela topologia da RNA que gerava 36 categorias.

Figura 39 - Grupos de artigos gerados pela topologia de 36 categorias



A Tabela 35 apresenta os artigos que compõem o GrupoA_E2 em cada uma das topologias selecionadas. Na topologia que gerava 36 categorias, não foi identificado o GrupoA_E2. Eram identificados o grande grupo e os demais artigos distribuídos nas categorias restantes. Esta topologia foi, por este motivo, descartada. Em cada uma das

topologias selecionadas, o grupo GrupoA_E2 foi denominado GrupoA_E2_4, GrupoA_E2_9, GrupoA_E2_10, GrupoA_E2_12, GrupoA_E2_16 e GrupoA_E2_25 respectivamente.

Tabela 35 - Características do GrupoA_E2 em cada uma das topologias

GrupoA_E2	Número de artigos	Artigos															
		A1	A6	A11	A18	A34	A35	A47	A48	A49	A50	A114	A141	A142	A150	A177	A195
GrupoA_E2_4	8	A1		A11	A18		A35	A47	A48	A49	A50						
GrupoA_E2_9	15		A6	A11	A18	A34	A35	A47	A48	A49	A50	A114	A141	A142	A150	A177	A195
GrupoA_E2_10	4	A1			A18			A47			A50						
GrupoA_E2_12	9	A1	A6		A18			A47	A48	A49	A50		A141				A195
GrupoA_E2_16	8	A1	A6		A18			A47	A48	A49	A50						A195
GrupoA_E2_25	6	A1			A18			A47	A48	A49	A50						

Para compor o GrupoA_E2, que foi utilizado para análise, foram selecionados os artigos presentes em mais de uma topologia. Foram analisados, portanto, 11 artigos, quais sejam, os artigos A1, A6, A11, A18, A35, A47, A48, A49, A50, A141 e A195. As características dos artigos foram apresentadas na Tabela 36.

Tabela 36 - Características dos artigos do GrupoA_E2

Artigos	Referências	Ano/No. de referências	Palavras-chave	Autores
A1	R1,R2,R3,R4,R5,R6,R7,R8, R9,R10,R11,R12,R13,R14, R15,R16,R17,R18,R19,R20, R21,R22,R23,R24,R25,R26, R27,R28,R29,R30,R31,R32, R33,R34,R35,R36,R37,R38, R39,R40,R41,R42,R43	2009/43	Asymptotic stability, k-winners-take-all (WTA), linear programming, neural network, quadratic programming	Xiaolin Hu; Bo Zhang;
A6	R1,R13,R16,R20,R21,R24, R25,R28,R33,R34,R44,R48, R283,R285,R287,R288, R289,R292,R295,R296, R297,R301,R302,R304, R305,R306,R307,R308, R311	2009/29	Convergence, neural network, stability, variational inequality	Xing-Bao Gao; Li-Zhi Liao
A11	R3,R4,R12,R13,R17,R24, R25,R26,R30,R32,R33,R41,	2010/39	L1-norm optimization, least absolute deviation(LAD),	Xiaolin Hu; Changyin

	R44,R45,R85,R292,R426, R432,R457,R458,R459, R460,R462,R463,R465, R470,R477,R478,R480, R482,R483,R484,R485, R486,R488,R489,R490, R491,R492		minimax optimization, recurrent neural network (RNN),stability analysis	Sun; Bo Zhang
A18	R1,R3,R4,R5,R6,R9,R10, R11,R12,R13,R15,R18, R19,R20,R22,R25,R26,R30, R32,R34,R41,R44,R55,R85, R283,R287,R289,R295, R297,R304,R307,R308, R432,R704,R762,R764, R769,R772,R774,R775, R786,R795,R798,R800, R802,R805,R806	2010/47	Convergence, linear and quadratic programming, neural network, stability	Xing-Bao Gao; Li-Zhi Liao
A35	R3,R4,R12,R13,R17,R24, R25,R26,R30,R32,R33,R41, R44,R45,R85,R292,R426, R432,R457,R458,R459, R460,R462,R463,R465, R470,R477,R478,R480, R482,R483,R484,R485, R486,R488,R489,R490, R491,R492	2010/39	L1-norm optimization, least absolute deviation (LAD), minimax optimization, recurrent neural network (RNN), stability analysis	Xiaolin Hu; Changyin Sun; Bo Zhang
A47	R1,R3,R4,R5,R9,R12,R13, R15,R16,R17,R19,R20,R24, R26,R30,R36,R40,R44,R50, R53,R92,R94,R134,R295, R802,R806,R1351,R1800, R1817,R1818,R1821,R1822, R1826,R1827,R1828, R1829	2008/36	winners-take-all (k-WTA), Global asymptotic stability, optimization, quadratic programming (QP), recurrent neural network	Xiaolin Hu; Jun Wang
A48	R1,R4,R5,R7,R9,R12,R18, R19,R24,R26,R55,R131, R134,R158,R160,R311, R439,R445,R802,R806, R1202,R1248,R1351,R1688, R1800,R1843,R1854,R1858,	2008/39	Differential inclusion, Lyapunov stability, global convergence, hard-limiting activation function, nonlinear programming, quadratic programming, recurrent neural	Qingshan Liu; Jun Wang

	R1859,R1860,R1861,R1862, R1864,R1865,R1866,R1868, R1869,R1870,R1871		network	
A49	R4,R6,R9,R13,R17,R18, R19,R24,R26,R33,R55, R120,R288,R292,R311, R426,R432,R434,R439, R445,R762,R806,R1204, R1348,R1351,R1354,R1688, R1689,R1712,R1843,R1858, R1873,R1874,R1875,R1877, R1883,R1885,R1886,R1890, R1907,R1908,R1909,R1911, R1912,R1914,R1915,R1916, R1917,R1919,R1920,R1922	2008/51	Constrained optimization, convergence, convex and nonconvex problems, recurrent neural networks	Maria P. Barbarosou; Nicholas G. Maratos
A50	R1,R3,R5,R9,R11,R12,R16, R17,R18,R19,R20,R21,R24, R26,R28,R33,R48,R49,R50, R52,R53,R55,R295,R1346, R1351,R1689,R1843,R1925, R1948	2007/29	Global convergence, linear programming, linear variational inequality (LVI), quadratic programming, recurrent neural network	Xiaolin Hu; Jun Wang
A141	R1,R4,R5,R6,R9,R23,R44, R71,R285,R288,R305,R432, R762,R802,R1345,R1346, R1351,R1827,R1843,R1875, R1885,R2973,R3652,R4275, R4276,R4278,R4292,R4296, R4297,R4299,R4300,R4302	2004/32	Global stability, recurrent neural networks, variational inequalities optimization	Youshen Xia; Jun Wang
A195	R1,R4,R5,R6,R18,R32,R44, R50,R52,R53,R287,R295, R307,R428,R439,R483, R1351,R1800,R1890,R3652, R4275,R4276,R4296,R4297, R5813,R5819,R5821,R5822, R5823,R5824,R5840,R5841, R5842,R5843,R5844,R5846, R5847,R5849,R5850	2006/39	Component wise pseudomonotone variational inequality, global asymptotic stability, projection neural network, pseudoconvex optimization, pseudomonotone variational inequality	Xiaolin Hu; Jun Wang

As próximas tabelas apresentaram as referências comuns a cada dois artigos do grupo e o número de vezes que as referências se repetiam nos artigos. Estas informações

confirmaram a existência de um grande número de referências comuns aos artigos do GrupoA_E2. Três dos artigos foram publicados em 2010, dois em 2009, três em 2008, um em 2007, um em 2006 e um em 2004. Avaliando-se as palavras-chave dos artigos, observou-se que sete artigos (A11,A35,A47,A48,A49,A50,A141) apresentaram a palavra-chave “*recurrent neural network*”, quatro artigos (A1,A47,A48,A50) tinham a palavra-chave “*quadratic programming*” e três dos artigos apresentaram a palavra “*neural network*”. A autoria dos artigos foi discutida posteriormente.


A Tabela 37 apresenta as referências comuns a cada dois dos onze artigos que compõem o GrupoA_E2.

Tabela 37 - Referências comuns a cada dois artigos do GrupoA_E2

Artigos	Número de Referências Comuns (Referências)
A1 e A6	10(R1,R13,R16,R20,R21,R24,R25,R28,R33,R34)
A1 e A11	12(R3,R4,R12,R13,R17,R24,R25,R26,R30,R32,R33,R41)
A1 e A18	21(R1,R3,R4,R5,R6,R9,R10,R11,R12,R13,R15,R18,R19,R20,R22,R25,R26,R30,R32,R34,R41)
A1 e A35	12(R3,R4,R12,R13,R17,R24,R25,R26,R30,R32,R33,R41)
A1 e A47	15(R1,R3,R4,R5,R9,R12,R13,R15,R16,R17,R19,R20,R24,R26,R30)
A1 e A48	10(R1,R4,R5,R7,R9,R12,R18,R19,R24,R26)
A1 e A49	10(R4,R6,R9,R13,R17,R18,R19,R24,R26,R33)
A1 e A50	16(R1,R3,R5,R9,R11,R12,R16,R17,R18,R19,R20,R21,R24,R26,R28,R33)
A1 e A141	6(R1,R4,R5,R6,R9,R23)
A1 e A195	6(R1,R4,R5,R6,R18,R32)
A6 e A11	6(R13,R24,R25,R33,R44,R292)
A6 e A18	14(R1,R13,R20,R25,R34,R44,R283,R287,R289,R295,R297,R304,R307,R308)
A6 e A35	6(R13,R24,R25,R33,R44,R292)
A6 e A47	7(R1,R13,R16,R20,R24,R44,R295)
A6 e A48	3(R1,R24,R311)
A6 e A49	6(R13,R24,R33,R288,R292,R311)
A6 e A50	9(R1,R16,R20,R21,R24,R28,R33,R48,R295)
A6 e A141	5(R1,R44,R285,R288,R305)
A6 e A195	5(R1,R44,R287,R295,R307)
A11 e A18	13(R3,R4,R12,R13,R25,R26,R30,R32,R41,R44,R45,R85,R432)
A11 e A35	39(R3,R4,R12,R13,R17,R24,R25,R26,R30,R32,R33,R41,R44,R45,R85, R292,R426,R432,R457,R458,R459,R460,R462,R463,R465,R470, R477,R478,R480,R482,R483,R484,R485,R486,R488,R489,R490,R491,R492)
A11 e A47	9(R3,R4,R12,R13,R17,R24,R26,R30,R44)
A11 e A48	4(R4,R12,R24,R26)

A11 e A49	9(R4,R13,R17,R24,R26,R33,R292,R426,R432)
A11 e A50	6(R3,R12,R17,R24,R26,R33)
A11 e A141	3(R4,R44,R432)
A11 e A195	4(R4,R32,R44,R483)
A18 e A35	12(R3,R4,R12,R13,R25,R26,R30,R32,R41,R44,R85,R432)
A18 e A47	14(R1,R3,R4,R5,R9,R12,R13,R15,R19,R20,R26,R30,R44,R295)
A18 e A48	9(R1,R4,R5,R9,R12,R18,R19,R26,R802)
A18 e A49	9(R4,R6,R9,R13,R18,R19,R26,R432,R762)
A18 e A50	11(R1,R3,R5,R9,R11,R12,R18,R19,R20,R26,R295)
A18 e A141	9(R1,R4,R5,R6,R9,R44,R432,R762,R802)
A18 e A195	10(R1,R4,R5,R6,R18,R32,R44,R287,R295,R307)
A35 e A47	9(R3,R4,R12,R13,R17,R24,R26,R30,R44)
A35 e A48	4(R4,R12,R24,R26)
A35 e A49	9(R4,R13,R17,R24,R26,R33,R292,R426,R432)
A35 e A50	6(R3,R12,R17,R24,R26,R33)
A35 e A141	3(R4,R44,R432)
A35 e A195	4(R4,R32,R44,R483)
A47 e A48	10(R1,R4,R5,R9,R12,R19,R24,R26,R1351,R1800)
A47 e A49	8(R4,R9,R13,R17,R19,R24,R26,R1351)
A47 e A50	15(R1,R3,R5,R9,R12,R16,R17,R19,R20,R24,R26,R50,R53,R295,R1351)
A47 e A141	6(R1,R4,R5,R9,R44,R1351)
A47 e A195	9(R1,R4,R5,R44,R50,R53,R295,R1351,R1800)
A48 e A49	11(R4,R5,R9,R18,R19,R24,R26,R311,R439,R1351,R1843)
A48 e A50	10(R1,R5,R9,R12,R18,R19,R24,R26,R1351,R1843)
A48 e A141	7(R1,R4,R5,R9,R802,R1351,R1843)
A48 e A195	7(R1,R4,R5,R18,R439,R1351,R1800)
A49 e A50	9(R9,R17,R18,R19,R24,R26,R33,R1351,R1843)
A49 e A141	10(R4,R6,R9,R288,R432,R762,R1351,R1843,R1875,R1885)
A49 e A195	6(R4,R6,R18,R439,R1351,R1890)
A50 e 141	6(R1,R5,R9,R1346,R1351,R1843)
A50 e A195	8(R1,R5,R18,R50,R52,R53,R295,R1351)
A141 e A195	11(R1,R4,R5,R6,R44,R1351,R3652,R4275,R4276,R4296,R4297)

A Figura 40 mostra o relacionamento existente entre os artigos do GrupoA_E2. Cada artigo tem referências em comum com todos os outros componentes do grupo. O número de referências comuns a cada dois artigos foi apresentado na tabela anterior.

Figura 40 - Relação de referências comuns aos artigos do GrupoA_E2

A Tabela 38 mostra o número de vezes que as referências são citadas pelos artigos do grupo.

Tabela 38 - Referências repetidas no GrupoA_E2

Número de vezes que as referências se repetem (Número de referências repetidas)	Referência (Artigos)
2(43)	R7(A1,A48),R10(A1,A18),R22(A1,A18),R23(A1,A141), R45(11,35),R48(A6,A50),R52(A50,A195),R283(A6,A18), R285(A6,A141),R289(A6,A18),R297(A6,A18),R304(A6,A18), R308(A6,A18),R305(A6,A141),R457(A11,A35),R458(A11,A35), R459(A11,A35),R460(A11,A35),R462(A11,A35),R463(A11,A35), R465(A11,A35),R470(A11,A35),R477(A11,A35),R478(A11,A35), R480(A11,A35),R482(A11,A35),R484(A11,A35),R485(A11,A35), R486(A11,A35),R488(A11,A35),R489(A11,A35),R490(A11,A35), R491(A11,A35),R492(A11,A35),R1346(A50,A141),

	R1875(A49,A141),R1885(A49,A141),R1890(A49,A195), R3652(A141,A195),R4275(A141,A195),R4276(A141,A195), R4296(A141,A195),R4297(A141,A195)
3(18)	R11(A1,A18,A50),R15(A1,A18,A47),R21(A1,A6,A50), R28(A1,A6,A50),R34(A1,A6,A18),R50(A47,A50,A195), R53(A47,A50,A195),R85(A11,A18,A35),R287(A6,A18,A195), R288(A6,A49,A141),R307(A6,A18,A195),R311(A6,A48,A49), R426(A11,A35,A49),R439(A48,A49,A195),R483(A11,A35,A195), R762(A18,A49,A141),R802(A18,A48,A141), R1800(A47,A48,A195)
4(4)	R16(A1,A6,A47,A50),R41(A1,A11,A18,A35), R292(A6,A11,A35,A49), R1843(A48,A49,A50,A141)
5(7)	R6(A1,A18,A49,A141,A195),R20(A1,A6,A18,A47,A50), R25(A1,A6,A11,A18,A35),R30(A1,A11,A18,A35,A47), R32(A1,A11,A18,A35,A195),R295(A6,A18,A47,A50,A195), R432(A11,A18,A35,A49,A141)
6(6)	R3(A1,A11,A18,A35,A47,A50),R17(A1,A11,A35,A47,A49,A50), R18(A1,A18,A48,A49,A50,A195), R19(A1,A18,A47,A48,A49,A50),R33(A1,A6,A11,A35,A49,A50), R1351(A47,A48,A49,A50,A141,A195)
7(5)	R5(A1,A18,A47,A48,A50,A141,A195), R9(A1,A18,A47,A48,A49,A50,A141), R12(A1,A11,A18,A35,A47,A48,A50), R13(A1,A6,A11,A18,A35,A47,A49), R44(A6,A11,A18,A35,A47,A141,A195)
8(3)	R1(A1,A6,A18,A47,A48,A50,A141,A195), R24(A1,A6,A11,A35,A47,A48,A49,A50), R26(A1,A11,A18,A35,A47,A48,A49,A50)
9(1)	R4(A1,A11,A18,A35,A47,A48,A49,A141,A195)

O GrupoA_E2 foi constituído pelos artigos analisados no GrupoUm_E1 do experimento anterior acrescido dos artigos A6, A11, A35, A141 e A195. Conforme mostrado na Tabela 36, assim como o GrupoUm_E1, este grupo tinha um grande número de referências em comum entre dois artigos, chegando a 21 referências em comum entre os artigos A1 e A18. Sem considerar as 39 referências que existiam em comum entre os artigos A11 e A35, porque os artigos eram iguais, algumas referências se repetiram em 2 artigos e, até, em 9 dos 11 artigos presentes no grupo. As características das cinco referências mais citadas podem ser vistas na Tabela 39.

Tabela 39 - Características das cinco referências mais citadas no GrupoA_E2

Referência	Número de citações	Título	Autores	Ano de publicação
R1	8	Nonlinear programming: Theory and Algorithms	M. S. Bazaraa, H. D. Sherali and C. M. Shetty	1993
R4	9	Simple neural optimization networks: An A/D converter, signal decision circuit and a linear programming circuit	D. W. Tank and J. Hopfield	1986
R5	8	Neural networks for nonlinear programming problems	M. P. Kennedy and L. O. Chua	1988
R24	8	Solving pseudomonotone variational inequalities and pseudoconvex optimization problems using the projection neural network	X. Hu and J. Wang	2006
R26	8	Generalized neural network for nonsmooth nonlinear programming problems	M. Forti, P. Nistri and M. Quincampoix	2004

A referência R24, citada por oito (A1,A6,A11,A35,A47,A48,A49,A50) dos onze artigos, de autoria de Xiaolin Hu e Jun Wang e publicada em 2006 era o artigo 195, integrante do GrupoA_E2. Xiaolin Hu era autor dos artigos A1, A11, A35, A47, A50 e A195. Jun Wang participava da autoria dos artigos A47, A48, A50, A141 e A195. Os dois autores publicaram juntos os artigos A47, A50 e A195. Estes autores não participaram da autoria dos artigos A6, A18 e A49, publicados, respectivamente em 2009, 2010 e 2008. Mesmo não sendo autores da referência R24, os artigos A6 e A49 citaram a referência R24, descaracterizando o que poderia ser identificado apenas como autocitação. A referência R24 não foi citada pelos artigos A18 e A141.

Três das referências mais citadas foram obras anteriores ao período utilizado para a seleção de artigos realizada neste trabalho, que compreende publicações de 2001 a 2010. A referência R1, “*Nonlinear programming: Theory and Algorithms*”, é um livro clássico de otimização, publicado em 1993. A referência R4, “*Simple neural optimization networks: An A/D converter, signal decision circuit and a linear programming circuit*”, é um dos artigos mais citados de J. Hopfield, que é considerado o responsável pelo ressurgimento das RNA na

década de 80. A referência R5, “*Neural networks for nonlinear programming problems*”, tem mais de 600 citações, no Google acadêmico.

Das 5 referências mais citadas no GrupoA_E2, quatro (R1, R4, R5, R26) fazem parte do grupo das 16 referências mais citadas pelos 200 artigos apresentado na Figura 16.

A Tabela 40 relaciona todos os autores encontrados nos artigos do GrupoA_E2 aos seus respectivos artigos.

Tabela 40 - Relação entre os autores e os artigos do GrupoA_E2

Autores	Artigos (Ano de Publicação)
Bo Zhang	A1(2009),A11(2010),A35(2010)
Changyin Sun	A11(2010),A35(2010)
Jun Wang	A47(2008),A48(2008),A50(2007),A141(2004),A195(2006)
Li-Zhi Liao	A6(2009),A18(2010)
Maria P. Barbarosou	A49(2008)
Nicholas G. Maratos	A49(2008)
Qingshan Liu	A48(2008)
Xing-Bao Gao	A6(2009),A18(2010)
Xiaolin Hu	A1(2009),A11(2010),A35(2010),A47(2008),A50(2007),A195(2006)
Youshen Xia	A141(2004)

Os autores identificados como autores dos artigos que compunham o GrupoA_E2 formavam um grupo de autores que publicavam juntos, mas, não necessariamente, sempre juntos, o que aumentava o número de autores do grupo. Para analisar a relação entre os autores dos artigos agrupados e avaliar se existem ligações entre os conteúdos das pesquisas desenvolvidas, os próximos parágrafos relatam algumas informações relativas à formação destes autores, à área em que atuam e aos seus principais interesses de pesquisa.

Bo Zhang graduou-se em Beijing, na China, em 1958. Em 2010, era professor do *State Key Laboratory of Intelligent Technology and Systems, Tsinghua National Laboratory for Information Science and Technology* e do Departamento de Ciência da Computação e Tecnologia, na *Tsinghua University*, em Beijing, na China. Seus principais interesses de pesquisa incluem inteligência artificial, robótica, controle inteligente e reconhecimento de padrões. Até a data mencionada, este autor havia publicado 150 artigos e três monografias neste campo.

Changyin Sun recebeu o grau de doutor em engenharia elétrica, em 2004, pela *Southeast University*, em Nanjing, na China. Em 2010, o autor era professor da *School of*

Automation, na *Southeast University*. Nesta época, ele tinha publicado mais de 50 artigos. Seus interesses de pesquisa incluem redes neurais, reconhecimento de padrões e teoria de controle inteligente.

Jun Wang recebeu o grau de doutor em engenharia de sistemas, em 1991, pela *Case Western Reserve University* em Cleveland, Ohio, nos Estados Unidos. Em 2008, era professor do Departamento de Mecânica e Engenharia de Automação, na *Chinese University of Hong Kong*, em Hong Kong. Seus interesses de pesquisa incluem redes neurais e suas aplicações.

Li-Zhi Liao recebeu o grau de doutor, em 1990, na *School of Operations Research and Industrial Engineering*, da *Cornell University*, em Ithaca, no Estado de Nova York. Em 2010, este autor era professor do Departamento de Matemática, na *Hong Kong Baptist University*, em Hong Kong. Seus recentes interesses de pesquisa incluem otimização, controle ótimo, desigualdade variacional e computação científica.

Maria P. Barbarosou recebeu o grau de doutora em redes neurais, em 2008, pela *National Technical University of Athens*, em Atenas, na Grécia. Em 2008, esta autora trabalhava como professora e pesquisadora do Departamento de Eletrônica, na *Technological Educational Institute of Piraeus*, em Atenas, na Grécia. Seus interesses de pesquisa incluem redes neurais, teoria de sistemas e estimação de estado.

Nicholas G. Maratos recebeu o grau de doutor em otimização, pela *Imperial College of Science and Technology*, em Londres, na Inglaterra, em 1978. Em 2008, ele trabalhava como professor na *School of Electrical and Computer Engineering*, na *National Technical University of Athens*. Seus interesses de pesquisa incluem otimização não linear, projeto computacional de circuitos elétricos e redes neurais.

Qingshan Liu é doutorando do Departamento de Mecânica e Engenharia de Automação, na *Chinese University of Hong Kong*, em Hong Kong, na China. Seus interesses de pesquisa incluem teoria de otimização e aplicações, teoria de estabilidade, sistemas não lineares e redes neurais.

Xing-Bao Gao recebeu o grau de doutor em matemática aplicada pela *Xidian University*, em Xi'an, na China, em 2000. Em 2010, ele era professor da *College of Mathematics and Information Science*, na *Shaanxi Normal University*. Seus interesses de pesquisa incluem teoria de otimização, algoritmos e suas aplicações, redes neurais e métodos numéricos para equações diferenciais parciais.

Xialin Hu recebeu, em 2007, o grau de doutor em automação e engenharia auxiliada por computador pela *Chinese University of Hong Kong*, em *New Territories*, em

Hong Kong. Em 2010, este autor era professor do *State Key Laboratory of Intelligent Technology and Systems*, do *Tsinghua National Laboratory for Information Science and Technology* e do *Department of Computer Science and Technology*, na *Tsinghua University*, em Beijing, na China. Seus interesses de pesquisa incluem inteligência artificial e neurociência computacional.

Youshen Xia recebeu o grau de doutor, em 2000, do *Department of Automation and Computer-Aided Engineering*, da *Chinese University of Hong Kong*, na China. Em 2004, ele era professor do Departamento de Matemática Aplicada, na *Nanjing University of Posts and Telecommunications*. Seus interesses de pesquisa incluem projeto e análise de redes neurais recorrentes para otimização restrita, aplicações de rede neural à mineração de dados, fusão de dados e processamento de imagem e sinal.

O Quadro 8 resume as características dos autores apresentadas anteriormente.

Quadro 8 - Características dos autores dos artigos do GrupoA_E2

Autor	Formação/ Local/ Ano	Local de trabalho	Áreas de interesse de pesquisa
Bo Zhang	Graduação, Beijing, China, 1958	<i>State Key Laboratory of Intelligent Technology and Systems, Tsinghua National Laboratory for Information Science and Technology</i> e Departamento de Ciência da Computação e Tecnologia, <i>Tsinghua University</i> , Beijing, China	Inteligência artificial, robótica, controle inteligente e reconhecimento de padrões
Changyin Sun	Doutor em engenharia elétrica, <i>Southeast University</i> , Nanjing, China, 2004	<i>School of Automation, Southeast University</i> , Nanjing, China	Redes neurais, reconhecimento de padrões e teoria de controle inteligente
Jun Wang	Doutor em engenharia de sistemas, <i>Case Western Reserve University</i> , Cleveland, Ohio, Estados Unidos, 1991	Departamento de Mecânica e Engenharia de Automação, <i>Chinese University of Hong Kong</i> , Hong Kong, China	Redes neurais e suas aplicações
Li-Zhi Liao	Doutor, <i>School of Operations Research and Industrial Engineering</i> , Cornell	Departamento de Matemática, na <i>Hong Kong Baptist University</i> , em Hong	Otimização, controle ótimo, desigualdade variacional e

	University, Ithaca, Estado de Nova York, 1990	Kong, China.	computação científica
Maria P. Barbarosou	Doutora em redes neurais, <i>National Technical University of Athens</i> , Atenas, Grécia, 2008	Departamento de Eletrônica, <i>Technological Educational Institute of Piraeus</i> , Atenas, Grécia	Redes neurais, teoria de sistemas e estimação de estado.
Nicholas G. Maratos	Doutor em otimização, <i>Imperial College of Science and Technology</i> , Londres, Inglaterra, 1978	<i>School of Electrical and Computer Engineering, National Technical University of Athens</i> , Grécia.	Otimização não linear, projeto computacional de circuitos elétricos e redes neurais.
Qingshan Liu	Mestrado em Matemática aplicada pela <i>Southeast University</i> , Nanjing, China, 2005	Doutorando do Departamento de Mecânica e Engenharia de Automação, <i>Chinese University of Hong Kong</i> , Hong Kong, China	Teoria de otimização e aplicações, teoria de estabilidade, sistemas não lineares e redes neurais
Xing-Bao Gao	Doutor em matemática aplicada, <i>Xidian University</i> , Xi'an, China, 2000	<i>College of Mathematics and Information Science, Shaanxi Normal University</i> , Xi'an, China	Teoria de otimização, algoritmos e suas aplicações, redes neurais e métodos numéricos para equações diferenciais parciais
Xiaolin Hu	Doutor em automação e engenharia auxiliada por computador, <i>Chinese University of Hong Kong, New Territories</i> , Hong Kong, 2007	<i>State Key Laboratory of Intelligent Technology and Systems, Tsinghua National Laboratory for Information Science and Technology, Department of Computer Science and Technology, Tsinghua University</i> , Beijing, China	Inteligência artificial e neurociência computacional.
Youshen Xia	Doutor, <i>Department of Automation and Computer-Aided Engineering, Chinese University of Hong Kong</i> , China, 2000	Departamento de Matemática Aplicada, <i>Nanjing University of Posts and Telecommunications</i> , Nanjing, China	Projeto e análise de redes neurais recorrentes para otimização restrita, aplicações de rede neural à mineração de

			dados, fusão de dados e processamento de imagem e sinal
--	--	--	---

Dos dez pesquisadores apresentados, oito trabalham na China e dois, na Grécia. Muitos têm ou tiveram o mesmo local de formação ou o mesmo local de trabalho. Os pesquisadores da Grécia citaram quatro das cinco referências apontadas como referências mais citadas. Há entre eles uma identificação de interesses de pesquisa, apontados em seus currículos, e um grande número de referências comuns que utilizam em suas publicações. Como o número de referências em comum entre os artigos destes pesquisadores é grande, pode-se constatar que as pesquisas desenvolvidas por estes autores são bem aceitas no grupo. Observando-se as citações ao longo do tempo podem ser identificadas tendências de pesquisa na área de conhecimento abordada nos conteúdos destes artigos.

O grande grupo presente em todas as topologias da RNA utilizadas neste experimento tinha artigos representantes de cada um dos grupos do experimento 1, com exceção do GrupoUm_E1. Para identificar o que o grande grupo tinha em comum, tomou-se como exemplo, para avaliação, a topologia que gerava 16 grupos. Estavam presentes os artigos do GrupoDois_E1, com exceção dos artigos A36 e A40, todo o GrupoTrês_E1 e todo o GrupoQuatro_E1, os artigos do GrupoCinco_E1, com exceção dos artigos A122 e A127, todo o GrupoSeis_E1 e os artigos do GrupoSete_E1, com exceção do artigo A199. Os grupos do teste anterior, como já discutido, tinham como atributo principal o ano de publicação dos artigos, com um número reduzido de referências em comum.

Observando-se as referências que mais se repetiam nos grupos da topologia de 16 categorias, foi possível afirmar que algumas referências estavam presentes em mais de um grupo, com frequência que justificava o agrupamento dos artigos neste grande grupo. Duas referências foram destacadas, a referência R202 e a referência R704. A referência R202, “*Neural Networks: A Comprehensive Foundation*”, de S. Haykin, publicada em 1994, se repetia 3 vezes no GrupoDois_E1, 2 vezes no GrupoTrês_E1, 5 vezes no GrupoQuatro_E1, 4 vezes no GrupoCinco_E1 e 3 vezes no GrupoSete_E1. A referência R704, “*Applied Nonlinear Control*”, de J. J. E. Slotine and W. Li, publicada em 1991, se repetia 3 vezes no GrupoQuatro_E1, 5 vezes no GrupoSeis_E1 e 2 vezes no GrupoSete_E1. Estas referências em comum, ora com determinados grupos, ora com outros, foram apresentadas como uma das justificativas para o agrupamento destes artigos em um único grupo.

Muitos dos artigos presentes neste grande grupo não eram integrantes dos grupos citados, mas apresentavam referências em comum com os artigos dos grupos identificados no experimento 1. Para ilustrar esta afirmativa, a Tabela 41 apresenta os 176 artigos do grande grupo da topologia de 16 categorias avaliada e alguma característica dos artigos agrupados que justificava a classificação deste artigo como artigo deste grande grupo. As características são apresentadas de modo simplificado. A afirmação “R4, que se repete 5 vezes no GrupoQuatro_E1” relacionava o artigo da primeira coluna com uma de suas referências, a referência R4, que estava presente no GrupoQuatro_E1. A apresentação do grupo afirmava que o artigo também estava presente no grupo citado no experimento 1 e que era um artigo cujas referências se repetiam em outros artigos do grupo. O artigo A3, por exemplo, era um artigo do GrupoDois_E1, cujas referências se repetiam em outros artigos do grupo. Nos casos de alguns artigos do experimento 1 que foram agrupados tendo o ano de publicação como principal atributo de categorização, foram apresentadas características adicionais relativas às suas referências que pudessem associá-lo ao grupo. O artigo A9, por exemplo, era artigo que compunha o GrupoDois_E1 e que tinha apenas duas referências em comum com o A31. Tanto o A9 quanto o A31 não se relacionavam com o GrupoDois_E1. No entanto, o A9 citava a R247, também, presente no A5. A tabela mostra que os artigos agrupados neste grande grupo não tinham um grande número de referências em comum, mas, ao mantê-los em um grupo único, a RNA fez uma pequena associação de referências entre dois ou mais artigos, de tal modo que pudessem ser considerados artigos portadores de uma característica em comum.

Tabela 41 - Artigos do grande grupo da topologia de 16 categorias

Artigo	Característica apresentada pelo artigo
A2	R4, que se repete 5 vezes no GrupoQuatro_E1
A3	GrupoDois_E1
A4	GrupoDois_E1
A5	R202
A7	R237, que se repete 2 vezes no GrupoTres_E1
A8	R237, que se repete 2 vezes no GrupoTres_E1
A9	GrupoDois_E1 (sem relacionamento com o grupo), que apresenta a R 247 presente no A5
A10	GrupoDois_E1
A12	R503 presente no A24
A14	R428, que se repete 3 vezes no GrupoDois_E1
A15	R202 e R704
A16	GrupoDois_E1 (sem relacionamento com o grupo), que apresenta as referências do A30

A17	GrupoDois_E1
A19	R419 presente no A9
A20	R248 presente no A5
A21	R892, que se repete 3 vezes no GrupoQuatro_E1
A22	R905 presente no A23
A23	R247 presente no A5
A24	R109, que se repete 2 vezes no GrupoDois_E1
A25	R1015, que se repete 2 vezes no GrupoTres_E1
A26	GrupoDois_E1 (sem relacionamento com o grupo), que apresenta a R332 presente no A7
A27	GrupoDois_E1
A28	R134, que se repete 3 vezes no GrupoDois_E1
A29	R1159, que se repete 2 vezes no GrupoDois_E1
A30	GrupoDois_E1 (sem relacionamento com o grupo), que apresenta as referências do A16
A31	GrupoDois_E1 (sem relacionamento com o grupo), que apresenta R404 e R413 presentes no A9
A32	GrupoDois_E1
A33	GrupoDois_E1
A34	GrupoDois_E1
A37	GrupoDois_E1 (sem relacionamento com o grupo), que apresenta a R404 presente no A9
A38	GrupoDois_E1
A39	GrupoDois_E1
A41	R26, que se repete 3 vezes no GrupoDois_E1
A42	GrupoTres_E1
A43	R202
A44	GrupoTres_E1
A46	GrupoTres_E1
A51	R1159, que se repete 2 vezes no GrupoDois_E1
A52	R202
A53	R202
A54	GrupoTres_E1
A55	R5, que se repete 3 vezes no GrupoDois_E1
A56	R1159, que se repete 2 vezes no GrupoDois_E1
A57	GrupoTres_E1
A58	GrupoTres_E1
A59	R134, que se repete 3 vezes no GrupoDois_E1
A60	R248 presente no A5
A61	R248 presente no A5
A63	GrupoTres_E1
A64	GrupoTres_E1
A65	R729, que se repete 2 vezes no GrupoDois_E1

A66	GrupoTres_E1
A67	R989, que se repete 2 vezes no GrupoQuatro_E1
A68	R202
A69	GrupoTres_E1
A70	GrupoTres_E1
A71	GrupoTres_E1
A72	R202
A73	R1752 presente no A46
A74	R342 presente no A8
A75	R248 presente no A5
A76	R1272 presente no A32
A77	R231 presente no A5
A78	GrupoTres_E1
A79	R4, que se repete 5 vezes no GrupoQuatro_E1
A80	G3 (sem relacionamento com o grupo), que apresenta a R698 presente no A15
A81	GrupoQuatro_E1
A82	GrupoQuatro_E1
A83	GrupoQuatro_E1
A84	GrupoQuatro_E1 (sem relacionamento com o grupo), que apresenta a R348 presente no A8
A85	GrupoQuatro_E1
A86	GrupoQuatro_E1
A87	GrupoQuatro_E1
A88	GrupoQuatro_E1 (sem relacionamento com o grupo)
A89	GrupoQuatro_E1
A90	GrupoQuatro_E1
A91	GrupoQuatro_E1 (sem relacionamento com o grupo)
A92	GrupoQuatro_E1 (sem relacionamento com o grupo), que apresenta a R2040 presente no A53
A93	GrupoQuatro_E1
A94	GrupoQuatro_E1
A95	GrupoQuatro_E1 (sem relacionamento com o grupo), que apresenta a R2637 presente no A68
A96	GrupoQuatro_E1
A97	GrupoQuatro_E1
A98	GrupoQuatro_E1
A99	GrupoQuatro_E1
A100	GrupoQuatro_E1
A101	GrupoQuatro_E1
A102	R813 presente no A19
A103	R202
A104	R145 presente no A4

A105	R3026, que se repete 2 vezes no GrupoQuatro_E1
A106	R2119 presente no A55
A107	R714, que se repete 2 vezes no GrupoDois_E1
A108	R432, que se repete 2 vezes no GrupoQuatro_E1
A109	R81 presente no A3
A110	R37 presente no A3
A111	R738 presente no A17
A112	R1418, que se repete 2 vezes no GrupoDois_E1
A113	R704
A114	GrupoQuatro_E1
A115	GrupoQuatro_E1
A116	R257 presente no A5
A117	R704
A118	R3710, R3711, R3717 e R3726 em comum com o A156
A119	R728 presente no A16
A120	R9, que se repete 2 vezes no GrupoQuatro_E1
A121	GrupoCinco_E1 (sem relacionamento com o grupo), que apresenta a R432 presente no A10
A123	R749, que se repete 2 vezes no G6
A124	R2785 presente no A71
A125	R704
A126	GrupoCinco_E1
A128	GrupoCinco_E1 (sem relacionamento com o grupo), que apresenta a R697 presente no A15
A129	GrupoCinco_E1 (sem relacionamento com o grupo), que apresenta a R1010 presente no A25
A130	GrupoCinco_E1
A131	GrupoCinco_E1 (sem relacionamento com o grupo), que apresenta a R248 presente no A5
A132	R202
A133	R4, que se repete 5 vezes no GrupoQuatro_E1
A134	GrupoCinco_E1 (sem relacionamento com o grupo), que apresenta a R749 , que se repete 2 vezes no GrupoSeis_E1
A135	GrupoCinco_E1 (sem relacionamento com o grupo)
A136	GrupoCinco_E1 (sem relacionamento com o grupo), que apresenta a R2634 presente no A68
A137	GrupoCinco_E1 (sem relacionamento com o grupo), que apresenta a R737 presente no A17
A138	GrupoCinco_E1 (sem relacionamento com o grupo), que apresenta a R2886 presente no A76
A139	GrupoCinco_E1 (sem relacionamento com o grupo), que apresenta a R1975 presente no A51
A140	GrupoCinco_E1 (sem relacionamento com o grupo), que apresenta a R2853 presente no A74
A142	GrupoSeis_E1
A143	GrupoSeis_E1
A144	GrupoSeis_E1
A145	GrupoSeis_E1 (sem relacionamento com o grupo), que apresenta a R428 presente no A10

A146	GrupoSeis_E1
A147	GrupoSeis_E1
A148	GrupoSeis_E1 (sem relacionamento com o grupo), que apresenta a R205 presente no A5
A149	GrupoSeis_E1
A150	GrupoSeis_E1
A151	GrupoSeis_E1 (sem relacionamento com o grupo), que apresenta a R3533 e a R3543 presentes no A108
A152	GrupoSeis_E1 (sem relacionamento com o grupo), que apresenta a R253 presente no A5
A153	GrupoSeis_E1 (sem relacionamento com o grupo), que apresenta a R3043 presente no A84
A154	GrupoSeis_E1 (sem relacionamento com o grupo), que apresenta a R122 , que se repete 2 vezes no G7
A155	Referências em comum com o A184
A156	R3710, R3711, R3717 e R3726 em comum com o A118
A157	GrupoSeis_E1 (sem relacionamento com o grupo), que apresenta a R121 presente no A4
A158	GrupoSeis_E1 (sem relacionamento com o grupo), que apresenta a R3430 presente no A103
A159	GrupoSeis_E1 (sem relacionamento com o grupo)
A160	GrupoSeis_E1 (sem relacionamento com o grupo), que apresenta a R749 , que se repete 3 vezes no G4
A161	R749, que se repete 2 vezes no GrupoSeis_E1
A162	R749, que se repete 2 vezes no GrupoSeis_E1
A164	R248 presente no A5
A165	GrupoSete_E1 (sem relacionamento com o grupo)
A166	GrupoSete_E1
A167	GrupoSete_E1 (sem relacionamento com o grupo), que apresenta a R257, que se repete no A5
A168	R134, que se repete 3 vezes no GrupoDois_E1
A169	R257 presente no A5
A170	R167, que se repete 2 vezes no GrupoDois_E1
A171	GrupoSete_E1
A172	R121, que se repete 2 vezes no GrupoSeis_E1
A174	GrupoSete_E1
A175	R248 presente no A5
A176	Sem relacionamento com o grupo
A177	R4, que se repete 5 vezes no GrupoQuatro_E1
A179	R257 presente no A5
A180	GrupoSete_E1 (sem relacionamento com o grupo), que apresenta a R1611 , que se repete 2 vezes no G3
A181	GrupoSete_E1
A182	GrupoSete_E1
A184	Referências em comum com o A155
A185	R1720, que se repete 2 vezes no GrupoTres_E1
A186	R251, que se repete 2 vezes no GrupoCinco_E1
A187	R697 presente no A15
A188	R2144, que se repete 2 vezes no GrupoSete_E1

A189	R2521 presente no A65
A190	GrupoSete_E1
A192	R1401 presente no A36
A193	R704
A194	GrupoSete_E1
A196	GrupoSete_E1
A197	R704
A198	GrupoSete_E1 (sem relacionamento com o grupo), que apresenta a R3606 presente no A111
A200	GrupoSete_E1 (sem relacionamento com o grupo), que apresenta a R2555 , que se repete 2 vezes no GrupoTres_E1

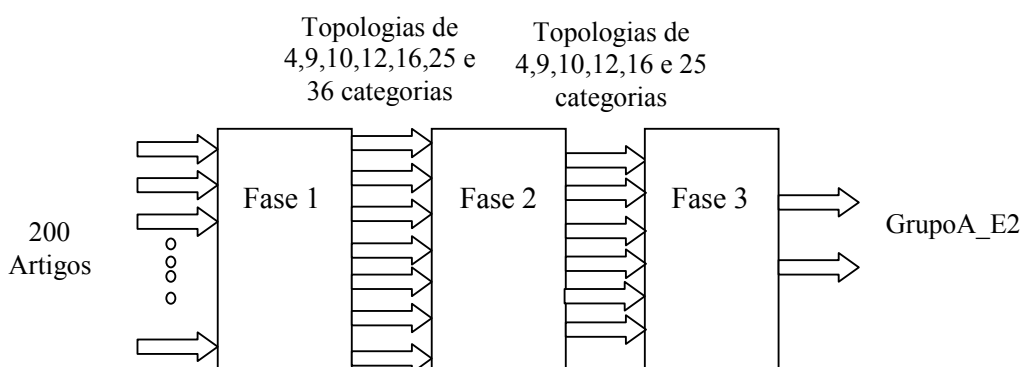
Dos 176 artigos avaliados, apenas seis artigos (A88, A91, A135, A159, A165 e A176) não tinham referência em comum com o grande grupo. Como este experimento apresentava o ano de publicação como atributo de categorização, este pode ter sido o atributo utilizado no agrupamento destes seis artigos. Os artigos A88 e A91, publicados em 2001, foram categorizados no GrupoQuatro_E1, onde 20 artigos também foram publicados em 2001. Todos os artigos do GrupoCinco_E1 foram publicados em 2003 e o artigo A135 pertencia a este grupo. Todos os artigos do GrupoSeis_E1 foram publicados em 2004, incluindo o artigo A159, que fazia parte deste grupo. O artigo A165 foi categorizado no GrupoSete_E1 e, neste grupo, todos os artigos foram publicados em 2006. O artigo A176 não pertencia a nenhum grupo do experimento 1, mas, foi publicado em 2005, juntamente com outros 13 artigos (A161, A169, A170, A172, A175, A179, A184, A185, A186, A187, A188, A189 e A192) agrupados neste grande grupo.

O experimento 2 gerou, em seis das sete topologias avaliadas, dois grupos principais de artigos. O grande grupo apresentava artigos sem um número significativo de referências em comum e era constituído de grupos do experimento 1 fracamente relacionados como mostrou a Tabela 41. O grupo pequeno, nomeado GrupoA_E2, formado pelo GrupoUm_E1 e outros artigos com um grande número de referências em comum, reforçou a existência de uma relação semântica forte entre os artigos que o integravam, já considerada na análise do GrupoUm_E1. Neste experimento, a RNA separou, no GrupoA_E2, artigos fortemente relacionados. No experimento 1, a grande influência do ano de publicação do artigo como atributo do processo de categorização distribuiu os artigos em um número maior de categorias.

A Figura 41 apresenta as fases do experimento 2. A primeira fase do experimento utilizou os dados relativos aos 200 artigos na entrada da RNA. A RNA gerou, como no

experimento 1, 7 resultados distintos. Cada uma delas gerava um número diferente de categorias, quais sejam 4, 9, 10, 12, 16, 25 e 36 categorias. Estas 7 topologias, caracterizadas por um número diferente de categorias geradas, foram analisadas na fase 2 do experimento, responsável pela definição das topologias que concentrassem a maioria dos artigos em um número semelhante de grupos. Como este experimento concentrou os artigos em dois grupos principais em seis das sete topologias, estas seis topologias foram selecionadas nesta fase. A fase 3 avaliou estas seis topologias, cada uma delas com seus dois grupos principais, identificou os artigos pertencentes ao grupo pequeno, denominado GrupoA_E2, e ao grande grupo e gerou a saída do experimento, utilizando os artigos que estavam presentes em mais de um grupo de cada uma das seis topologias.

Figura 41 - Fases do experimento 2



5.3. Apresentação e análise dos resultados do experimento 3

Este experimento não utilizou o ano como atributo para o processo de categorização. Os resultados encontrados nas 5 topologias selecionadas são apresentados na Tabela 42. Assim como na seção anterior, foram identificados um grupo grande de artigos e um grupo menor, estando os outros artigos distribuídos nas demais categorias. A topologia de 36 categorias não foi utilizada porque não houve a formação, no resultado apresentado pela RNA, do grupo menor, denominado, neste experimento, GrupoB_E3. Os grupos foram denominados, em cada uma das topologias, GrupoB_E3_4, GrupoB_E3_9, GrupoB_E3_10, GrupoB_E3_12 e GrupoB_E3_16 e GrupoB_E3_25.

Tabela 42 - Características do GrupoB_E3 em cada uma das topologias

GrupoB_E3	Número de artigos	Artigos														
		1	6	11	18	34	35	47	48	49	50	141	142	150	177	195
GrupoB_E3_4	8	1		11	18		35	47	48	49	50					
GrupoB_E3_9	10	1	6		18			47	48	49		141	142		177	195
GrupoB_E3_10	9	1	6		18			47	48	49	50	141				195
GrupoB_E3_12	12	1	6		18	34		47	48	49	50	141	142		177	195
GrupoB_E3_16	6	1			18			47	48	49	50					
GrupoB_E3_25	11		6		18			47	48	49	50	141	142	150	177	195

Foram selecionados para análise, assim como no experimento 2 apresentado na seção anterior, os artigos presentes em mais de uma topologia. Foram analisados, portanto, os artigos A1, A6, A18, A47, A48, A49, A50, A141, A142, A177 e A195. Foram encontrados onze artigos, como no experimento anterior, com a diferença de acréscimo dos artigos A142 e A177 e de exclusão dos artigos A11 e A35. As características dos dois artigos acrescentados neste teste são encontradas na Tabela 43.

Tabela 43 - Características dos artigos A142 e A177

Artigos	Referências	Ano/No. de referências	Palavras-chave	Autores
A142	R1,R5,R6,R44,R52,R283, R287,R288,R295,R297, R306,R307,R311,R432, R704,R762,R764,R774, R775,R3088,R3648,R3801, R4316,R4325	2004/24	Convergence and stability, neural network, nonlinear convex programming	Xing-Bao Gao
A177	R1,R4,R9,R23,R44,R52, R55,R63,R134,R287,R288, R301,R762,R1138,R1139, R1142,R1202,R1292,R1351, R1557,R1574,R1907,R2400, R2425,R3801,R4800,R5218, R5222,R5228,R5231,R5232, R5233,R5241,R5243,R5252	2005/35	Asymptotical stability, Lyapunov-Krasovskii functional, delayed neural networks, exponential stability, linear matrix inequality (LMI), quadratic programming	Qingshan Liu; Jinde Cao; Youshen Xia

Os artigos excluídos foram os artigos A11 e A35, ambos de 2010. Os artigos incluídos foram publicados em 2004 e em 2005 e têm um grande número de referências


comuns com o grupo, como mostrado nas próximas tabelas. O GrupoB_E3 tinha apenas um artigo de 2010, enquanto o GrupoA_E2 possuía 3 artigos. A utilização do ano como atributo do experimento 2 pode ter influenciado o agrupamento de mais dois artigos de 2010. O experimento 3, que só utiliza as referências como atributo, incluiu um artigo de 2005, que é um ano de publicação não encontrado nos artigos reunidos no GrupoA_E2. O artigo A142 tinha “*neural network*” como palavra-chave e o artigo A177 apresentou a palavra-chave “*quadratic programming*”. Estas palavras estavam presentes nos artigos do GrupoA_E2.

A Tabela 44 apresenta as referências que os dois artigos incluídos tinham em comum com os demais artigos do GrupoB_E3.

Tabela 44 - Referências comuns aos artigos A142, A177 e ao GrupoB_E3

Artigos	Número de Referências Comuns (Referências)
A142 e A1	3(R1,R5,R6)
A142 e A6	10(R1,R44,R283,R287,R288,R295,R297,R306,R307,R311)
A142 e A18	15(R1,R5,R6,R44,R283,R287,R295,R297,R307,R432,R704,R762,R764,R774,R775)
A142 e A47	4(R1,R5,R44,R295)
A142 e A48	3(R1,R5,R311)
A142 e A49	5(R6,R288,R311,R432,R762)
A142 e A50	4(R1,R5,R52,R295)
A142 e A141	7(R1,R5,R6,R44,R288,R432,R762)
A142 e A177	7(R1,R44,R52,R287,R288,R762,R3801)
A142 e A195	8(R1,R5,R6,R44,R52,R287,R295,R307)
A177 e A1	4(R1,R4,R9,R23)
A177 e A6	5(R1,R44,R287,R288,R301)
A177 e A18	7(R1,R4,R9,R44,R55,R287,R762)
A177 e A47	6(R1,R4,R9,R44,R134,R1351)
A177 e A48	7(R1,R4,R9,R55,R134,R1202,R1351)
A177 e A49	6(R4,R9,R288,R762,R1351,R1907)
A177 e A50	5(R1,R9,R52,R55,R1351)
A177 e A141	8(R1,R4,R9,R23,R44,R288,R762,R1351)
A177 e A195	6(R1,R4,R44,R52,R287,R1351)

A relação de referências comuns a cada dois artigos do GrupoB_E3 pode ser visualizada na Figura 42.

Figura 42 - Relação de referências comuns aos artigos do GrupoB_E3

A Tabela 45 mostra o número de vezes que as referências foram citadas pelos artigos do grupo.

Tabela 45 - Referências repetidas no GrupoB_E3

Número de vezes que as referências se repetem (Número de referências repetidas)	Referência (Artigos)
2(29)	R7(A1,A48),R10(A1,A18),R22(A1,A18),R41(A1,A18), R48(A6,A50),R285(A6,A141),R289(A6,A18), R292(A6,A49),R301(A6,A177),R304(A6,A18),R305(A6,A141), R306(A6,A142),R308(A6,A18),R704(18,142),R764(18,142), R774(18,142),R775(A18,A142),R1202(A48,A177),

	R1346(A50,A141),R1875(A49,A141),R1885(A49,A141), R1890(A49,A195),R1907(A49,A177),R3652(A141,A195), R3801(A142,A177),R4275(A141,A195),R4276(A141,A195), R4296(A141,A195),R4297(A141,A195)
3(18)	R11(A1,A18,A50),R15(A1,A18,A47),R21(A1,A6,A50), R23(A1,A141,A177),R25(A1,A6,A18),R28(A1,A6,A50), R30(A1,A18,A47),R32(A1,A18,A195),R34(A1,A6,A18), R50(A47,A50,A195),R53(A47,A50,A195),R55(A48,A50,A177), R134(A47,A48,A177),R283(A6,A18,A142),R297(A6,A18,A142), R439(A48,A49,A195),R802(A18,A48,A141), R1800(A47,A48,A195)
4(9)	R3(A1,A18,A47,A50),R16(A1,A6,A47,A50), R17(A1,A47,A49,A50),R33(A1,A6,A49,A50), R52(A50,A142,A177,A195),R307(A6,A18,A142,A195), R311(A6,A48,A49,A142),R432(A18,A49,A141,A142), R1843(A48,A49,A50,A141)
5(6)	R12(A1,A18,A47,A48,A50),R13(A1,A6,A18,A47,A49), R20(A1,A6,A18,A47,A50),R287(A6,A18,A142,A177,A195), R288(A6,A49,A141,A142,A177),R762(A18,A49,A141,A142,A177)
6(6)	R6(A1,A18,A49,A141,A142,A195), R18(A1,A18,A48,A49,A50,A195), R19(A1,A18,A47,A48,A49,A50),R24(A1,A6,A47,A48,A49,A50), R26(A1,A18,A47,A48,A49,A50), R295(A6,A18,A47,A50,A142,A195)
7(2)	R44(A6,A18,A47,A141,A142,A177,A195), R1351(A47,A48,A49,A50,A141,A177,A195)
8(3)	R4(A1,A18,A47,A48,A49,A141,A177,A195), R5(A1,A18,A47,A48,A50,A141,A142,A195), R9(A1,A18,A47,A48,A49,A50,A141,A177)
10(1)	R1(A1,A6,A18,A47,A48,A50,A141,A142,A177,A195)

Todos os artigos do GrupoB_E3 apresentavam referências em comum. Os artigos que não faziam parte do GrupoA_E2 (A142 e A177) mantiveram relação forte com o grupo de artigos, chegando a apresentar 15 referências em comum, como os artigos A18 e A142.

A Tabela 46 apresenta as características das 6 referências mais citadas no GrupoB_E3.

Tabela 46 - Características das referências mais citadas no GrupoB_E3

Referência	Número de citações	Título	Autores	Ano de publicação
R1	10	Nonlinear programming: Theory and Algorithms	M. S. Bazaraa, H. D. Sherali and C. M. Shetty	1993
R4	8	Simple neural optimization networks: An A/D converter, signal decision circuit and a linear programming circuit	D. W. Tank and J. Hopfield	1986
R5	9	Neural networks for nonlinear programming problems	M. P. Kennedy and L. O. Chua	1988
R9	8	A new neural network for solving linear and quadratic programming problems	Y. Xia	1996
R44	7	An Introduction to Variational Inequalities and Their Applications	D. Kinderlehrer and G. Stampcchia	1980
R1351	7	A projection neural network and its application to constrained optimization problems	Y. Xia, H. Leung and J. Wang	2002

As referências R1, R4 e R5 foram apresentadas como mais citadas no GrupoA_E2 e no GrupoB_E3. Duas das outras três referências mais citadas pelos 11 artigos do GrupoB_E3, as referências R9 e R1351, são de autoria de Youshen Xia, um dos autores do artigo A141. O outro autor do artigo A141 é Jun Wang, que, também, é autor da referência R1351 e dos artigos A47, A48, A50 e A195.

Das 6 referências mais citadas no GrupoB_E3, quatro (R1, R4, R5, R44) fazem parte do grupo das 16 referências mais citadas pelos 200 artigos apresentado na Figura 16.

A Tabela 47 relaciona todos os autores encontrados nos artigos do GrupoB_E3 aos seus respectivos artigos.

Tabela 47 - Relação entre os autores e os artigos do GrupoB_E3

Autores	Artigos (Ano de Publicação)
Bo Zhang	A1(2009)
Jinde Cao	A177(2005)
Jun Wang	A47(2008),A48(2008),A50(2007),A141(2004),A195(2006)
Li-Zhi Liao	A6(2009),A18(2010)
Maria P. Barbarosou	A49(2008)

Nicholas G. Maratos	A49(2008)
Qingshan Liu	A48(2008), A177(2005)
Xing-Bao Gao	A6(2009), A18(2010), A142(2004)
Xiaolin Hu	A1(2009), A47(2008),A50(2007),A195(2006)
Youshen Xia	A141(2004),A177(2005)

Em relação ao GrupoA_E2, observou-se que um autor é incluído, Jinde Cao, e um autor, Changyin Sun, excluído, como mostra o Quadro 9. O autor excluído é um dos autores dos artigos A11 e A35, que não faziam parte do GrupoB_E3, e o autor incluído é um dos autores do artigo A177 que, compunha o GrupoB_E3.

Quadro 9 - Comparação de autores do GrupoA_E2 e do GrupoB_E3

Autores	GrupoA_E2	GrupoB_E3
Bo Zhang	x	x
Changyin Sun	x	
Jinde Cao		x
Jun Wang	x	x
Li-Zhi Liao	x	x
Maria P. Barbarosou	x	x
Nicholas G. Maratos	x	x
Qingshan Liu	x	x
Xing-Bao Gao	x	x
Xiaolin Hu	x	x
Youshen Xia	x	x

Jinde Cao, um dos autores do artigo A177, integrante do GrupoB_E3, recebeu o grau de doutor em matemática e matemática aplicada pela *Sichuan University, Chengdu, China*, em 1998. Em 2005, ele trabalhava como pesquisador no Departamento de Matemática, na *City University of Hong Kong*, em Hong Kong, e como professor da *Southeast University*. Ele é autor ou coautor de mais de 100 artigos e cinco livros. Seus interesses de pesquisa incluem sistemas não lineares, redes neurais, sistemas complexos e redes complexas, teoria da estabilidade e matemática aplicada. Assim como os oito pesquisadores do GrupoA_E2, este pesquisador também trabalha na China.

Como os grupos GrupoA_E2 e GrupoB_E3 são semelhantes, os grandes grupos gerados e a distribuição dos artigos nas categorias dos dois experimentos também o são. A distribuição dos artigos em cada uma das topologias do experimento 3 está apresentada no Apêndice E. As fases apresentadas no experimento 2 também representam as fases do experimento 3.

5.4. Apresentação e análise dos resultados do experimento 4

Neste experimento, uma ferramenta de categorização que utiliza palavras-chave como atributo foi utilizada para categorizar os 200 artigos da base de dados. O *software* utilizado, cujo código é aberto, foi o Tanagra, que é uma ferramenta livre de exploração e análise de dados, desenvolvida para fins acadêmicos e de pesquisa. As palavras-chave dos artigos, selecionadas pelos próprios autores dos artigos, dispostas em ordem alfabética, foram apresentadas no Apêndice F, formando uma lista de 661 palavras-chave.

O arquivo utilizado na entrada do Tanagra possuía a informação da presença ou da ausência das 661 palavras-chave presentes nos 200 artigos. A Figura 43 apresenta uma visão parcial do arquivo de entrada do Tanagra. As linhas representam os artigos e as colunas representam as palavras-chave. Para cada artigo, além de seu número de identificação, existiam 661 dígitos (0 ou 1). A matriz era, portanto, formada por 200 linhas e 662 colunas. A primeira coluna representava o número de identificação do artigo e as 661 restantes apresentavam os dígitos 0 ou 1, identificando a ausência ou a presença, no artigo, da palavra chave representada pela coluna correspondente.

Figura 43 - Parte do arquivo de entrada da ferramenta Tanagra

			Palavra-chave 4												Palavra-chave 14			
01	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
02	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
03	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
⇒ 04	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	
05	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
06	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
07	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
08	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
09	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
10	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
11	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
12	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
13	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
14	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
16	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
17	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
⇒ 18	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
19	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	
20	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
21	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
22	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
23	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
24	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	

Fonte: VIANA, 2012

Nesta figura, podem ser vistas as primeiras 24 linhas e as primeiras 17 colunas do arquivo de entrada do *software*. Podem ser constatadas a presença ou a ausência das primeiras 16 palavras-chave dos primeiros 24 artigos utilizados. Foi possível identificar a presença da palavra-chave cadastrada com o número 14, “*almost periodic functions*”, no artigo A4 e da palavra-chave cadastrada com o número 4, “*adaptive equalizer*”, no artigo A19. Esta numeração foi apresentada no Apêndice F. O Quadro 10 reproduz as palavras-chave dos artigos A4 e A19 e destaca, em negrito, as identificadas na Figura 43.

Quadro 10 - Palavras-chave dos artigos 4 e 19

Artigo	Título	Palavras-chave
A4	Common Asymptotic Behavior of Solutions and Almost Periodicity for Discontinuous, Delayed, and Impulsive Neural Networks	Almost periodic functions , common asymptotic behavior, delays, discontinuous neural networks, global exponential stability, impulses
A19	Adaptively Combined FIR and Functional Link Artificial Neural Network Equalizer for Nonlinear Communication Channel	Adaptive equalizer , finite impulse response (FIR) filter, functional link artificial neural network (FLANN), nonlinear channel

No processo de categorização que utilizava o *software*, foram selecionadas topologias cujo número de grupos variava de 3 a 20. Na maioria das topologias, os artigos se concentraram em um único grupo. Foi selecionada para análise, a topologia onde eram formados 13 grupos. Nesta topologia, a maioria dos 200 artigos foi distribuída em quatro grupos, denominados GrupoC_E4, GrupoD_E4, GrupoE_E4 e GrupoF_E4. O Quadro 11 apresenta as características dos quatro grupos principais gerados e as palavras-chave que predominavam nos artigos agrupados em cada uma destas quatro categorias.

Quadro 11 - Características dos quatro grupos gerados na topologia de 13 categorias

Grupo	Número de artigos	Palavras-chave predominantes	Artigos
GrupoC_E4	141	Neural network	A1,A2,A4,A6,A7,A8,A9,A10,A12,A13,A14,A15,A16,A17,A18,A19,A20,A21,A22,A23,A24,A25,A26,A27,A29,A30,A31,A32,A34,A37,A39,A40,A41,A44,A51,

			A53,A54,A55,A58,A59,A60,A61,A62,A65,A66,A70,A71,A72,A74,A75,A76,A77,A78,A80,A82,A83,A84,A85,A86,A87,A88,A89,A91,A92,A93,A94,A95,A96,A97,A101,A103,A105,A109,A110,A111,A112,A113,A115,A116,A117,A118,A119,A120,A122,A123,A124,A125,A126,A128,A129,A130,A131,A132,A133,A134,A135,A136,A137,A138,A139,A140,A142,A143,A144,A145,A147,A148,A149,A150,A151,A152,A153,A154,A155,A156,A157,A158,A159,A160,A162,A163,A165,A166,A167,A168,A169,A170,A171,A173,A174,A175,A176,A177,A179,A183,A184,A185,A186,A187,A188,A189,A190,A191,A192,A193,A197,A198,A199,A200
GrupoD_E4	8	Global asymptotic stability	A43,A47,A98,A172,A181,A194,A195, A196
GrupoE_E4	35	Recurrent Neural Network	A28,A35,A36,A38,A45,A46,A48,A49,A50,A52,A56,A57,A63,A64,A67,A69,A79,A81,A90,A99,A100,A104,A106,A107,A108,A114,A121,A127,A141,A146,A161, A182
GrupoF_E4	7	Radial Basis Function Neural Network	A33,A42,A73,A102,A164,A178, A180

Tomando-se por base as palavras-chave identificadas como predominantes nos artigos agrupados, é possível afirmar que estas palavras nem sempre estavam presentes em todos os artigos. Existem palavras comuns entre os artigos que justificam a criação do grupo, mas, no caso do GrupoC_E4, que é o maior grupo gerado, a palavra que é apresentada com mais frequência não é comum a todos os artigos. Os números em negrito caracterizam os artigos nos quais as palavras-chaves identificadas como predominantes estavam presentes. Todos os artigos dos grupos GrupoD_E4 e GrupoF_E4 relacionavam as palavras-chaves predominantes em seu grupo. No caso do grupo GrupoE_E4, o artigo A121, integrante do grupo, não tinha a palavra-chave “*recurrent neural network*” definida como predominante. Para os 200 artigos selecionados para este trabalho, conclui-se que os grupos menores de artigos gerados neste experimento podem ser representados, em sua quase totalidade, por palavras-chave comuns a todos os artigos do grupo. Esta afirmativa não pode ser aplicada ao GrupoC_E4, onde menos de 50% dos artigos apresentava a palavra-chave definida como predominante.

O grupo GrupoC_E4 agrupava o maior número de artigos. Como um dos critérios utilizados para a composição da base de dados era a presença das palavras “neural network” nos títulos dos artigos, grande parte dos artigos apresentava a expressão como palavra-chave, o que justificava o maior número de artigos reunidos neste grupo. Apenas os artigos marcados em negrito tinham a expressão como palavra-chave. Os outros artigos do GrupoC_E4, de algum modo, se relacionaram aos artigos nos quais a expressão estava presente entre as palavras-chave. O artigo A2, por exemplo, possuía palavra-chave em comum com o artigo A1, “*asymptotical stability*”, e o artigo A1 possuía a palavra-chave que predominava no grupo. Deste modo, existia uma palavra-chave em comum entre estes artigos e os em negrito, explicando, assim, a criação do grupo.

Os artigos integrantes do GrupoA_E2 e do GrupoB_E3 não foram reunidos no mesmo grupo. Os artigos do GrupoA_E2 estavam divididos em 3 grupos. Os artigos A1, A6 e A18 estavam no grupo GrupoC_E4. Os artigos A47 e A195 estavam no grupo GrupoD_E4. Os artigos A35, A48, A49, A50 e A141 estavam no grupo GrupoE_E4. Os artigos A142 e A177, que fazem parte do GrupoB_E3, estavam no grupo GrupoC_E4. A divisão dos artigos em três grupos distintos mostra que os artigos presentes no GrupoA_E2 ou no GrupoB_E3 não seriam identificados como pertencentes ao mesmo grupo com a categorização que utilizava palavras-chave como atributo.

5.5. Comparação entre os experimentos

O primeiro experimento realizado pela RNA utilizou o ano de publicação dos artigos e as referências citadas pelos artigos como atributos de categorização. Na análise dos resultados, foi possível observar, na maioria dos grupos gerados, a grande influência do ano de publicação como atributo de categorização. Dos sete grupos gerados, apenas o grupo menor, denominado GrupoUm_E1, formado por seis artigos, era composto por trabalhos publicados em quatro diferentes anos. Os outros grupos concentravam, se não a totalidade, a quase totalidade dos artigos publicados em um único ano. Este pequeno grupo, além de ter sido pouco influenciado pelo ano de publicação em sua criação, foi o grupo que apresentou o maior número de referências em comum.

O segundo experimento representou o ano de publicação com valores significativamente menores, o que diminuiu a influência do ano como atributo de categorização, gerando um grande grupo e um pequeno grupo de documentos na saída da RNA. Na topologia que gerou 16 categorias, por exemplo, cujo grande grupo foi analisado,

detalhadamente, para justificar o agrupamento de seus artigos, o grande grupo continha 176 artigos, ou seja, 88% dos artigos, e o GrupoA_E2_16 continha 8 artigos, correspondendo a 4% dos artigos. Apenas estes 8 dos 200 artigos que compunham a base de documentos apresentavam um número grande de citações em comum que justificasse o seu agrupamento. O grande grupo concentrava artigos sem uma relação significativa de citações. Os 16 artigos restantes, perfazendo um percentual de 8%, estavam distribuídos nos 14 grupos restantes, caracterizando a inexistência de citações em comum com os outros grupos gerados. Pela análise dos resultados, foi possível perceber que os autores dos documentos que formavam o pequeno grupo gerado no experimento 2, nomeado GrupoA_E2, realizavam os seus trabalhos, referenciando um grande número de trabalhos comuns. O GrupoA_E2 era composto por onze artigos. Destes onze artigos, seis eram os artigos que compunham o GrupoUm_E1 do experimento 1.

Para verificar a influência do ano de publicação dos artigos no processo de categorização dos documentos, o terceiro experimento não utilizou o ano de publicação dos artigos como atributo de categorização. O resultado encontrado em muito se assemelhou ao resultado obtido no segundo experimento. Foi possível identificar um pequeno grupo, denominado GrupoB_E3, com a grande maioria de artigos igual ao pequeno grupo encontrado no segundo experimento. No GrupoB_E3, assim como no GrupoA_E2, formado por onze artigos, seis artigos eram os artigos que formavam o GrupoUm_E1. O GrupoB_E3 incluiu apenas um artigo de ano não encontrado nos artigos do GrupoA_E2, o que sugere a pouca influência do ano de publicação na categorização realizada pelo experimento 2. Os três experimentos reuniram, basicamente, os mesmos artigos fortemente relacionados por suas citações. Os experimentos 2 e 3 foram capazes de identificar um número maior de artigos relacionados por suas citações porque não sofriam a grande influência do ano de publicação, que caracterizava o experimento 1.

O quarto experimento realizado teve o propósito de comparar o processo de categorização que utiliza as referências citadas nos artigos com a categorização realizada por um algoritmo que utiliza as palavras-chave dos artigos como atributo. Como a escolha da base de dados deste trabalho restringiu o domínio da pesquisa, limitando a escolha dos artigos a aqueles que apresentassem a expressão “*neural network*” em seus títulos em um periódico especializado, o grande grupo encontrado, neste teste, apresentava esta expressão como palavra-chave predominante. Os outros grupos, significativamente menores, eram caracterizados por palavras-chave derivadas desta expressão principal. Os integrantes dos grupos GrupoA_E2 e GrupoB_E3 reuniam os artigos com o maior número de referências

comuns, fato comprovado nas análises dos experimentos 2 e 3, e estes artigos não faziam parte do mesmo grupo do experimento 4. O processo de categorização por palavras-chave mostrou-se, portanto, pouco eficiente para gerar grupos de artigos com um grande número de citações comuns em um domínio de conteúdo restrito. O experimento 4 não invalida os experimentos anteriores, mas, mostra que a categorização por palavras-chave deve ser usada com um propósito diferente do que foi proposto neste trabalho.

CAPÍTULO 6: CONCLUSÃO

A proposta deste trabalho foi categorizar documentos utilizando as referências dos artigos selecionados como atributos principais do mecanismo de agrupamento. O método apresentado utilizou uma rede SOM, tradicionalmente utilizada em processos de categorização de documentos, para reconhecer similaridades entre os documentos e, posteriormente, agregá-los em categorias.

Recuperar grupos de artigos que apresentam um grande número de referências em comum é uma garantia para o usuário de que as pesquisas desenvolvidas por estes autores apresentam uma aceitação e um reconhecimento de um grupo de pesquisadores que desenvolve trabalhos na área de conhecimento selecionada.

O objetivo geral do trabalho de verificar a viabilidade do uso de RNA para categorizar documentos, utilizando-se as referências bibliográficas foi alcançado. Os grupos identificados nos três experimentos, GrupoUm_E1, GrupoA_E2 e GrupoB_E3, apresentaram um grande número de referências em comum e a análise dos resultados evidenciou o forte relacionamento existente entre o grupo de autores destes artigos e a forte relação semântica entre os textos. Entre os 200 artigos utilizados no processo, foi possível identificar um grupo de artigos, na saída da RNA de cada um dos experimentos, com características similares associadas ao principal atributo empregado na categorização.

O protótipo proposto na apresentação dos objetivos específicos mostrou, no seu desenvolvimento, que o método de categorização, utilizando-se os *scripts* criados e a rede SOM, era passível de ser implementado. A base de 200 artigos criada foi pré-processada e organizada para que pudesse ser utilizada na entrada da rede SOM. Finalmente, o método de categorização proposto para a base de dados utilizada no trabalho foi comparado com o processo de categorização que utilizava um algoritmo de categorização. Tratando-se de um domínio específico, como o adotado neste trabalho, com muitas palavras-chave em comum, dificilmente, uma categorização que utilizasse palavras-chave poderia identificar este grupo de artigos encontrado nos experimentos 1, 2 e 3. O experimento 4 confirmou esta expectativa.

O acoplamento bibliográfico e a co-citação são exemplos de estudos que ressaltam a importância de se encontrar documentos que cite os mesmos trabalhos na pesquisa de grupos de artigos que apresentem um relacionamento que vai além da existência de um grande número de referências bibliográficas comuns. Guedes e Borschiver (2005), na avaliação dos estudos baseados na análise de citações, já evidenciavam a importância de se

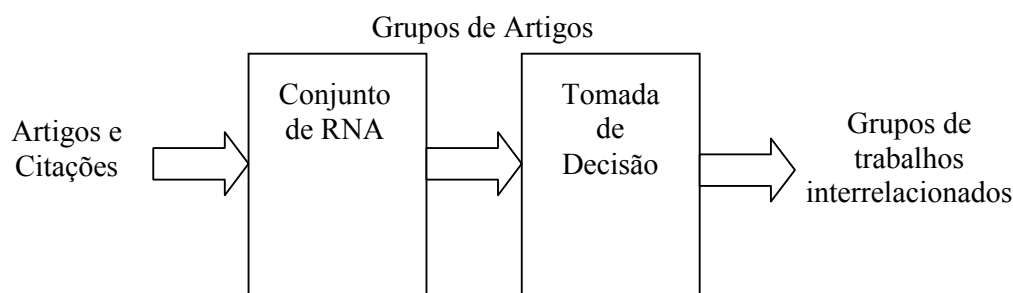
identificar a frente de pesquisa de uma determinada área científica, por meio de um conjunto de autores que se citam, revelando um estreito padrão de relações múltiplas. Neste pequeno grupo de artigos entrelaçados pelas referências bibliográficas que têm em comum, presente nos três experimentos, é possível identificar o trabalho de alguns colaboradores que formam o que a literatura define como os chamados Colégios Invisíveis.

A possibilidade de acesso ao grande volume de documentos eletronicamente disponível aumenta a qualidade das buscas bibliográficas, mas desafia o usuário a escolher aqueles que realmente atendem a sua necessidade. Avaliando-se grupos de artigos relacionados por suas referências, é possível, pela análise dos conteúdos dos artigos e das citações ao longo do tempo, verificar tendências de pesquisa na área de conhecimento que é objeto de estudo destes pesquisadores ou, ainda, constatar o desuso de um determinado tema abordado nesta linha de pesquisa. Esta é uma contribuição prática para o processo de recuperação de informação, que pode auxiliar o usuário na seleção dos documentos recuperados em um processo de busca.

Outra contribuição prática em se identificar grupos de artigos relacionados por suas referências diz respeito à utilização, pelo usuário, no auxílio à formulação ou à reformulação de uma consulta a uma base de dados. Esta contribuição seria particularmente útil nos casos em que o usuário tem apenas uma vaga ideia do conteúdo dos textos que estão sendo examinados. De posse de grupos de artigos com um grande número de referências em comum, as tendências, as dispersões e as relações semânticas identificadas poderiam ser úteis na elaboração da consulta. Como já destacado na introdução deste trabalho, o processo de recuperação de informação que utiliza as ferramentas de busca disponíveis exige do usuário habilidades cognitivas para organizar sua pesquisa. Este método de categorização, neste sentido, é uma proposta para minimizar as dificuldades não solucionadas pelas tecnologias de busca disponíveis.

Como contribuição metodológica, o trabalho propôs um método de análise dos dados gerados na saída da RNA, validado por um protótipo. Com a evolução dos experimentos, foi possível encontrar uma proposta de análise que contempla o objetivo proposto de agrupar artigos com forte relacionamento de citações. O método é ilustrado na Figura 44. A RNA recebe, na entrada, os dados relativos aos artigos e às citações destes artigos. Na saída da RNA, são gerados grupos de artigos categorizados, utilizando-se as referências citadas nos artigos como principal atributo de categorização. Os grupos alimentam o processo de tomada de decisão, cuja saída define os grupos de trabalhos fortemente relacionados por suas citações.

Figura 44 - Método de categorização utilizando RNA



O processo de tomada de decisão envolve a análise das referências citadas nos artigos agrupados. Como o processo, neste trabalho, foi executado manualmente, o tempo exigido para avaliar uma base de dados maior ou grupos maiores de artigos gerados na saída da RNA poderá inviabilizar o método. Automatizar as etapas que envolvem a análise dos grupos de artigos gerados na saída da RNA e que identificam os trabalhos interrelacionados por suas referências constitui uma necessidade ao se trabalhar com um número de artigos maior.

Como contribuições metodológicas, esta pesquisa reforçou a importância do uso de citações, destacada em estudos bibliométricos, e confirmou algumas das dificuldades encontradas nestes estudos durante a etapa de desenvolvimento da base de testes. O pré-processamento dos dados realizado para assegurar a identificação, pelo programa desenvolvido, de citações iguais citadas por autores diferentes, encontrou algumas limitações técnicas na base de dados. Estas limitações foram corrigidas para garantir a consistência do arquivo utilizado na entrada da RNA. Para que a RNA possa, no método apresentado, identificar grupos de artigos, é necessário que a base de dados contenha artigos cujos autores cite um número significativo de publicações em comum. A base de dados selecionada deve apresentar esta característica, constituindo-se, assim, em uma limitação para esse trabalho.

6.1. Propostas de trabalhos futuros

Para trabalhos posteriores, podem ser utilizadas bases de dados que contenham documentos com características distintas das que foram utilizadas neste trabalho. Poderão ser selecionadas amostras específicas de artigos, contendo um grande número de citações e um pequeno número de citações em comum para validar o método. O domínio de conhecimento pode, também, ser ampliado e ou alterado para que outras avaliações possam ser realizadas.

A proposta de tornar automático o processo de tomada de decisão, caracterizado na seção anterior, pode viabilizar a geração de grupos de artigos semanticamente relacionados utilizando-se bases de dados significativamente maiores. A escolha das topologias a serem trabalhadas e, dentro das topologias, a seleção dos grupos gerados pode ser um processo automático. Manualmente, foram analisadas as referências comuns a cada dois artigos dos grupos gerados, o número de vezes que as referências se repetem nos grupos, o número de referências que se repetem e os artigos que apresentam as referências repetidas. Estas análises podem ser executadas automaticamente por um *software* e, neste caso, a aplicação do método poderia ser ampliada para ser utilizada em grandes coleções de documentos.

Considerando-se a utilização do método na organização de grandes coleções de documentos, as inconsistências identificadas nos dados cadastrados poderiam ser avaliadas e corrigidas utilizando-se lógica *fuzzy*. Esta ferramenta de Inteligência Artificial permite que se converta relações gerais e imprecisas em variáveis linguísticas, que caracterizam a perspectiva humana de descrever um problema.

O método proposto pode ser comparado ao processo de categorização que utilize como atributo as palavras-chave dos trabalhos utilizados nas referências dos artigos. A partir de um experimento comparativo desta natureza, pode ser constatada ou não a formação de grupos semelhantes aos obtidos no processo de categorização proposto neste trabalho e observar como o método proposto pode se destacar dos métodos baseados em descritores.

6.2. Considerações Finais

O processo de categorização é um processo natural do ser humano, que busca, na criação de grupos, um modo de organizar as informações e simplificar suas interações com o mundo. Fazendo associações de tudo que lhe parece novo aos grupos de imagens e conceitos já estabelecidos, o indivíduo é capaz de reorganizar as estruturas já concebidas e entender com mais simplicidade o ambiente que o cerca.

A categorização facilita a armazenagem e a recuperação eficientes de informação e reduz as demandas por estoques cognitivos desnecessariamente mantidos na memória humana (JACOB, 2004). Sem a possibilidade de representar o mundo que o cerca, utilizando-se do processo de categorização, cada experiência vivenciada pelo ser humano necessitaria de um espaço único em sua memória.

O gigantismo das coleções de documentos criou a necessidade de organizá-las. Na tentativa de organizar estas coleções, muitos trabalhos discutem a categorização de artigos

utilizando palavras e contextos em que estas palavras estão inseridas. O método de categorização proposto é uma alternativa para subsidiar a organização e a busca de tais documentos no processo de recuperação de informação.

REFERÊNCIAS

ABADAL, Ernest; CODINA, Lluís. **Recuperación de Información**. Bases de Datos Documentales: Características, funciones y método. Capítulo 2. p. 29-92. Madrid: Síntesis, 2005.

ALVARENGA, Lídia. **Bibliometria e arqueologia do saber de Michel Foucault – traços de identidade teórico-metodológica**. Ciência da Informação, Brasília, v. 27, n. 3, set. 1998.

ALVARENGA, Lídia. **Citações como método de trabalho na bibliometria**: notas de aula da disciplina Análises no processo classificatório para Sistemas de Recuperação de Informação, PPGCI – UFMG, 24f, 2009.

ALVARENGA, Lídia. **Conexões com a “Realidade”- Linguagem, Classificação e Categorização**: notas de aula da disciplina Análises no processo classificatório para Sistemas de Recuperação de Informação, PPGCI – UFMG, 28f, 2009.

ARAÚJO, Vania Maria R. H. de. **Sistemas de informação: nova abordagem teórico-conceitual**. Ciência da Informação, v. 24, n. 1, p. 54-76, jan./abril 1995.

BAKUS, J.; HUSSIN, M. F.; KAMEL M. **A SOM-Based Document Clustering Using Phrases**. In: Proceedings of the 9th International Conference on Neural Information Processing, v. 5, nov. 2002.

BARITE, Mario Guido. **The Notion of “Category”: Its Implications in Subject Analysis and in the Construction and Evaluation of Indexing Languages**. Knowledge organization, v. 27, n.1/n.2, p. 4-10, 2000.

BASS, Bianca Laufer. **Plasticidade Neural**. Disponível em: <<http://br.geocities.com/fisioterapiabsb/artigos/e015.html>>. Acesso em: 18 out. 2009.

BELKIN, N. J.; ODDY, R. N.; BROOKS, H. M. **ASK for Information Retrieval: part I, background and theory**. The Journal of Documentation, v. 38, n. 2, p. 61-71, June 1982.

BICALHO, Lucinéia; OLIVEIRA, Marlene de. **A teoria e a prática da interdisciplinaridade em Ciência da Informação**. Perspectivas em Ciência da Informação, v. 16, n. 3, p. 47-74, jul./set. 2011.

BOISOT, Max; CANAIS, Agustí. **Data, information and Knowledge: have we got it right?** Trabalho aprovado para publicação em fevereiro de 2004 pelo Internet Interdisciplinary Institute. Disponível em: < <http://www.uoc.edu/in3/dt/20388/index.html>>. Acesso em: 14 fev. 2011.

BORGMAN, Christine L.; FURNER, Jonathan. **Scholarly Communication and Bibliometrics**. Annual Review of Information Science and Technology, v. 36, n. 1, p. 2-72, 2002.

BORKO, Harold. **Information Science: What Is It?** American Documentation, v. 19, p. 3-5, 1968.

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

BRAGA, Gilda Maria. **Relações bibliométricas entre a frente de pesquisa e revisões de literatura: estudo aplicado à Ciência da Informação**. Ciência da Informação, Rio de Janeiro, v. 2, n. 1, p. 9-26, 1973.

BROOKES, Bertram C. **The foundations of Information Science**. Journal of Information Science, v. 2, Part I (p. 125-133), Part II (p. 209-221), Part III (p. 269-275), and v. 3, Part IV (p. 3-12), 1980/1981.

CAPUANO, Ethel A. **O poder cognitivo das redes neurais artificiais modelo ART1 na recuperação de informação**. Ciência da Informação, Brasília, v. 38, n. 1, p. 9-30, jan./abr. 2009.

CHEN, Hsinchun. **Machine Learning for Information Retrieval: Neural Networks, Symbolic Learning and Genetic Algorithms**. Journal of the American Society for Information Science, v. 46, n. 3, p. 194-216, abr. 1995.

CRONIN, Blaise. **The citation process**. London: Taylor Graham, 1984, 103 p.

DURÃES, Rodrigo Leite. **Validação de Modelos Baseados em RNA Utilizando Análise Estatística de Dados e Lógica Fuzzy**. 2009. 123f. Dissertação (Mestrado em Modelagem Matemática e Computacional) - Centro Federal de Educação Tecnológica de Minas Gerais. Belo Horizonte.

ELLIS, David. **Progress and Problems in Information Retrieval**. 2. ed. Londres: Library Association Publishing, 1996.

FERNEDA, Edberto. **Redes neurais e sua aplicação em sistemas de recuperação de informação**. *Ciência da Informação*, Brasília, v. 35, n. 1, p. 25-30, jan./abr. 2006.

FRANCESCHET, Massimo. **A comparison of bibliometric indicators for computer science scholars and journals on Web of Science and Google Scholar**. *Scientometrics*, v. 83, n. 1, p. 243-258, abr. 2010.

GUEDES, Vânia L. S.; BORSCHIVER, Suzana. **Bibliometria: uma ferramenta estatística para a Gestão da informação e do conhecimento, em Sistemas de informação, de comunicação e de avaliação científica e tecnológica**. In: *Proceedings CINFORM – Encontro Nacional de Ciência da Informação VI*, Salvador, Bahia, 2005.

GUIMARÃES ROSA, João. **Grande Sertão: veredas**. Rio de Janeiro: Nova Fronteira, 1986.

GOMES, Henriette F. **Interdisciplinaridade e Ciência da Informação: de característica a critério delineador de seu núcleo principal**. *DataGramZero – Revista de Ciência da Informação*, v. 2, n. 4, ago. 2001.

HE, Yulan; HUI, Siu Cheung. **PubSearch: a Web citation-based retrieval system**. *Library Hi Tech*, v. 19, n. 3, p. 274-285, 2001.

HAYKIN, Simon. **Neural Networks: a comprehensive foundation**. New Jersey: Prentice Hall, 1994.

HUSSIN, M. F.; KAMEL, M. **Document Clustering using Hierarchical SOMART Neural Network**. In: Proceedings of the International Joint Conference on Neural Networks, v. 3, 2003.

JACOB, Elin. **Classification and categorization: a difference that makes a difference**. Library trends, v. 52, n. 3, p. 515-540, 2004.

KOHONEN, Teuvo et al. **Self Organization of a Massive Document Collection**. IEEE Transactions on Neural Networks, v. 11, n. 3, maio 2000.

KURAMOTO, Hélio. **Uma abordagem alternativa para o tratamento e a recuperação de informação textual: os sintagmas nominais**. Ciência da Informação, v. 25, n. 2, maio/ago., p. 182-192, 1996.

KURAMOTO, Hélio. **Sintagmas nominais: uma nova proposta para a Recuperação da Informação**. DataGramZero, v. 3, n. 1, fev. 2002.

LANCASTER, F. Wilfrid; WARNER, Amy J. **Information Retrieval Today**. Arlington, VA: Information Resources Press, 1993.

LEAL, Igor Campos. **Análise de citações da produção científica de uma comunidade: a construção de uma ferramenta e sua aplicação em um acervo de teses e dissertações do PPGCI - UFMG**. 2005. 94f. Dissertação (Mestrado em Ciência da Informação) – Universidade Federal de Minas Gerais. Belo Horizonte.

LE COADIC, Yves François. **A ciência da informação**. Tradução de Maria Yêda F. S. de Filgueiras Gomes. Brasília, DF: Briquet de Lemos/Livros, 1996, 115p.

LENSU, Anssi; KOIKKALAINEN, Pasi. **Similar Document Detection using Self-Organizing Maps**. In: Third International Conference on Knowledge-Based Intelligent Information Engineering Systems, Adelaide, Australia, 1999.

LIMA, Gercina A. B. de Oliveira. **O Modelo Simplificado para Análise Facetada de Spiteri a partir de Ranganathan e do *Classification Research Group***. *Información, Cultura y Sociedad*, no. 11, p. 57-72, 2004.

LIMA, Gercina A. B. de Oliveira. **Modelos de categorização: apresentando o modelo clássico e o modelo de protótipos**. *Perspectivas em Ciência da Informação*, v. 15, n. 2, p. 108-122, maio/ago. 2010.

LIN, Xia; SOERGEL, Dagobert; MARCHIONINI, Gary. **A Self-organizing Semantic Map for Information Retrieval**. In: 14th Annual International ACM SIGIR Conference on Research and Development in Information Retrieval Association for Computing Machinery, 1991.

LUO, X.; ZINCIR-HEYWOOD, A. Nur. **A Comparison of SOM Based Document Categorization Systems**. In: Proceedings of the International Joint Conference on Neural Networks, v. 3, 2003.

MACIAS-CHAPULA, Cesar A. **O papel da informetria e da cienciometria e sua perspectiva nacional e internacional**. *Ciência da Informação*, Brasília, v. 27, n. 2, 1998.

MAC ROBERTS, Michael H.; MAC ROBERTS, Barbara R. **Problems of citation analysis: a critical review**. *Journal of the American Society for Information Science*, v. 40, n. 5, p. 342-349, 1989.

MACULAN, B. C. M. S. **Manual de normalização: padronização de documentos acadêmicos do NITEG/UFMG e do PPGCI/UFMG**. 2. ed. atual. e rev. Belo Horizonte: UFMG, 2011. 49p. Apostila. Disponível em: <<http://www.eci.ufmg.br/normalizacao>>. Acesso em: 4 dez. 2011.

MCGARRY, Kevin. **O contexto dinâmico da informação: uma análise introdutória**. Tradução de Helena Vilar de Lemos, Brasília, DF: Briquet de Lemos/Livros, 1999, 200p.

MEIRELES, Magali Rezende Gouvêa; ALMEIDA, Paulo Eduardo Maciel; SIMÕES, Marcelo Godoy. **A Comprehensive Review for Industrial Applicability of Artificial**

Neural Networks. IEEE Transactions on Industrial Electronics. EUA, v. 50, n. 3, p. 1-18, 2003.

MEIRELES, Magali Rezende Gouvêa ; CENDÓN, Beatriz Valadares. **Categorização e Classificação de documentos a partir de suas citações: uma proposta baseada em Redes Neurais Artificiais.** DataGramZero (Rio de Janeiro), v. 12, p. 2, 2011.

MEIRELES, Magali Rezende Gouvêa; CENDÓN, Beatriz Valadares. **Citation-Based Document Categorization: an approach using Artificial Neural Networks.** In: 4th Qualitative and Quantitative Methods in Libraries, Limerick, Ireland, May, 2012.

MORRIS, S. A.; WU, Z.; YEN, G. **A SOM Mapping Technique for Visualizing Documents in a Database.** In: Proceedings International Joint Conferences on Neural Networks, v. 3, 2001.

NICOLELIS, Miguel. **Muito além do nosso eu: a nova neurociência que une cérebros e máquinas e como ela pode mudar nossas vidas.** Tradução do autor: revisão Giselda Laporta Nicolelis, São Paulo: Companhia das Letras, 2011.

PEREIRA, Frederico Cesar Mafra. **A Equação Fundamental da Ciência da Informação de Brookes e sua importância para o campo da Ciência da Informação.** Informação & Informação, Londrina, v. 13, n. 1, p. 15-31, jan./jun. 2008.

PEREIRA, Júlio César Rodrigues. **Análise de Dados Qualitativos: Estratégias Metodológicas para as Ciências da Saúde, Humanas e Sociais.** 3. ed. São Paulo: Edusp, 2001.

PIEIDADE, Maria Antonieta R. **Introdução à teoria da classificação.** 2. ed. Rio de Janeiro: Interciência, 1983.

PINHEIRO, Lena Vania Ribeiro. **Ciência da Informação: desdobramentos disciplinares, interdisciplinaridade e transdisciplinaridade.** 2006.

PINHEIRO, Lena Vania Ribeiro; LOUREIRO, José Mauro Matheus. **Traçados e limites da ciência da informação**. *Ciência da Informação*, v. 24, n. 1, 1995.

PINTO, Angelo C.; ANDRADE, Jailson B. de. **Fator de Impacto de Revistas Científicas: Qual o significado deste parâmetro?** *Química Nova*, v. 22, 1999.

POMBO, O. **Epistemologia da interdisciplinaridade**. In: Pombo, O. *Interdisciplinaridade, humanismo, universidade*. Porto: Campo das Letras, 2004.

PHUC, Do; HUNG, Mai Xuan. **Using SOM based Graph Clustering for Extracting Main Ideas from Documents**. In: IEEE International Conference on Research, Innovation and Vision for the Future, 2008.

PONTIFÍCIA UNIVERSIDADE CATÓLICA DE MINAS GERAIS. Pró-Reitoria de Graduação. Sistema de Bibliotecas. **Padrão PUC Minas de normalização**: normas da ABNT para apresentação de teses, dissertações, monografias e trabalhos acadêmicos. 9. ed. rev. ampl. atual. Belo Horizonte: PUC Minas, 2011. Disponível em: <<http://www.pucminas.br/biblioteca>>. Acesso em: 4 dez. 2011.

REZENDE, Solange Oliveira. **Sistemas Inteligentes: fundamentos e aplicações**. Barueri, SP: Manole, 2003.

ROJAS, Miguel Ángel Rendón. **Relación entre los conceptos: información, conocimiento y valor. Semejanzas y diferencias**. *Ciência da Informação*, v. 34, n. 2, p. 52-61, maio/ago. 2005.

ROSCH, Eleanor et al. **Principles of Categorization**. In: Rosch, Eleanor; Lloyd, Barbara B. (eds). *Cognition and categorization*. Hillsdale, N. J.: Lawrence Erlbaum, 1978.

SANTOS, Boaventura de Souza. **Um discurso sobre as ciências**. São Paulo: Cortez, 2003.

SARACEVIC, Tefko. **Ciência da Informação: origem, evolução e relações**. *Perspectivas em Ciência da Informação*, v. 1, n. 1, p. 41-62, jan./jun. 1996.

SEARLE, John R. **Mente, Cérebro e Ciência**. Lisboa: Edições 70, 1984.

SENGUPTA, I. N. **Bibliometrics, Informetrics, Scientometrics and Librametrics: An Overview**. Libri, v. 42, n. 2, p. 75-98, 1992.

SETZER, Valdemar W. **Dado, Informação, Conhecimento e Competência**. In: Os Meios Eletrônicos e a Educação: Uma Visão alternativa. São Paulo: Escrituras, Coleção Ensaio Transversais, v. 10, 2001.

SHANNON, Claude E. **A Mathematical Theory of Communication**. The Bell System Technical Journal, v. 27, pp. 379-423, 623-656, July, October, 1948.

SHARMA, Anil K. et al. **Classification and Clustering: Using Neural Networks**. Journal of Chemical Information and Computer Sciences, v. 34, pp. 1130-1139, 1994.

SILVA, Maurício Marx et al. **A consciência: algumas concepções atuais sobre sua natureza, função e base neuroanatômica**. R. Psiquiatr. RS, 25 (suplemento 1), p. 52-64, abril 2003.

SOUZA, Renato Rocha. **Sistemas de Recuperação de Informações e Mecanismos de Busca na web: panorama atual e tendências**. Perspectivas em ciência da informação, Belo Horizonte, v. 11, n. 2, p. 161-173, mai./ago. 2006.

STAFYLOPATIS, Andreas; LIKAS, Aristidis. **Pictorial Information Retrieval Using the Random Neural Network**. IEEE Transactions on Software Engineering, v. 18, n. 7, July, 1992.

TURBAN, Efraim; RAINER JR., R. Kelly; POTTER, Richard E. **Introdução a sistemas de informação**, Rio de Janeiro: Elsevier, 2007.

VIANA, Rita Diniz. **Aplicação das ferramentas Weka e Tanagra para a categorização de artigos a partir de suas palavras-chave**. 2012. 57f. Monografia (Conclusão do curso) – Pontifícia Universidade Católica de Minas Gerais, Curso Sistemas de Informação, Belo Horizonte.

WANG, Wei; YU, Bo. **Text categorization based on combination of modified back propagation neural network and latent semantic analysis**. *Neural Computing & Applications*, v. 18, n. 8, p. 875-881, 2008.

XAVIER, Beatriz Rêgo. **As categorias de Aristóteles e o conhecimento científico**. *Pensar, Fortaleza*, v. 13, n. 1, p. 57-64, jan./jun. 2008.

YEN, Gary G.; WU, Zheng. **A Self-Organizing Map Based Approach for Document Clustering and Visualization**. In: *International Joint Conference on Neural Networks*. Vancouver, Canada, July, 2006.

YU, Yan et al. **A Document Clustering Method Based on Once-Dimensional SOM**. In: *Seventh IEEE/ACIS International Conference on Computer and Information Science*. 2008

APÊNDICE A - PROGRAMAÇÃO DO MATLAB E RESULTADOS OBTIDOS PARA O PROTÓTIPO

```

%Criação e plotagem dos dados de entrada
A=[2002 (1+2^2+2^4+2^6+2^8+2^10+2^12+2^14+2^16+2^18+2^34+2^49+2^63);2003
(1+2^2+2^4+2^14+2^16+2^18+2^34+2^49+2^63);2003
(2^4+2^6+2^8+2^10+2^12+2^14+2^34+2^49+2^63);2005
(2+2^20+2^28+2^38+2^51+2^52+2^53+2^54+2^56+2^60+2^61+2^62);2006
(2+2^4+2^9+2^20+2^28+2^31+2^38+2^46+2^60+2^61+2^62);2006
(2+2^20+2^28+2^38+2^43+2^50+2^54+2^57+2^60+2^61+2^62);2007
(2^7+2^15+2^21+2^22+2^29+2^34+2^39+2^40+2^41+2^48+2^58);2008
(2^7+2^15+2^21+2^22+2^29+2^35+2^39+2^44+2^45+2^47+2^55);2006
(2^7+2^13+2^15+2^21+2^22+2^23+2^24+2^25+2^29+2^35+2^39+2^45);2005
(2^3+2^11+2^17+2^19+2^26+2^27+2^30+2^32+2^33+2^36+2^37+2^42+2^45+2^59+2^62+
2^63)];
limites=[2000 2010;0 2^64-1];

%Criação de uma rede SOM armazenada na variável net
net=newsom(limites,[2,3],'GRIDTOP');
plotsom(net.iw{1,1},net.layers{1}.distances);

%pause;

%Treinamento da rede
net.trainParam.epochs=100;
net.trainParam.show=20;
net=train(net,A');
plotsom(net.iw{1,1},net.layers{1}.distances);

%pause;

%Identificação dos pontos categorizados
c=zeros(6,10);
for i=1:10,
    c(:,i)=sim(net,A(i,:));
end;
c

```

TRAINR, Epoch 0/100
TRAINR, Epoch 20/100
TRAINR, Epoch 40/100
TRAINR, Epoch 60/100
TRAINR, Epoch 80/100
TRAINR, Epoch 100/100
TRAINR, Maximum epoch reached.

```
c =  0  0  0  0  0  0  1  1  1  0
      0  0  0  0  0  0  0  0  0  0
      0  0  0  0  0  0  0  0  0  0
      0  0  0  0  0  0  0  0  0  1
      0  0  0  1  1  1  0  0  0  0
      1  1  1  0  0  0  0  0  0  0
```


APÊNDICE C - TABELA DE ARTIGOS

Artigo	Título	Ano de Publicação	Número de Referências	Autores	Palavras-chave
A1	A New Recurrent Neural Network for Solving Convex Quadratic Programming Problems With an Application to the k-Winners-Take-All Problem	2009	43	Xiaolin Hu; Bo Zhang;	Asymptotic stability, k-winners-take-all (WTA), linear programming, neural network, quadratic programming
A2	A Delayed Projection Neural Network for Solving Linear Variational Inequalities	2009	28	Long Cheng; Zeng-Guang Hou; Min Tan;	Asymptotical stability, delayed neural networks, exponential stability, linear matrix inequality (LMI), Lyapunov–Krasovskii functional, quadratic programming
A3	A Novel Recurrent Neural Network With One Neuron and Finite-Time Convergence for k-Winners-Take-All Operation	2010	38	Qingshan Liu; Chuangyin Dang; Jinde Cao;	Global convergence in finite time, k-winners-take-all operation, Lyapunov function, recurrent neural network
A4	Common Asymptotic Behavior of Solutions and Almost Periodicity for Discontinuous, Delayed, and Impulsive Neural Networks	2010	77	Allegretto, W.; Papini, D.; Forti, M.;	Almost periodic functions, common asymptotic behavior, delays, discontinuous neural networks, global exponential stability, impulses
A5	The Graph Neural Network Model	2009	96	Scarselli, F.; Gori, M.; Ah Chung	Graphical domains, graph neural networks (GNNs), graph processing, recursive neural networks

				Tsoi; Hagenbuch ner, M.; Monfardini, G.;	
A6	A New Projection- Based Neural Network for Constrained Variational Inequalities	2009	29	Xing-Bao Gao; Li-Zhi Liao;	Convergence, neural network, stability, variational inequality
A7	Permitted and Forbidden Sets in Discrete-Time Linear Threshold Recurrent Neural Networks	2009	28	Zhang Yi; Lei Zhang; Jiali Yu; Kok Kiong Tan;	Complete convergence, discrete-time recurrent neural networks, forbidden set, linear threshold, multiattractivity, permitted set
A8	Large Memory Capacity in Chaotic Artificial Neural Networks: A View of the Anti-Integrable Limit	2009	61	Wei Lin; Guanrong Chen;	Anti-integrable limit, artificial neural network, chaos, periodic activation function
A9	Neural Network Learning without Backpropagation	2010	27	Wilamowsk i, B.M.; Hao Yu;	Forward-only computation, Levenberg– Marquardt algorithm, neural network training
A10	Subgradient-Based Neural Networks for Nonsmooth Nonconvex Optimization Problems	2009	29	Wei Bian; Xiaoping Xue;	Convergence in finite time, differential inclusion, neural network, nonsmooth nonconvex optimization, slowsolution
A11	Design of Recurrent Neural Networks for Solving Constrained Least Absolute Deviation Problems	2010	39	Xiaolin Hu; Changyin Sun; Bo Zhang;	L1-norm optimization, least absolute deviation(LAD), minimax optimization, recurrent neural network (RNN), stability analysis

A12	A Recurrent Neural-Network-Based Sensor and Actuator Fault Detection and Isolation for Nonlinear Systems With Application to the Satellite's Attitude Control subsystem	2009	31	Talebi, H.A.; Khorasani, K.; Tafazoli, S.;	Attitude control subsystem (ACS), dynamic neural networks, fault detection and isolation (FDI), nonlinear systems
A13	Real-Time Robot Path Planning Based on a Modified Pulse-Coupled Neural Network Model	2009	67	Hong Qu; Yang, S.X.; Willms, A.R.; Zhang Yi;	Collision avoidance, mobile robot, neural dynamics, path planning, pulse-coupled neural networks (PCNNs), spiking, wave
A14	A Neural Network Model to Minimize the Connected Dominating Set for Self-Configuration of Wireless Sensor Networks	2009	45	Hongmei He; Zhenhuan Zhu; Makinen, E.;	Connected dominating set (CDS), directed convergence, neural networks, transmission radius, wireless sensor networks
A15	Robust Neural Network Motion Tracking Control of Piezoelectric Actuation Systems for Micro/Nanomanipulation	2009	75	Hwee Choo Liaw; Shirinzadeh, B.; Smith, J.;	Function approximations, micro/nanomanipulation, neural network control, piezoelectric actuator, robust control
A16	Exceptional Reducibility of Complex-Valued Neural Networks	2010	16	Kobayashi, M.;	Complex-valued neural networks, minimality, reducibility, rotation-equivalence
A17	Dynamic Analysis of a General Class of Winner-Take-All Competitive Neural Networks	2010	30	Yuguang Fang; Cohen, M.A.; Kincaid,	Competition, convergence analysis, lateral inhibition, neural networks, neurodynamics, shunting and additive, very large

				T.G.;	scale integration (VLSI) neural networks, winner- take-all(WTA)
A18	A New One-Layer Neural Network for Linear and Quadratic Programming	2010	47	Xingbao Gao; Li-Zhi Liao;	Convergence, linear and quadratic programming, neural network, stability
A19	Adaptively Combined FIR and Functional Link Artificial Neural Network Equalizer for Nonlinear Communication Channel	2009	32	Haiquan Zhao; Jiashu Zhang;	Adaptive equalizer, finite impulse response (FIR)filter, functional link artificial neural network (FLANN), nonlinear channel
A20	Partial Logistic Artificial Neural Network for Competing Risks Regularized With Automatic Relevance Determination	2009	37	Lisboa, P.J.G.; Etchells, T.A.; Jarman, I.H.; Arsene, C.T.C.; Aung, M.S.H.; Eleuteri, A.; Taktak, A.F.G.; Ambrogi, F.; Boracchi, P.; Biganzoli, E.;	Censorship, prognostic modeling, risk analysis, survival modeling, time- to-event data
A21	Artificial Neural Network Method for Solution of Boundary Value Problems With Exact Satisfaction of Arbitrary Boundary	2009	20	McFall, K.S.; Mahan, J.R.;	Boundary value problems (BVPs), finite-element method, irregular boundaries, length factor, mixed boundary conditions

	Conditions				
A22	Simple Artificial Neural Networks That Match Probability and Exploit and Explore When Confronting a Multiarmed Bandit	2009	39	Dawson, M.; Dupuis, B.; Spetch, M.L.; Kelly, D.M.;	Instrumental learning, multiarmed bandit, operant conditioning, perceptron, probability matching
A23	R-POPTVR: A Novel Reinforcement-Based POPTVR Fuzzy Neural Network for Pattern Classification	2009	39	Wing-Cheong Wong; Siu-Yeung Cho; Chai Quek;	Clustering methods, fuzzy neural networks (FNNs), pattern classification, reinforcement learning
A24	Adaptive Statistic Tracking Control Based on Two-Step Neural Networks With Time Delays	2009	34	Yang Yi; Lei Guo; Hong Wang;	B-spline neural network, dynamic neural net-work (DNN), non-Gaussian systems, probability density functions(pdf), statistic tracking control (STC), variable structure control
A25	Regularized Negative Correlation Learning for Neural Network Ensembles	2009	39	Huanhuan Chen; Xin Yao;	Ensembles, negative correlation learning (NCL), neural network ensembles, neural networks, probabilistic model, regularization
A26	Large-Scale Pattern Storage and Retrieval Using Generalized Brain-State-in-a-Box Neural Networks	2010	37	Cheolhwan Oh; Zak, S.H.;	Associative memory, Brain-State-in-a-Box (BSB), image storage and retrieval, neural networks, pattern decomposition, pattern sequence storage and retrieval
A27	Novel Hysteretic Noisy Chaotic Neural Network for Broadcast Scheduling Problems in Packet	2010	42	Ming Sun; Lin Zhao; Wei Cao; Yaoqun Xu; Xuefeng	Broadcast scheduling problems, hysteretic, noisy chaotic neural network, packet radio network

	Radio Networks			Dai, Xiaoxu Wang;	
A28	Almost Sure Exponential Stability of Recurrent Neural Networks With Markovian Switching	2009	45	Yi Shen; Jun Wang;	Almost sure exponential stability, Halanay in- equality, Markov chain, recurrent neural networks, time-varying delay
A29	Identifying the Topology of a Coupled FitzHugh– Nagumo Neurobiological Network via a Pinning Mechanism	2009	40	Jin Zhou; Wenwu Yu; Xiumin Li; Small, M.; Jun-an Lu;	Complex network, neural network, pinning, topology identification, weight couplings
A30	Exceptional Reducibility of Complex-Valued Neural Networks	2010	16	Kobayashi, M.;	Complex-valued neural networks, minimality, reducibility, rotation- equivalence
A31	Novel Maximum- Margin Training Algorithms for Supervised Neural Networks	2010	27	Ludwig, O.; Nunes, U.;	Information theory, maximal-margin (MM) principle, multilayer perceptron (MLP), pattern recognition, supervised learning
A32	LMI Approach for Stationary Oscillation of Interval Neural Networks With Discrete and Distributed Time- Varying Delays Under Impulsive Perturbations	2010	42	Xiaodi Li; Jianhua Shen;	Differential inequality, discrete time-varying delays, distributed time- varying delays, impulsive delay, impulsive perturbations interval neural networks, linear matrix inequality, stationary oscillation
A33	File Access Prediction Using Neural Networks	2010	36	Patra, P.K.; Sahu, M.; Mohapatra, S.; Samantray, R.K.;	Competitive predictor, file prediction, Levenberg– Marquardt (LM) backpropagation, multilayer perceptron (MLP), probabilistic predictor, radial basis

					function (RBF) network, success rate
A34	A Discrete-Time Neural Network for Optimization Problems With Hybrid Constraints	2010	23	Huajin Tang; Haizhou Li; Zhang Yi;	Discrete-time neural networks, global exponential stability, hybrid constraints, linear variational inequality, quadratic optimization
A35	Design of Recurrent Neural Networks for Solving Constrained Least Absolute Deviation Problems	2010	39	Xiaolin Hu; Changyin Sun; Bo Zhang;	L1-norm optimization, least absolute deviation (LAD), minimax optimization, recurrent neural network (RNN), stability analysis
A36	Identification of Finite State Automata With a Class of Recurrent Neural Networks	2010	39	Sung Hwan Won; Lickho Song; Sun Young Lee; Cheol Hoon Park;	Cost function, finite state automaton (FSA), hybrid greedy simulated annealing (HGSA), recurrent neural network (RNN), system identification
A37	Adaptive Tracking for Periodically Time-Varying and Nonlinearly Parameterized Systems Using Multilayer Neural Networks	2010	20	Weisheng Chen; Licheng Jiao;	Backstepping, dynamic surface control (DSC), Fourier series expansion (FSE), integral-type Lyapunov function (ILF), multilayer neural network (MNN), nonlinearly parameterized systems, periodically time-varying disturbances
A38	Recursive Bayesian Recurrent Neural Networks for Time-Series Modeling	2010	47	Mirikitani, D.T.; Nikolaev, N.;	Bayesian regularization, recurrent neural network (RNN), sequential Levenberg–Marquardt
A39	Impulsive Control and Synchronization for Delayed Neural Networks With Reaction–Diffusion	2010	30	Cheng Hu; Haijun Jiang; Zhidong Teng;	Delays, exponential stability, impulsive control, impulsive synchronization, neural network, reaction–

	Terms				diffusion
A40	Improved Delay-Dependent Stability Condition of Discrete Recurrent Neural Networks With Time-Varying Delays	2010	21	Zhengguan g Wu; Hongye Su; Jian Chu; Wuneng Zhou;	Delay dependent, exponential stability, linear matrix inequality (LMI), neural networks, time-varying delays
A41	Robust Stability Analysis for Interval Cohen–Grossberg Neural Networks With Unknown Time-Varying Delays	2008	48	Huaguang Zhang; Zhanshan Wang; Derong Liu;	Matrix , Cohen–Grossberg neural networks, Halanay inequality, interval neural networks, linear matrix inequality (LMI), robust stability, time-varying delays
A42	Wavelet Basis Function Neural Networks for Sequential Learning	2008	21	Ning Jin; Derong Liu;	Radial basis function neural network (RBFNN), sequential learning, wavelet basis function neural network (WBFNN)
A43	Robust State Estimation for Uncertain Neural Networks With Time-Varying Delay	2008	36	He Huang; Gang Feng; Jinde Cao;	Delay-dependent criteria, global asymptotical stability, linear matrix inequality (LMI), neural networks, robust state estimation, time-varying delay systems, uncertain systems
A44	Global u-Synchronization of Linearly Coupled Unbounded Time-Varying Delayed Neural Networks With Unbounded Delayed Coupling	2008	20	Tianping Chen; Wei Wu; Wenjuan Zhou;	Linearly coupled recurrently connected neural networks, global u-synchronization, moore-penrose inverse, unbounded time-varying delay
A45	A Recurrent Neural Network for Hierarchical Control of Interconnected Dynamic Systems	2007	39	Zeng-Guang Hou; Gupta, M.M.; Nikiforuk,	Dynamic neural networks, goal coordination, hierarchical control, interconnected systems, large-scale systems, neural

				P.N.; Min Tan; Cheng, L.;	networks, optimal control, optimization, recurrent neural networks
A46	Multiobjective Hybrid Optimization and Training of Recurrent Neural Networks	2008	82	Delgado, M.; Cuellar, M.P.; Pegalajar, M.C.;	Memetic algorithms, multi objective, recurrent neural networks (RNNs), time series
A47	An Improved Dual Neural Network for Solving a Class of Quadratic Programming Problems and Its k- Winners-Take-All Application	2008	36	Hu, X.; Wang, J.;	Winners-take-all (k-WTA), Global asymptotic stability, optimization, quadratic programming (QP), recurrent neural network
A48	A One-Layer Recurrent Neural Network With a Discontinuous Hard- Limiting Activation Function for Quadratic Programming	2008	39	Qingshan Liu; Jun Wang;	Differential inclusion, Lyapunov stability, global convergence, hard- limiting activation function, nonlinear programming, quadratic programming, recurrent neural network
A49	A Nonfeasible Gradient Projection Recurrent Neural Network for Equality-Constrained Optimization Problems	2008	51	Barbarosou, M.P.; Maratos, N.G.;	Constrained optimization, convergence, convex and nonconvex problems, recurrent neural networks
A50	Design of General Projection Neural Networks for Solving Monotone Linear Variational Inequalities and Linear and Quadratic Optimization Problems	2007	29	Xiaolin Hu; Jun Wang;	Global convergence, linear programming, linear variational inequality (LVI), quadratic programming, recurrent neural network

A51	Stability Analysis and the Stabilization of a Class of Discrete-Time Dynamic Neural Networks	2007	31	Patan, K.;	Constrained optimization, dynamic neural network, learning, stability, stabilization, stochastic approximation
A52	Discrete-Time Analogs for a Class of Continuous-Time Recurrent Neural Networks	2007	29	Pingzhou Liu; Qing-Long Han;	Delays, discrete-time analogs, recurrent neural networks, stability
A53	Logistic Model Tree Extraction From Artificial Neural Networks	2007	37	Dancey, D.; Bandar, Z.A.; McLean, D.;	Artificial intelligence, feedforward neural networks, multilayer perceptrons (MPLs), neural networks
A54	Robust Synchronization of an Array of Coupled Stochastic Discrete-Time Delayed Neural Networks	2008	45	Jinling Liang; Zidong Wang; Yurong Liu; Xiaohui Liu;	Coupled neural networks, Kronecker product, discrete time, matrix functional, robust synchronization, stochastic perturbation, time-varying delay
A55	Cooperative Recurrent Neural Networks for the Constrained L1 Estimator	2007	40	Youshen Xia; Kamel, M.S.;	Constrained least absolute deviation (LAD) estimation, cooperative recurrent neural networks (CRNNs), global convergence, linear parameter estimation
A56	Delayed Standard Neural Network Models for Control Systems	2007	29	Meiqin Liu;	Delayed standard neural network model (DSNNM), generalized eigenvalue problem (GEVP), linear matrix inequality (LMI), nonlinear system, recurrent neural network (RNN), stability

A57	A New Approach to Knowledge-Based Design of Recurrent Neural Networks	2008	66	Kolman, E.; Margaliot, M.;	Context-free grammar, formal languages, fuzzy all-permutations rule base (FARB), knowledge insertion, knowledge-based neurocomputing, neurofuzzy systems, recurrent neural networks (RNNs), regular grammar
A58	Hybrid Multiobjective Evolutionary Design for Artificial Neural Networks	2008	65	Chi-Keong Goh; Eu-Jin Teoh; Kay Chen Tan;	Artificial neural network (ANN), evolutionary algorithms, local search, multi objective optimization, singular value decomposition (SVD)
A59	Dynamics of Winner-Take-All Competition in Recurrent Neural Networks With Lateral Inhibition	2007	38	Zhi-Hong Mao; Massaquoi, S.G.;	Discontinuous neuron activations, equilibrium, lateral inhibition, striatum, winner-take-all (WTA)
A60	A Modular Fault-Diagnostic System for Analog Electronic Circuits Using Neural Networks With Wavelet Transform as a Preprocessor	2007	23	Aminian, M.; Aminian, F.;	Circuit fault diagnosis, computational intelligence, neural network, signal processing, wavelet transform
A61	Bayesian Neural Networks for Internet Traffic Classification	2007	41	Auld, T.; Moore, A.W.; Gull, S.F.;	Internet traffic, network operations, neural network applications, pattern recognition, traffic identification
A62	Global Robust Stability of Bidirectional Associative Memory Neural Networks	2007	36	Senan, S.; Arik, S.;	Delayed neural networks, Lyapunov functionals, equilibrium and stability analysis

	With Multiple Time Delays				
A63	A Neural-Network-Based Model for the Dynamic Simulation of the Tire/Suspension System While Traversing Road Irregularities	2008	41	Guarneri, P.; Rocca, G.; Gobbi, M.;	Dynamics, recurrent neural network (RNN), road vehicle, suspension testing, tire
A64	Delay-Dependent Criteria for Global Robust Periodicity of Uncertain Switched Recurrent Neural Networks With Time-Varying Delay	2008	36	Xuyang Lou; Baotong Cui;	Delay-dependent criteria, global robust periodicity, recurrent neural networks (RNNs), switched systems, time-varying delay
A65	Design of Asymptotic Estimators: An Approach Based on Neural Networks and Nonlinear Programming	2007	44	Alessandri, A.; Cervellera, C.; Sanguineti, M.;	Feedforward neural networks, Lyapunov function, offline optimization, penalty function, quasi-random sequences, state observer
A66	A New Jacobian Matrix for Optimal Learning of Single-Layer Neural Networks	2008	46	Jian-Xun Peng; Kang Li; Irwin, G.W.;	Approximation, Jacobian matrix, convergence, single-hidden layer feedforward neural network (SLFN), supervised learning, training accuracy
A67	Multifeedback-Layer Neural Network	2007	32	Savran, A.;	Adjoint mode, Levenberg–Marquardt (LM), backpropagation through time (BPTT), identification, prediction, recurrent neural network (RNN)
A68	Simultaneous Pattern Classification and	2007	52	Hoya, T.; Washizawa,	Constructive approach, kernel method, pattern

	Multidomain Association Using Self-Structuring Kernel Memory Networks			Y.;	classification, self-structuring neural networks
A69	An Improved Algebraic Criterion for Global Exponential Stability of Recurrent Neural Networks With Time-Varying Delays	2008	20	Yi Shen; Jun Wang;	Global exponential stability, M-matrix, recurrent neural networks, time-varying delays
A70	Delay-Distribution-Dependent Exponential Stability Criteria for Discrete-Time Recurrent Neural Networks With Stochastic Delay	2008	39	Dong Yue; Yijun Zhang; Engang Tian; Chen Peng;	Delay distribution dependent, discrete-time recurrent neural networks (DRNNs), exponential stability, linear matrix inequality (LMI), stochastic delay
A71	Best Approximation of Gaussian Neural Networks With Nodes Uniformly Spaced	2008	70	Mulero-Martinez, J.I.;	Best approximation, Gaussian radial basis functions (RBFs), existence, functions band-limited in frequency, sampling theory, truncation, uniqueness
A72	Training Winner-Take-All Simultaneous Recurrent Neural Networks	2007	29	Xindi Cai; Prokhorov, D.V.; Wunsch, D.C.;	Backpropagation through time (BPTT), extended Kalman filter (EKF), simultaneous recurrent network (SRN), winner-take-all (WTA)
A73	Artificial Immune Networks Based Radial Basic Function Neural Networks Construction Algorithm and	2007	10	Jiang Zhong; Yong Feng; Chunxiao Ye; Ling Ou; Zhiguo Li;	Application software, artificial neural networks, clustering algorithms, feedforward neural networks, intrusion detection, neural networks, neurons, radial

	Application				basis function networks, software algorithms, supervised learning
A74	The Hierarchical Fast Learning Artificial Neural Network (HieFLANN)—An Autonomous Platform for Hierarchical Neural Network Construction	2007	22	Tay, A.L.P.; Zurada, J.M.; Lai-Ping Wong; Jian Xu;	Iterations fast learning artificial neural network (KFLANN), Canonical correlation analysis (CCA), data presentation sequence sensitivity (DPSS), hierarchical neural networks (NNs), homogeneous feature subspaces
A75	Comparing Support Vector Machines and Feedforward Neural Networks With Similar Hidden-Layer Weights	2007	13	Romero, E.; Toppo, D.;	Feedforward neural networks (FNNs), sparse models, support vector machines (SVMs)
A76	On the Almost Periodic Solution of Cellular Neural Networks With Distributed Delays	2007	19	Yiguang Liu; Zhisheng You; Liping Cao;	Almost periodic solution (APS), cellular neural networks (CNNs), distributed delays, fixed-point theorem
A77	Localized Generalization Error Model and Its Application to Architecture Selection for Radial Basis Function Neural Network	2007	29	Yeung, D.S.; Ng, W.W.Y.; Defeng Wang; Tsang, E.C.C.; Xi-Zhao Wang;	Localized generalization error, network architecture selection, radial basis function neural network (RBFNN), sensitivity measure network (RBFNN), sensitivity measure
A78	Configuration of Continuous Piecewise-Linear Neural Networks	2008	18	Shuning Wang; Xiaolin Huang; Khan Junaid, K.M.;	Canonical representation, function approximation, hinging hyperplanes, piecewise-linear approximation, piecewise-linear neural network

A79	Equilibria and Their Bifurcations in a Recurrent Neural Network Involving Iterates of a Transcendental Function	2008	33	Gao, B.; Weinian Zhang;	Bifurcation, center manifold, equilibrium, iteration, recurrent neural network, transcendental function
A80	Neural Network Adaptive Control for a Class of Nonlinear Uncertain Dynamical Systems With Asymptotic Stability Guarantees	2008	22	Hayakawa, T.; Haddad, W.M.; Hovakimyan, N.;	Adaptive control, asymptotic stability, input-to-state stable internal dynamics, neural networks (NNs), partial stability, sector-bounded nonlinearities
A81	A complete proof of global exponential convergence of a neural network for quadratic optimization with bound constraints	2001	9	Chung-Hwa Chang; Anderson, G.T.; Loizou, P.C.;	Global exponential stability, quadratic optimization with bound constraints, recurrent neural networks
A82	A neural network model for optimizing vowel recognition by cochlear implant listeners	2001	14	Chung-Hwa Chang; Gary T. Anderson; Philipos C. Loizou;	Cochlear implants, neural networks for cochlear implants
A83	Multiwavelet neural network and its approximation properties	2001	13	Licheng Jiao; Jin Pan; Yangwang Fang;	Multiwavelet, multiwavelet neural network, neural network, wavelet
A84	Weighted centroid neural network for edge preserving image compression	2001	22	Dong-Chul Park; Young-June Woo;	Edge, image compression, neural network, unsupervised learning, vector quantization
A85	A new gradient-based neural network for solving linear and quadratic	2001	25	Yee Leung; Kai-Zhou Chen; Yong-	Asymptotic stability, convergence, duality theory, linear programming, neural

	programming problems			Chang Jiao; Xing-Bao Gao;	network, quadratic programming
A86	A novel continuous-time neural network for realizing associative memory	2001	25	Qing Tao; Tingjian Fang; Hong Qiao;	Associative memory, basin of attraction, equilibrium points, neural networks, projection operator
A87	A neural learning approach for adaptive image restoration using a fuzzy model-based network architecture	2001	34	Hau-San Wong; Ling Guan;	Fuzzy theory, image processing, image restoration, neural networks, regularization
A88	Mapping Boolean functions with neural networks having binary weights and zero thresholds	2001	7	Deolalikar, V.;	Binary neural networks, Boolean function mapping, one-layer networks, two-layer networks
A89	A neural network for shortest path computation	2001	9	Araujo, F.; Ribeiro, B.; Rodrigues, L.;	Neural networks, shortest path computation problem, two-layer Hopfield neural network
A90	An algorithmic approach to adaptive state filtering using recurrent neural networks	2001	46	Parlos, A.G.; Menon, S.K.; Atiya, A.;	Adaptive state filtering, dynamic networks, extended Kalman filters (EKF), nonlinear state filtering, recurrent networks
A91	Classification of freeway traffic patterns for incident detection using constructive probabilistic neural networks	2001	17	Xin Jin; Srinivasan, D.; Ruey Long Cheu;	Incident detection, model adaptation, network pruning, probabilistic neural network
A92	Fuzzy neural network with general parameter adaptation for modeling of	2001	10	Akhmetov, D.F.; Dote, Y.; Ovaska, S.J.;	Fault diagnosis, fuzzy systems, neural networks, nonlinear systems

	nonlinear time-series				
A93	New recursive-least-squares algorithms for nonlinear active control of sound and vibration using neural networks	2001	21	Bouchard, M.;	Active control of sound and vibration, gradient computations, multilayer feedforward neural networks, nonlinear control, recursive-least-squares algorithms, steepest descent algorithms
A94	Efficient training of RBF neural networks for pattern recognition	2001	12	Lampariello, F.; Sciandrone, M.;	Error functions, neural network training, pattern recognition
A95	Training of a feedforward multiple-valued neural network by error backpropagation with a multilevel threshold function	2001	7	Asari, V.K.;	Backpropagation, multilevel threshold function, multiple valued neural network
A96	Global exponential stability of neural networks with globally Lipschitz continuous activations and its application to linear variational inequality problem	2001	32	Xue-Bin Liang; Si, J.;	Global exponential stability, global Lipschitz continuous activations, linear variational inequality problems, recurrent neural networks extraction, feedforward neural networks
A97	Approximation of nonlinear systems with radial basis function neural networks	2001	31	Schilling, R.J.; Carroll, J.J., Jr.; Al-Ajlouni, A.F.;	Function approximation, neural network, nonlinear system, radial basis function
A98	A cross-associative neural network for SVD of non-squared	2001	22	Da-Zheng Feng; Zheng Bao;	Cross-associative neural network, global asymptotic stability,

	data matrix in signal processing			Xian-Da Zhang;	learning rate, signal processing, singular value decomposition
A99	Qualitative analysis of a recurrent neural network for nonlinear continuously differentiable convex minimization over a nonempty closed convex subset	2001	11	Xue-Bin Liang;	Closed convex subsets, convex minimization, global convergence, global existence of solutions, global exponential convergence, recurrent neural networks, uniform convexity
A100	A recurrent neural network for nonlinear continuously differentiable optimization over a compact convex subset	2001	11	Xue-Bin Liang;	Compact convex subset, convergence, convex minimization, nonlinear optimization, projection operator, recurrent neural networks
A101	Some extensions of a new method to analyze complete stability of neural networks	2002	25	Forti, M.;	Neural networks, piecewise-linear functions, stability
A102	Communication channel equalization using complex-valued minimal radial basis function neural networks	2002	18	Deng Jianping; Narasimhan Sundararajan; Saratchandran, P.;	Channel equalization, complex minimal resource allocation network, quadrature amplitude modulation, radial basis function neural network
A103	Evolving a modular neural network-based behavioral fusion using extended VFF and environment classification for mobile robot navigation	2002	15	Kwang-Young Im; Se-Young Oh; Seong-Joo Han;	Behavioral fusion, evolutionary learning, mobile robot navigation, modular neural networks
A104	Bounds of the incremental gain for	2002	15	Yun-Chung Chu;	Diagonally dominant matrices, linear matrix

	discrete-time recurrent neural networks				inequalities, recurrent neural networks, servomechanism problem
A105	The simplicial neural cell and its mixed-signal circuit implementation: an efficient neural-network architecture for intelligent signal processing in portable multimedia applications	2002	24	Dogaru, R.; Julian, P.; Chua, L.O.; Glesner, M.;	Cellular neural networks, feedforward neural networks, image reconstruction, mixed analog–digital integrated circuits, pattern classification, piecewise linear approximation
A106	A recurrent neural network for solving Sylvester equation with time-varying coefficients	2002	20	Yunong Zhang; Danchi Jiang; Jun Wang;	Global exponential convergence, matrix inversion, nonlinear output regulation, recurrent neural network, time-varying Sylvester equation
A107	Complex-bilinear recurrent neural network for equalization of a digital satellite channel	2002	31	Dong-Chul Park; Tae-Kyun Jung Jeong;	Bilinear polynomial, decision feedback equalizer filter, equalizer, neural network, recurrent neural network, Volterra series of a digital satellite channel
A108	Robust CDMA multiuser detection using a neural-network approach	2002	28	Teong Chee Chuah; Sharif, B.S.; Hinton, O.R.;	Stable distributions, decorrelating detector, M-estimation, non-Gaussian noise, recurrent neural network
A109	An optimal power-dispatching system using neural networks for the electrochemical process of zinc depending on varying	2002	18	Chunhua Yang; Deconinck, G.; Weihua Gui; Yonggang Li;	Electrochemical process of zinc, neural networks, optimization, power-dispatching, varying prices of electricity

	prices of electricity				
A110	A new k-groups neural network	2002	15	Jui-Cheng Yen;	Coarse-and-fine competition, convergence rate, divide-and-conquer principle, k-groups neural network
A111	Interpretation of artificial neural networks by means of fuzzy rules	2002	22	Castro, J.L.; Mantas, C.J.; Benitez, J.M.;	Artificial neural networks, extraction, fuzzy rules, interpretation
A112	Neighborhood based Levenberg-Marquardt algorithm for neural network training	2002	12	Lera, G.; Pinzolas, M.;	Learning algorithms, neural networks
A113	A general backpropagation algorithm for feedforward neural networks learning	2002	12	Xinghuo Yu; Efe, M.O.; Kaynak, O.;	Backpropagation, feedforward neural networks, stability, training
A114	On the analysis of a recurrent neural network for solving nonlinear monotone variational inequality problems	2002	18	Xue-Bin Liang;	Convergence, equilibrium points, exponential convergence, limit cycles, monotone variational inequalities, nonsymmetric monotone variational inequalities, recurrent neural networks, solution trajectories, stability analysis, strictly monotone variational inequalities, uniformly monotone variational inequalities
A115	On the discrete-time dynamics of the basic Hebbian neural network node	2002	20	Zufria, P.J.;	Chaos, dynamical behavior, Hebbian neural networks, stochastic approximation
A116	VEP optimal channel	2002	16	Palaniappan	Alcoholism, digital filter,

	selection using genetic algorithm for neural network classification of alcoholics			, R.; Raveendran, P.; Omatu, S.;	fuzzy ARTMAP, multilayer perceptron, visual evoked potential
A117	A decentralized control of interconnected systems using neural networks	2002	14	Huang, S.N.; Tan, K.K.; Lee, T.H.;	Decentralized control, large-scale systems, neural networks, stability
A118	Region growing with pulse-coupled neural networks: an alternative to seeded region growing	2002	20	Stewart, R.D.; Fermin, I.; Oppen, M.;	Image segmentation, pulse-coupled neural network, region growing, statistical control, seeded region growing
A119	A finite-element mesh generator based on growing neural networks	2002	22	Triantafyllidis, D.G.; Labridis, D.P.;	Automatic mesh generation, best matching unit location, finite-element method, let-it-grow neural networks, mesh density prediction
A120	Improved neural network for SVM learning	2002	16	Anguita, D.; Boni, A.;	Quadratic programming, recurrent networks, support vector machine
A121	A dual neural network for redundancy resolution of kinematically redundant manipulators subject to joint limits and joint velocity limits	2003	39	Yunong Zhang ; Jun Wang ; Youshen Xia;	Drift-free, dual neural network, joint limits, joint velocity limits, kinematically redundant manipulators
A122	Tuning of the structure and parameters of a neural network using an improved genetic algorithm	2003	37	Leung, F.H.F. ; Lam, H.K. ; Ling, S.H. ; Tam, P.K.S.;	Genetic algorithm (GA), neural networks, parameter learning, structure learning
A123	Trajectory generation	2003	49	Zegers, P. ;	Dynamic neural network

	and modulation using dynamic neural networks			Sundareshan, M.K.;	(DNN), recurrent neural network (RNN), trajectory generation, trajectory modulation
A124	Extraction and use of neural network models in automated synthesis of operational amplifiers	2003	44	Wolfe, G. ; Vemuri, R.;	Analog integrated circuits, modeling, neural networks, synthesis
A125	Neural-network control of nonaffine nonlinear system with zero dynamics by state and output feedback	2003	35	Ge, S.S. ; Jin Zhang;	High-gain observer, neural networks, nonaffine system, output feedback control, zero dynamics
A126	An efficient fully unsupervised video object segmentation scheme using an adaptive neural-network classifier architecture	2003	34	Doulamis, A. ; Doulamis, N. ; Ntalianis, K. ; Kollias, S.;	Adaptive neural networks, MPEG-4, video object extraction
A127	Neural-network hybrid control for antilock braking systems	2003	22	Chih-Min Lin ; Hsu, C.-F.;	Adaptive law, antilock braking system, recurrent neural network (RNN), sliding-mode control
A128	A new wide range Euclidean distance circuit for neural network hardware implementations	2003	14	Gopalan, A. ; Titus, A.H.;	Analog very large-scale integration (VLSI), Euclidean distance circuit, hardware synapse, neural network
A129	Medical diagnosis with C4.5 rule preceded by artificial neural network ensemble	2003	32	Zhi-Hua Zhou ; Yuan Jiang;	Artificial neural networks, ensemble learning, machine learning, rule induction
A130	Two-stage clustering via neural networks	2003	29	Jung-Hua Wang ; Jen-Da Rau ;	Clustering, gravitation, k-means, neural networks, quantization

				Wen-Jeng Liu;	
A131	Neural-network construction and selection in nonlinear modeling	2003	36	Rivals, I.; Personnaz, L.;	Growing and pruning procedures, ill-conditioning detection, input selection, least squares (LS) estimation, leave-one-out cross validation, linear Taylor expansion, model selection, neural networks, nonlinear regression, statistical hypothesis tests
A132	A neural-network packet switch controller: scalability, performance, and network optimization	2003	20	Symington, K.J.; Waddie, A.J.; Taghizadeh, M.R.; Snowdon, J.F.;	Neural networks, optical diffraction, optimization methods, packet switching
A133	A high-performance feedback neural network for solving convex nonlinear programming problems	2003	16	Yee Leung; Kai-Zhou Chen; Xing-Bao Gao;	Asymptotic stability, convergence, convex nonlinear programming, feedback neural network
A134	Performance analysis for a K-winners-take-all analog neural network: basic theory	2003	11	Marinov, C.A.; Calvert, B.D.;	Continuous-time Hopfield network, K-winners-take-all, large gain behavior, processing time
A135	Design and implementation of a random neural network routing engine	2003	16	Kocak, T.; Seeber, J.; Terzioglu, H.;	Network processors, neural network, packet switched networks, random neural networks
A136	DSP-based hierarchical neural network modulation signal classification	2003	13	Namjin Kim; Kehtarnava z, N.;	Digital signal processor (DSP) implementation, hierarchical neural network classifier,

				Yeary, M.B.; Thornton, S.;	modulation signal classification
A137	Global exponential stability of competitive neural networks with different time scales	2003	11	Meyer- Baese, A.; Pilyugin, S.S.; Chen, Y.;	Flow invariance, global exponential stability, multi timescale neural network
A138	0.8 μ m CMOS implementation of weighted-order statistic image filter based on cellular neural network architecture	2003	21	Kowalski, J.;	Application specific integrated circuit (ASIC), cellular neural networks, image processing, nonlinear filtering
A139	FPGA implementation of a pulse density neural network with learning ability using simultaneous perturbation	2003	17	Maeda, Y. ; Tada, T. ;	Field-programmable gate array (FPGA), learning ability, neural networks (NNs), pulse density, simultaneous perturbation
A140	The self-trapping attractor neural network. I. Analysis of a simple 1-D model	2003	11	Pavloski, R.; Karimi, M.;	Associative memory, attractor neural network(ANN), connectivity, coupled systems, feedback, Hopfield model, Ising model, self-trapping
A141	A general projection neural network for solving monotone variational inequalities and related optimization problems	2004	32	Youshen Xia; Jun Wang;	Global stability, recurrent neural networks, variational inequalities optimization
A142	A Novel Neural Network for Nonlinear convex	2004	24	Xing-Bao Gao;	Convergence and stability, neural network, nonlinear convex programming

	programming				
A143	Supervisory recurrent fuzzy neural network control of wing rock for slender delta wings	2004	25	Chih-Min Lin ; Chun-Fei Hsu;	Recurrent fuzzy neural network (RFNN), supervisory
A144	An adaptive H [∞] controller design for bank-to-turn missiles using ridge Gaussian neural networks	2004	28	Chuan-Kai Lin; Sheng-De Wang;	Bank-to-turn (BTT) missiles, Gaussian neural networks, H control theory, ridge functions
A145	A Hopfield network learning method for bipartite subgraph problem	2004	19	Rong Long Wang; Zheng Tang; Qi Ping Cao;	Bipartite subgraph problem, gradient ascent learning, Hopfield neural network, NP-complete problem, total coloring problem
A146	Reproducing chaos by variable structure recurrent neural networks	2004	13	Felix, R.A.; Sanchez, E.N.; Guanrong Chen;	Chaos generation, identification, recurrent neural networks, variable structure system
A147	Adaptive hybrid control for linear piezoelectric ceramic motor drive using diagonal recurrent CMAC network	2004	32	Rong-Jong Wai; Chih-Min Lin; Ya-Fu Peng;	Adaptive hybrid control, cerebellar-model-articulation-computer (CMAC), diagonal recurrent, linear piezoelectric ceramic motor (LPCM), LLCC resonant inverte
A148	Entropy-based generation of supervised neural networks for classification of structured patterns	2004	36	Hsien-Leing Tsai; Shie-Jue Lee;	Delta rules, generalized recursive neuron, information entropy, multilayer perceptrons, structured patterns
A149	Robust redesign of a neural network controller in the presence of	2004	38	Rovithakis, G.A.;	Neural control, nonlinear systems, robust adaptive control, unmodeled dynamic

	unmodeled dynamics				
A150	A neural network for a class of convex quadratic minimax problems with constraints	2004	19	Xing-Bao Gao ; Li-Zhi Liao ; Weimin Xue;	Convergence and stability, minimax problem, neural network, saddle point
A151	Fast converging minimum probability of error neural network receivers for DS-CDMA communications	2004	20	Matyjas, J.D.; Psaromiligkos, I.N.; Batalama, S.N.; Medley, M.J.;	Accelerated convergence, approximation theory, direct-sequence code-division-multiple-access (DS-CDMA) systems, importance sampling (IS), minimum bit-error rate (BER), minimum probability of error, multilayer perceptron, neural networks (NNs), stochastic approximation, supervised learning algorithm
A152	Efficient learning algorithms for three-layer regular feedforward fuzzy neural networks	2004	34	Puyin Liu; Hongxing Li;	Back-propagation (BP) algorithm, fuzzy BP algorithm, fuzzy conjugate gradient algorithm, regular fuzzy neural network, function
A153	Branching competitive learning Network:A novel self-creating model	2004	24	Huilin Xiong; Swamy, M.N.S.; Ahmad, M.O.; Irwin King;	Competitive learning, self-creating neural network, vector quantization
A154	Associative memory design for 256 gray-level images using a multilayer neural network	2004	10	Costantini, G.; Casali, D.; Perfetti, R.;	Associative memories, brain-state-in-a-box (BSB) neural networks, gray-scale images, multilayer architecture
A155	Neural-network-based adaptive	2004	37	Chin-Teng Lin; Wen-	Enforcing integrability, Lambertian model, neural

	hybrid-reflectance model for 3-D surface reconstruction			Chang Cheng; Sheng-Fu Liang;	network, reflectance model, shape from shading, surface normal
A156	Pulse-coupled neural networks for contour and motion matchings	2004	24	Bo Yu; Liming Zhang;	Image matching, primary cortex, prior knowledge, pulse-coupled neural network (PCNN), temporal codin
A157	Grouping synchronization in a pulse-coupled network of chaotic spiking oscillators	2004	18	Nakano, H.; Saito, T.;	Chaos, grouping, integrate-and-fire, pulse-coupled network (PCN), spiking neuron, synchronization
A158	Combining expert neural networks using reinforcement feedback for learning primitive grasping behavior	2004	20	Moussa, M.A.;	Mixture of experts, modular architecture, robot grasping, robot learning
A159	A hierarchical self-organizing approach for learning the patterns of motion trajectories	2004	22	Weiming Hu ; Dan Xie ; Tieniu Tan;	Hierarchical self-organizing neural network, trajectory analysis and learning, anomaly detection, behavior prediction
A160	An automated method for lumen and media-adventitia border detection in a sequence of IVUS frames	2004	18	Plissiti, M.E.; Fotiadis, D.I.; Michalis, L.K.; Bozios, G.E.;	Deformable models, image segmentation, intravascular ultrasound (IVUS)
A161	Simultaneous perturbation learning rule for recurrent neural networks and its FPGA implementation	2005	28	Maeda, Y. ; Wakamura, M.;	Field-programmable gate array (FPGA) implementation, Hopfield neural networks (HNNs), recurrent neural networks (RNNs), recursive

					learning, simultaneous perturbation
A162	Improved conditions for global exponential stability of recurrent neural networks with time-varying delays	2006	22	Zhigang Zeng ; Jun Wang;	External inputs, neural networks (NNs), stability, time-varying delay
A163	Global exponential stability and global convergence in finite time of delayed neural networks with infinite gain	2005	38	Forti, M. ; Nistri, P. ; Papini, D.;	Convergence in finite time, delayed neural networks, discontinuous dynamical systems, global exponential stability
A164	Training Reformulated Radial Basis Function Neural Networks Capable of Identifying Uncertainty in Data Classification	2006	26	Karayiannis , N.B. ; Yaohua Xiong;	Cosine radial basis function (RBF), feed-forward neural network (FFNN), gradient descent learning, quantum neural network (QNN), radial basis function neural network (RBFNN), uncertainty
A165	Viscosity Prediction for PET Process Based on Hybrid Neural Networks	2006	9	Liu-lin Cao ; Xing-hua Xu ; Pei Jiang;	BSNN, DRNN, Hybrid Neural Network, RPE
A166	Associative memory design for 256 gray-level images using a multilayer neural network	2006	10	Costantini, G. ; Casali, D. ; Perfetti, R.;	Associative memories, brain-state-in-a-box (BSB) neural networks, gray-scale images, multilayer architectures
A167	Convergence of gradient method with momentum for two-Layer feedforward neural networks	2006	11	Naimin Zhang ; Wei Wu ; Gaofeng Zheng;	Convergence, feedforward neural network, gradient method, momentum
A168	Global robust stability of a class of discrete-time interval	2006	29	Sanqing Hu ; Jun Wang;	Discrete-time, globally robust stable, interval matrix, neural network

	neural networks				
A169	Extension neural network-type 2 and its applications	2005	26	Mang-Hui Wang;	ENN-2, extension neural network (ENN), neural networks (NNs), unsupervised learning
A170	Existence and global exponential stability of almost periodic solution for cellular neural networks with variable coefficients and time-varying delays	2005	31	Haijun Jiang ; Zhang, L. ; Zhidong Teng;	Almost periodic solution, cellular neural networks (CNNs), global exponential stability, hull equation, hull function, time-varying delays, variable coefficient, young inequality
A171	A New Adaptive Backpropagation Algorithm Based on Lyapunov Stability Theory for Neural Networks	2006	23	Zhihong Man ; Hong Ren Wu ; Sophie Liu ; Xinghuo Yu;	Adaptive filtering, Lyapunov stability, backpropagation (BP), convergence, feedforward neural networks
A172	Deriving sufficient conditions for global asymptotic stability of delayed neural networks via nonsmooth analysis-II	2005	28	Houduo Qi ; Liqun Qi ; Xiaoqi Yang;	Equilibrium point, Lipschitzian functions, global asymptotic stability, neural networks, nonsmooth analysis
A173	Observing the evolution of neural networks learning to play the game of Othello	2005	47	Chong, S.Y. ; Tan, M.K. ; White, J.D.;	Artificial intelligence, Othello, coevolution, evolutionary computation, neural networks
A174	Evolutionary Design of Neural Network Architectures Using a Descriptive Encoding Language	2006	49	Jae-Yoon Jung ; Reggia, J.A.;	Descriptive encoding, evolutionary neural networks, modular neural network
A175	Are artificial neural networks white boxes?	2005	37	Kolman, E. ; Margaliot, M.;	Feedforward neural networks, hybrid intelligent systems, knowledge-based

					networks, rule extraction, rule generation, rule refinement
A176	Emergent epileptiform activity in neural networks with weak excitatory synapses	2005	38	Van Drongelen, W. ; Lee, H.C. ; Hereld, M. ; Zheyang Chen ; Elsen, F.P. ; Stevens, R.L.;	Epilepsy, neocortex, neural modeling
A177	A delayed neural network for solving linear projection equations and its analysis	2005	35	Qingshan Liu ; Jinde Cao ; Youshen Xia;	Asymptotical stability, Lyapunov-Krasovskii functional, delayed neural networks, exponential stability, linear matrix inequality (LMI), quadratic programming
A178	High-speed face recognition based on discrete cosine transform and RBF neural networks	2005	38	Meng Joo Er ; Chen, W. ; Shiqian Wu;	Discrete cosine transform (DCT), FERET database, Fisher's linear discriminant (FLD), Olivetti Research Laboratory (ORL) database, Yale database, face recognition, illumination invariance, radial basis function (RBF) neural networks
A179	Bio-basis function neural network for prediction of protease cleavage sites in proteins	2005	56	Zheng Rong Yang ; Thomson, R.;	Amino acid mutation matrix, bio-basis function neural network (BBFNN), pattern recognition, protease cleavage site prediction
A180	A novel radial basis function neural network for	2006	43	Zheng Rong Yang;	Bayesian method, discriminant analysis, radial basis function

	discriminant analysis				neural networks (RBFNNs)
A181	An improved global asymptotic stability criterion for delayed cellular neural networks	2006	23	Yong He ; Min Wu ; Jin-Hua She;	Delayed cellular neural networks, S-procedure, global asymptotic stability, linear matrix inequality (LMI)
A182	On stability of recurrent neural networks-an approach from volterra integro-differential equations	2006	15	Pingzhou Liu ; Han, Q.-L.;	Delay, Volterra integro-differential systems, recurrent neural networks (RNNs), stability
A183	Global asymptotic stability analysis of bidirectional associative memory neural networks with time delays	2005	34	Arik, S.;	Delayed neural networks, Lyapunov functionals, equilibrium and stability analysis
A184	Neural-network-based adaptive hybrid-reflectance model for 3-D surface reconstruction	2005	37	Chin-Teng Lin ; Wen-Chang Cheng ; Sheng-Fu Liang;	Enforcing integrability, Lambertian model, neural network, reflectance model, shape from shading, surface normal
A185	Pareto evolutionary neural networks	2005	69	Fieldsend, J.E. ; Singh, S.;	Adaptive topologies, evolutionary computation (EC), multiple objectives, neural networks (NNs), time series forecasting
A186	Constructive feedforward neural networks using Hermite polynomial activation functions	2005	37	Liyang Ma ; Khorasani, K.;	Constructive neural networks, Hermite polynomials, functional level adaptation, incremental training algorithms
A187	A novel neural network for the synthesis of antennas and microwave	2005	37	Delgado, H.J. ; Thursby, M.H. ;	Antenna synthesis, computationally intensive problems, finite-difference time-domain (FDTD)

	devices			Ham, F.M.;	method, group and weight scheme number representation, microwave device optimization, microwave device synthesis, novel neural network, randomization processes, simple sum scheme
A188	State estimation for delayed neural networks	2005	18	Zidong Wang ; Ho, D.W.C. ; Xiaohui Liu;	Exponential stability, linear matrix inequalities (LMIs), neural networks, state estimation, time-delays
A189	Deterministic convergence of an online gradient method for BP neural networks	2005	22	Wei Wu ; Guorui Feng ; Zhengxue Li ; Yuesheng Xu;	Online gradient methods, backward propagation (BP) neural networks, convergence
A190	Output convergence analysis for a class of delayed recurrent neural networks with time-varying inputs	2006	32	Zhang Yi ; Jian Cheng Lv ; Lei Zhang;	Delays, output convergence, recurrent neural networks, time-varying inputs
A191	Qualitative analysis for recurrent neural networks with linear threshold transfer functions	2005	21	Tan, K.C. ; HuaJin Tang ; Weinian Zhang;	Equilibria, global attractivity, linear threshold (LT) neural network, multistability, nonsaturating
A192	The applicability of recurrent neural networks for biological sequence analysis	2005	21	Hawkins, J. ; Boden, M.;	Machine learning, bias, biological sequence analysis, classifier design, motif, neural network architecture, pattern recognition, recurrent neural network, subcellular localization
A193	A stable neural	2006	36	Abdollahi,	Flexible joint

	network-based observer with application to flexible-joint manipulators			F. ; Talebi, H.A. ; Patel, R.V.;	manipulators, neural networks (NN), nonlinear observer
A194	Global Asymptotical Stability of Recurrent Neural Networks With Multiple Discrete Delays and Distributed Delays	2006	20	Jinde Cao ; Kun Yuan ; Han-Xiong Li;	Discrete delays, distributed delays, global asymptotical stability, linear matrix inequality (LMI), recurrent neural networks (RNNs), time-varying delays
A195	Solving Pseudomonotone Variational Inequalities and Pseudoconvex Optimization Problems Using the Projection Neural Network	2006	39	Xiaolin Hu ; Jun Wang;	Component wise pseudomonotone variational inequality, global asymptotic stability, projection neural network, pseudoconvex optimization, pseudomonotone variational inequality
A196	Stability analysis for stochastic Cohen-Grossberg neural networks with mixed time delays	2006	26	Zidong Wang ; Yurong Liu ; Maozhen Li ; Xiaohui Liu;	Cohen-Grossberg neural networks, discrete delays, distributed delays, global asymptotic stability, linear matrix inequality (LMI), Lyapunov-krasovskii functional, stochastic systems
A197	A stable neural network-based observer with application to flexible-joint manipulators	2006	36	Abdollahi, F. ; Talebi, H.A. ; Patel, R.V.;	Flexible joint manipulators, neural networks (NN), nonlinear observer
A198	Training cost-sensitive neural networks with methods addressing the class imbalance	2006	39	Zhi-Hua Zhou ; Xu-Ying Liu;	Machine learning, class imbalance learning, cost-sensitive learning, data mining, ensemble learning, neural networks,

	problem				sampling, threshold-moving
A199	Adaptive wavelet neural network control with hysteresis estimation for piezo-positioning mechanism	2006	46	Faa-Jeng Lin ; Shieh, H.-J. ; Po-Kai Huang;	Adaptive wavelet neural network (AWNN), hysteresis friction model, lumped uncertainty, piezo-positioning mechanism, robust compensator
A200	Adaptive neural network control for a class of low-triangular-structured nonlinear systems	2006	18	Hongbin Du ; Huihe Shao ; Pingjing Yao;	Adaptive control, backstepping design, neural networks (NNs), triangular forms

Columns 106 through 120

```

0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
1 1 1 1 1 1 1 1 1 1 1 1 1 1 1
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0

```

Columns 121 through 135

```

0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
1 1 1 1 1 1 1 1 1 1 1 1 1 1 1
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0

```

Columns 136 through 150

```

0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
1 1 1 1 1 1 1 1 1 1 1 1 1 1 1
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0

```

Columns 151 through 165

```

0 0 0 0 0 0 0 0 0 0 1 1 1 1 1
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
1 1 1 1 1 1 1 1 1 1 0 0 0 0 0
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0

```

Columns 166 through 180

```

1 1 1 1 1 1 1 1 1 1 1 1 1 1 1
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0

```

Columns 181 through 195

```

1 1 0 1 1 1 1 1 1 1 1 1 1 1 1
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
0 0 1 0 0 0 0 0 0 0 0 0 0 0 0

```

Columns 196 through 200

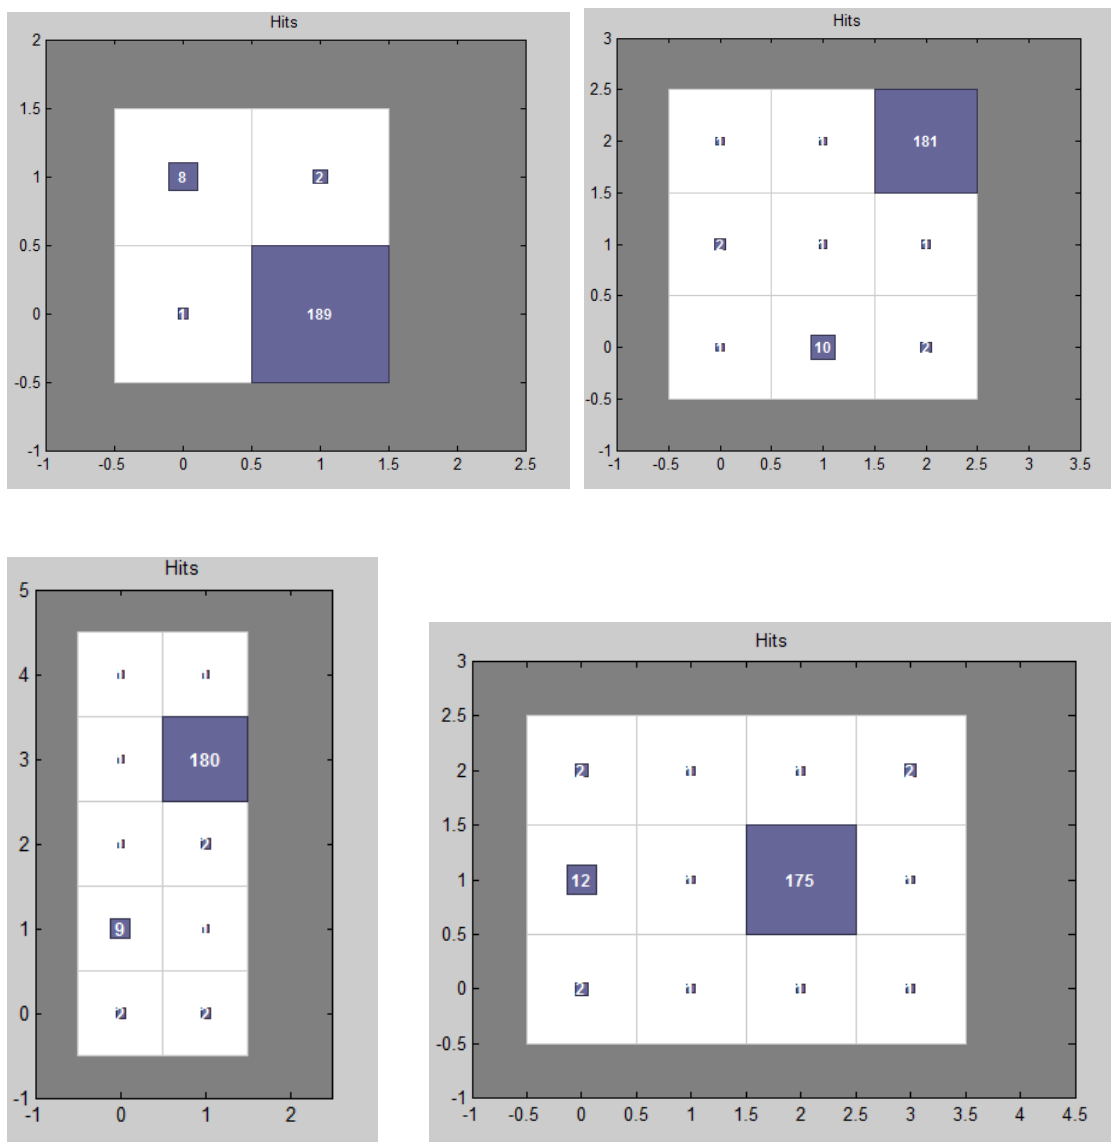
```




1 1 1 1 1
0 0 0 0 0
0 0 0 0 0
0 0 0 0 0

```

APÊNDICE E - DISTRIBUIÇÃO DOS ARTIGOS NA SAÍDA DA RNA NO EXPERIMENTO 3

As figuras apresentadas neste Apêndice representam a distribuição dos artigos, na saída da RNA, para as topologias de 4, 9, 10, 12, 16, 25 e 36 categorias no experimento 3.





APÊNDICE F - LISTA DE PALAVRAS-CHAVE EM ORDEM ALFABÉTICA

As palavras-chave dos 200 artigos foram listadas em ordem alfabética (VIANA, 2012) para utilização no Teste 4.

- 1 Accelerated convergence
- 2 Active control of sound and vibration
- 3 Adaptive control
- 4 Adaptive equalizer
- 5 Adaptive filtering
- 6 Adaptive hybrid control
- 7 Adaptive law
- 8 Adaptive neural networks
- 9 Adaptive state filtering
- 10 Adaptive topologies
- 11 Adaptive wavelet neural network (AWNN)
- 12 Adjoint model
- 13 Alcoholism
- 14 Almost periodic functions
- 15 Almost periodic solution (APS)
- 16 Almost sure exponential stability
- 17 Amino acid mutation matrix
- 18 Analog integrated circuits
- 19 Analog very large-scale integration
- 20 Anomaly detection
- 21 Antenna synthesis
- 22 Anti-integrable limit
- 23 Antilock braking system
- 24 Application software
- 25 Application specific integrated circuit (ASIC)
- 26 Approximation
- 27 Approximation theory
- 28 Artificial intelligence
- 29 Artificial neural network (ANN)
- 30 Associative memories
- 31 Asymptotic stability
- 32 Attitude control subsystem (ACS)
- 33 Attractor neural network(ANN)
- 34 Automatic mesh generation
- 35 Backpropagation (BP)
- 36 Backpropagation through time (BPTT)
- 37 Backstepping
- 38 Backstepping design
- 39 Backward propagation (BP) neural networks
- 40 Bank-to-turn (BTT) missiles
- 41 Basin of attraction
- 42 Bayesian method
- 43 Bayesian regularization
- 44 Behavior prediction
- 45 Behavioral fusion
- 46 Best approximation
- 47 Best matching unit location
- 48 Bias

- 49 Bifurcation
- 50 Bilinear polynomial
- 51 Binary neural networks
- 52 Bio-basis function neural network (BBFNN)
- 53 Biological sequence analysis
- 54 Bipartite subgraph problem
- 55 Boolean function mapping
- 56 Boundary value problems (BVPs)
- 57 Brain-State-in-a-Box (BSB)
- 58 Broadcast scheduling problems
- 59 BSNN
- 60 B-spline neural network
- 61 Canonical correlation analysis (CCA)
- 62 Canonical representation
- 63 Cellular neural networks
- 64 Censorship
- 65 Center manifold
- 66 Cerebellar-model-articulation-computer (CMAC)
- 67 Channel equalization
- 68 Chaos
- 69 Chaos generation
- 70 Circuit fault diagnosis
- 71 Class imbalance learning
- 72 Classifier design
- 73 Closed convex subsets
- 74 Clustering
- 75 Clustering algorithms
- 76 Clustering methods
- 77 Coarse-and-fine competition
- 78 Cochlear implants
- 79 Coevolution
- 80 Cohen–Grossberg neural networks
- 81 Collision avoidance
- 82 Common asymptotic behavior
- 83 Compact convex subset
- 84 Competition
- 85 Competitive learning
- 86 Competitive predictor
- 87 Complete convergence
- 88 Complex minimal resource allocation network
- 89 Complex network
- 90 Complex-valued neural networks
- 91 Component wise pseudomonotone variational inequality
- 92 Computational intelligence
- 93 Computationally intensive problems
- 94 Connected dominating set (CDS)
- 95 Connectivity
- 96 Constrained least absolute deviation (LAD) estimation
- 97 Constrained optimization
- 98 Constructive approach
- 99 Constructive neural networks
- 100 Context-free grammar
- 101 Continuous-time Hopfield network
- 102 Convergence

- 103 Convergence analysis
- 104 Convergence and stability
- 105 Convergence in finite time
- 106 Convergence rate
- 107 Convex and nonconvex problems
- 108 Convex minimization
- 109 Convex nonlinear programming
- 110 Cooperative recurrent neural networks (CRNNs)
- 111 Cosine radial basis function (RBF)
- 112 Cost function
- 113 Cost-sensitive learning
- 114 Coupled neural networks
- 115 Coupled systems
- 116 Cross-associative neural network
- 117 Data mining
- 118 Data presentation sequence sensitivity (DPSS)
- 119 Decentralized control
- 120 Decision feedback equalizer filter
- 121 Decorrelating detector
- 122 Deformable models
- 123 Delay dependent
- 124 Delay distribution dependent
- 125 Delay-dependent criteria
- 126 Delayed cellular neural networks
- 127 Delayed neural networks
- 128 Delayed standard neural network model (DSNNM)
- 129 Delays
- 130 Delta rules
- 131 Descriptive encoding
- 132 Diagonal recurrent
- 133 Diagonally dominant matrices
- 134 Differential inclusion
- 135 Differential inequality
- 136 Digital filter
- 137 Digital signal processor (DSP) implementation
- 138 Directed convergence
- 139 Direct-sequence code-division-multiple-access (DS-CDMA) systems
- 140 Discontinuous dynamical systems
- 141 Discontinuous neural networks
- 142 Discontinuous neuron activations
- 143 Discrete cosine transform (DCT)
- 144 Discrete delays
- 145 Discrete time-varying delays
- 146 Discrete-time
- 147 Discrete-time analogs
- 148 Discrete-time neural networks
- 149 Discrete-time recurrent neural networks (DRNNs)
- 150 Discriminant analysis
- 151 Distributed delays
- 152 Distributed time-varying delays
- 153 Divide-and-conquer principle
- 154 Drift-free
- 155 DRNN
- 156 Dual neural network

- 157 Duality theory
- 158 Dynamic networks
- 159 Dynamic neural network (DNN)
- 160 Dynamic surface control (DSC)
- 161 Dynamical behavior
- 162 Dynamics
- 163 Edge
- 164 Electrochemical process of zinc
- 165 Enforcing integrability
- 166 ENN-2
- 167 Ensemble learning
- 168 Ensembles
- 169 Epilepsy
- 170 Equalizer
- 171 Equilibria
- 172 Equilibrium
- 173 Equilibrium and stability analysis
- 174 Equilibrium point
- 175 Error functions
- 176 Euclidean distance circuit
- 177 Evolutionary algorithms
- 178 Evolutionary computation (EC)
- 179 Evolutionary learning
- 180 Evolutionary neural networks
- 181 Existence
- 182 Exponential convergence
- 183 Exponential stability
- 184 Extended Kalman filter (EKF)
- 185 Extension neural network (ENN)
- 186 External inputs
- 187 Extraction
- 188 Face recognition
- 189 Fault detection and isolation (FDI)
- 190 Fault diagnosis
- 191 Feedback
- 192 Feedback neural network
- 193 Feedforward neural network (FFNN)
- 194 FERET database
- 195 Field-programmable gate array (FPGA)
- 196 Field-programmable gate array (FPGA) implementation
- 197 File prediction
- 198 Finite impulse response (FIR)filter
- 199 Finite state automaton (FSA)
- 200 Finite-difference time-domain (FDTD) method
- 201 Finite-element method
- 202 Fisher's linear discriminant (FLD)
- 203 Fixed-point theorem
- 204 Flexible joint manipulators
- 205 Flow invariance
- 206 Forbidden set
- 207 Formal languages
- 208 Forward-only computation
- 209 Fourier series expansion (FSE)
- 210 Function

- 211 Function approximations
- 212 Functional level adaptation
- 213 Functional link artificial neural network (FLANN)
- 214 Functions band-limited in frequency
- 215 Fuzzy all-permutations rule base (FARB)
- 216 Fuzzy ARTMAP
- 217 Fuzzy BP algorithm
- 218 Fuzzy conjugate gradient algorithm
- 219 Fuzzy neural networks (FNNs)
- 220 Fuzzy rules
- 221 Fuzzy systems
- 222 Fuzzy theory
- 223 Gaussian neural networks
- 224 Gaussian radial basis functions (RBFs)
- 225 Generalized eigenvalue problem (GEVP)
- 226 Generalized recursive neuron
- 227 Genetic algorithm (GA)
- 228 Global asymptotic stability
- 229 Global attractivity
- 230 Global convergence
- 231 Global convergence in finite time
- 232 Global existence of solutions
- 233 Global exponential convergence
- 234 Global exponential stability
- 235 Global Lipschitz continuous activations
- 236 Global robust periodicity
- 237 Global stability
- 238 Global u-synchronization
- 239 Globally robust stable
- 240 Goal coordination
- 241 Gradient ascent learning
- 242 Gradient computations
- 243 Gradient descent learning
- 244 Gradient method
- 245 Graph neural networks (GNNs)
- 246 Graph processing
- 247 Graphical domains
- 248 Gravitation
- 249 Gray-scale images
- 250 Group and weight scheme number representation
- 251 Grouping
- 252 Growing and pruning procedures
- 253 Halanay in-equality
- 254 Hard-limiting activation function
- 255 Hardware synapse
- 256 H-control theory
- 257 Hebbian neural networks
- 258 Hermite polynomials
- 259 Hierarchical control
- 260 Hierarchical neural network classifier
- 261 Hierarchical neural networks (NNs)
- 262 Hierarchical self-organizing neural network
- 263 High-gain observer
- 264 Hinging hyperplanes

- 265 Homogeneous feature subspaces
- 266 Hopfield model
- 267 Hopfield neural network
- 268 Hopfield neural networks (HNNS)
- 269 Hull equation
- 270 Hull function
- 271 Hybrid constraints
- 272 Hybrid greedy simulated annealing (HGSA)
- 273 Hybrid intelligent systems
- 274 Hybrid Neural Network
- 275 Hysteresis friction model
- 276 Hysteretic
- 277 Identification
- 278 Ill-conditioning detection
- 279 Illumination invariance
- 280 Image compression
- 281 Image matching
- 282 Image processing
- 283 Image reconstruction
- 284 Image restoration
- 285 Image segmentation
- 286 Image storage and retrieval
- 287 Importance sampling (IS)
- 288 Impulses
- 289 Impulsive control
- 290 Impulsive delay
- 291 Impulsive perturbations interval neural networks
- 292 Impulsive synchronization
- 293 Incident detection
- 294 Incremental training algorithms
- 295 Information entropy
- 296 Information theory
- 297 Input selection
- 298 Input-to-state stable internal dynamics
- 299 Instrumental learning
- 300 Integral-type Lyapunov function (ILF)
- 301 Integrate-and-fire
- 302 Interconnected systems
- 303 Internet traffic
- 304 Interpretation
- 305 Interval matrix
- 306 Interval neural networks
- 307 Intravascular ultrasound (IVUS)
- 308 Intrusion detection
- 309 Irregular boundaries
- 310 Ising model
- 311 Iteration
- 312 Iterations fast learning artificial neural network (KFLANN)
- 313 Jacobian matrix
- 314 Joint limits
- 315 Joint velocity limits
- 316 K winners take all
- 317 Kernel method
- 318 Kinematically redundant manipulators

- 319 Knowledge insertion
- 320 Knowledge-based networks
- 321 Knowledge-based neurocomputing
- 322 Kronecker product
- 323 K-groups neural network
- 324 K-means
- 325 K-winners-take-all (WTA)
- 326 K-winners take-all operation
- 327 L1-norm optimization
- 328 Lambertian model
- 329 Large gain behavior
- 330 Large-scale systems
- 331 Lateral inhibition
- 332 Learning
- 333 Learning ability
- 334 Learning algorithms
- 335 Learning rate
- 336 Least absolute deviation (LAD)
- 337 Least squares (LS) estimation
- 338 Leave-one-out cross validation
- 339 Length factor
- 340 Let-it-grow neural networks
- 341 Levenberg–Marquardt (LM)
- 342 Levenberg–Marquardt (LM) backpropagation
- 343 Levenberg–Marquardt algorithm
- 344 Limit cycles
- 345 Linear and quadratic programming
- 346 Linear matrix inequalities (LMIs)
- 347 Linear parameter estimation
- 348 Linear piezoelectric ceramic motor (LPCM)
- 349 Linear programming
- 350 Linear Taylor expansion
- 351 Linear threshold (LT) neural network
- 352 Linear threshold
- 353 Linear variational inequality (LVI)
- 354 Linearly coupled recurrently connected neural networks
- 355 Lipschitzian functions
- 356 LLC resonant inverte
- 357 Local search
- 358 Localized generalization error
- 359 Lumped uncertainty
- 360 Lyapunov function
- 361 Lyapunov stability
- 362 Lyapunov–Krasovskii functional
- 363 Machine learning
- 364 Markov chain
- 365 Matrix
- 366 Matrix functional
- 367 Matrix inversion
- 368 Maximal-margin (MM) principle
- 369 Memetic algorithms
- 370 Mesh density prediction
- 371 M-estimation
- 372 Micro/nanomanipulation

- 373 Microwave device optimization
- 374 Microwave device synthesis
- 375 Minimality
- 376 Minimax optimization
- 377 Minimax problem
- 378 Minimum bit-error rate (BER)
- 379 Minimum probability of error
- 380 Mixed analog–digital integrated circuits
- 381 Mixed boundary conditions
- 382 Mixture of experts
- 383 M-matrix
- 384 Mobile robot
- 385 Mobile robot navigation
- 386 Model adaptation
- 387 Model selection
- 388 Modeling
- 389 Modular architecture
- 390 Modular neural network
- 391 Modulation signal classification
- 392 Momentum
- 393 Monotone variational inequalities
- 394 Moore-penrose inverse
- 395 Motif
- 396 MPEG-4
- 397 Multi objective
- 398 Multi objective optimization
- 399 Multi timescale neural network
- 400 Multiarmed bandit
- 401 Multiattractivity
- 402 Multilayer architecture
- 403 Multilayer feedforward neural networks
- 404 Multilayer neural network (MNN)
- 405 Multilayer perceptron (MLP)
- 406 Multilevel threshold function
- 407 Multiple objectives
- 408 Multiple valued neural network
- 409 Multistability
- 410 Multiwavelet
- 411 Multiwavelet neural network
- 412 Negative correlation learning (NCL)
- 413 Neocortex
- 414 Network architecture selection
- 415 Network operations
- 416 Network processors
- 417 Network pruning
- 418 Neural control
- 419 Neural dynamics
- 420 Neural modeling
- 421 Neural network
- 422 Neural network applications
- 423 Neural network architecture
- 424 Neural network control
- 425 Neural network ensembles
- 426 Neural network training

- 427 Neural networks for cochlear implants
- 428 Neurodynamics
- 429 Neurofuzzy systems
- 430 Neurons
- 431 Noisy chaotic neural network
- 432 Nonaffine system
- 433 Non-Gaussian noise
- 434 Non-Gaussian systems
- 435 Nonlinear channel
- 436 Nonlinear control
- 437 Nonlinear convex programming
- 438 Nonlinear filtering
- 439 Nonlinear observer
- 440 Nonlinear optimization
- 441 Nonlinear output regulation
- 442 Nonlinear programming
- 443 Nonlinear regression
- 444 Nonlinear state filtering
- 445 Nonlinear system
- 446 Nonlinearly parameterized systems
- 447 Nonsaturating
- 448 Nonsmooth analysis
- 449 Nonsmooth nonconvex optimization
- 450 Nonsymmetric monotone variational inequalities
- 451 Novel neural network
- 452 NP-complete problem
- 453 Offline optimization
- 454 Olivetti Research Laboratory (ORL) database
- 455 One-layer networks
- 456 Online gradient methods
- 457 Operant conditioning
- 458 Optical diffraction
- 459 Optimal control
- 460 Optimization
- 461 Optimization methods
- 462 Othello
- 463 Output convergence
- 464 Output feedback control
- 465 Packet radio network
- 466 Packet switching
- 467 Packet switched networks
- 468 Parameter learning
- 469 Partial stability
- 470 Path planning
- 471 Pattern classification
- 472 Pattern decomposition
- 473 Pattern recognition
- 474 Pattern sequence storage and retrieval
- 475 Penalty function
- 476 Perceptron
- 477 Periodic activation function
- 478 Periodically time-varying disturbances
- 479 Permitted set
- 480 Piecewise-linear approximation

- 481 Piecewise-linear functions
- 482 Piecewise-linear neural network
- 483 Piezoelectric actuator
- 484 Piezo-positioning mechanism
- 485 Pinning
- 486 Power-dispatching
- 487 Prediction
- 488 Primary cortex
- 489 Prior knowledge
- 490 Probabilistic model
- 491 Probabilistic neural network
- 492 Probabilistic predictor
- 493 Probability density functions (pdfs)
- 494 Probability matching
- 495 Processing time
- 496 Prognostic modeling
- 497 Projection neural network
- 498 Projection operator
- 499 Protease cleavage site prediction
- 500 Pseudoconvex optimization
- 501 Pseudomonotone variational inequality
- 502 Pulse density
- 503 Pulse-coupled network (PCN)
- 504 Pulse-coupled neural networks (PCNNs)
- 505 Quadratic optimization
- 506 Quadratic optimization with bound constraints
- 507 Quadratic programming (QP)
- 508 Quadrature amplitude modulation
- 509 Quantization
- 510 Quantum neural network (QNN)
- 511 Quasi-random sequences
- 512 Radial basis function neural network (RBFNN)
- 513 Random neural networks
- 514 Randomization processes
- 515 Reaction–diffusion
- 516 Recurrent neural network (RNN)
- 517 Recurrent fuzzy neural network (RFNN)
- 518 Recurrent neural networks extraction
- 519 Recursive learning
- 520 Recursive-least-squares algorithms
- 521 Recursive neural network
- 522 Reducibility
- 523 Reflectance model
- 524 Region growing
- 525 Regular fuzzy neural network
- 526 Regular grammar
- 527 Regularization
- 528 Reinforcement learning
- 529 Ridge functions
- 530 Risk analysis
- 531 Road vehicle
- 532 Robot grasping
- 533 Robot learning
- 534 Robust adaptive control

- 535 Robust compensator
- 536 Robust control
- 537 Robust stability
- 538 Robust state estimation
- 539 Robust synchronization
- 540 Rotation-equivalence
- 541 RPE
- 542 Rule extraction
- 543 Rule generation
- 544 Rule induction
- 545 Rule refinement
- 546 Saddle point
- 547 Sampling
- 548 Sampling theory
- 549 Sector-bounded nonlinearities
- 550 Seeded region growing
- 551 Self-creating neural network
- 552 Self-structuring neural networks
- 553 Self-trapping
- 554 Sensitivity measure
- 555 Sensitivity measure network (RBFNN)
- 556 Sequential learning
- 557 Sequential Levenberg–Marquardt
- 558 Servomechanism problem
- 559 Shape from shading
- 560 Shortest path computation problem
- 561 Shunting and additive
- 562 Signal processing
- 563 Simple sum scheme
- 564 Simultaneous perturbation
- 565 Simultaneous recurrent network (SRN)
- 566 Single-hidden layer feedforward neural network (SLFN)
- 567 Singular value decomposition (SVD)
- 568 Sliding-mode control
- 569 Slowsolution
- 570 Software algorithms
- 571 Solution trajectories
- 572 Sparse models
- 573 Spiking
- 574 Spiking neuron
- 575 S-procedure
- 576 Stability
- 577 Stability analysis
- 578 Stability training
- 579 Stabilization
- 580 Stable distributions
- 581 State estimation
- 582 State observer
- 583 Stationary oscillation
- 584 Statistic tracking control (STC)
- 585 Statistical control
- 586 Statistical hypothesis tests
- 587 Steepest descent algorithms
- 588 Stochastic approximation

- 589 Stochastic delay
- 590 Stochastic perturbation
- 591 Stochastic systems
- 592 Striatum
- 593 Strictly monotone variational inequalities
- 594 Structure learning
- 595 Structured patterns
- 596 Subcellular localization
- 597 Success rate
- 598 Supervised learning
- 599 Supervised learning algorithm
- 600 Supervisory
- 601 Support vector machine
- 602 Surface normal
- 603 Survival modeling
- 604 Suspension testing
- 605 Switched systems
- 606 Synchronization
- 607 Synthesis
- 608 System identification
- 609 Temporal codin
- 610 Threshold-moving
- 611 Time series
- 612 Time series forecasting
- 613 Time-delays
- 614 Time-to-event data
- 615 Time-varying delay
- 616 Time-varying inputs
- 617 Time-varying Sylvester equation
- 618 Tire
- 619 Topology identification
- 620 Total coloring problem
- 621 Traffic identification
- 622 Training accuracy
- 623 Trajectory analysis and learning
- 624 Trajectory generation
- 625 Trajectory modulation
- 626 Transcendental function
- 627 Transmission radius
- 628 Triangular forms
- 629 Truncation
- 630 Two-layer Hopfield neural network
- 631 Two-layer networks
- 632 Unbounded time-varying delay
- 633 Uncertain systems
- 634 Uncertainty
- 635 Uniform convexity
- 636 Uniformly monotone variational inequalities
- 637 Uniqueness
- 638 Unmodeled dynamic
- 639 Unsupervised learning
- 640 Variable coefficient
- 641 Variable structure control
- 642 Variable structure system

- 643 Variational inequalities optimization
- 644 Variational inequality
- 645 Varying prices of electricity
- 646 Vector quantization
- 647 Very large scale integration (VLSI) neural networks
- 648 Video object extraction
- 649 Visual evoked potential
- 650 Volterra integro-differential systems
- 651 Volterra series of a digital satellite channel
- 652 Wave
- 653 Wavelet
- 654 Wavelet basis function neural network (WBFNN)
- 655 Wavelet transform
- 656 Weight couplings
- 657 Winners-take-all (k-WTA)
- 658 Wireless sensor networks
- 659 Yale database
- 660 Young inequality
- 661 Zero dynamics